

idpp 2022

International
Artificial
Intelligence
and Data Processing
Symposium

September / 08-09 / 2022
<http://idap.inonu.edu.tr> - <http://www.asoiu.edu.az>

ATATÜRK ÜNİVERSİTESİ
1920

ANATOLIAN
SCIENCE

1987
İNÖNÜ ÜNİVERSİTESİ
MÜHENDİSLİK
FAKÜLTESİ

Signal processing hardware
Information security
Robotics
Signal processing
Data Mining
Brain-computer interfaces
Deep learning
Data processing
Big data
Computer vision
Spatio-spectral analysis
Computational statistics

Organization Committee

Honory Chair/s	Prof. Dr. Ahmet KIZILAY (İnönü University)
	Prof. Dr. Ali KARCI (İnönü University)
	Prof. Dr. Mustafa BABANLI (Azerbaijan State Oil And Industry University)
Chairman	Doç. Dr. Kazım Hanbay
	Prof. Dr. Teymuraz ABBASOV
Technical Chair	Dr. Kenan İNCE
Organization Committee	A.A. Aydın (İnönü University)
	A. Aliyev (ADNSU)
	A. Arı (İnönü University)
	A. Ateş (İnönü University)
	A. Karadoğan (İnönü University)
	B.B. Alagöz (İnönü University)
	C. Hark (Turgut Özal University)
	C. İnce (İnönü University)
	C. Keleş (İnönü University)
	D. Hanbay (İnönü University)
	E. Ahmedov (ADNSU)
	E. A. Oymak (İnönü University)
	E. Hüseyinov (ADNSU)
	F. Okumuş (İnönü University)
	F. Öztemiz (İnönü Üniversitesi)
	G. Abdullayeva (ADNSU)
	G. İsmayılova (ADNSU)
	G. Mammadova (ADNSU)
	İ.B. Aydılek (Harran University)
	İ. Türkoğlu (Fırat University)
	K. İnce (İnönü University)
	M. Daşkın (İnönü University)
	M.E. Tağluk (İnönü University)
	M. Karaköse (Fırat University)
	M. Kaya (Fırat University)
	Ö. F. Özgüven (İnönü University)
	R. Daş (Fırat University)
	R. Kerimova (ADNSU)

S.E. Hamamcı (İnönü University)

S. Hanahmedova (ADNSU)

S. Mirzoyeva (ADNSU)

Ş. Nasirov (ADNSU)

S. Yakut (İnönü University)

T. Uçkan (Yüzüncü Yıl University)

Scientific Committee

Dr. Ahmet Arif Aydın (İnönü University)

Dr. Ahmet Çınar (Fırat University)

Dr. Ali Erdoğan (İnönü University)

Dr. Ali Karci (İnönü University)

Dr. Ali Kaveh (Iran University Of Science & Technology)

Dr. Ali Safak Sekmen (Tennessee State University)

Dr. Asım Kaygusuz (İnönü University)

Dr. Aşkın Demirkol (Sakarya University)

Dr. Ayhan İstanbullu (Balıkesir University)

Dr. B.Baykant Alagöz (İnönü University)

Dr. Bedri Özer (Fırat University)

Dr. Berat Doğan (İnönü University)

Dr. Bilal Alataş (Fırat University)

Dr. Bilal Şenol (İnönü University)

Dr. B. Ramakrishnan (S.T. Hindu College)

Dr. Bugra Koku (Middle East Technical University)

Dr. Burhan Ergen (Fırat University)

Dr. Burhan SELÇUK (Karabük University)

Dr. Cafer Bal (Fırat University)

Dr. Celaleddin Yeroğlu (İnönü University)

Dr. Cemil Çolak (İnönü University)

Dr. Çiğdem İnan ACI (Mersin University)

Dr. Davut Hanbay (İnönü University)

Dr. Deniz KILINÇ (Celal Bayar University)

Dr. Engin Avcı (Fırat University)

Dr. Erdem Erdemir (Tennessee State University)

Dr. Erdiñç Avaroğlu (Mersin University)

Dr. Erhan Akbal (Fırat University)

Dr. Erkan Tanyıldızı (Fırat University)

Dr. Fatih Özkaynak (Fırat University)

Dr. Fatih Tüysüz (Harran University)

Dr. Fuad Mammadov (Azerbaijan State Oil and Industry University)

Dr. Furkan Öztemiz (İnönü Üniversitesi)

Dr. Galip Aydın (Fırat University)

Dr. İbrahim Berkan Aydilek (Harran University)

Dr. İbrahim Türkoğlu (Firat University)

Dr. İlhan Aydın (Firat University)

Dr. Jaroslav Koton (Brno University of Technology)

Dr. Kazım Hanbay (İnönü University)

Dr. Kemal Balıkçı (Osmaniye University)

Dr. Latafat Gardashova (Azerbaijan State Oil and Industry University)

Dr. Mahmudur Rahman (Morgan State University)

Dr. Marouane EL MABROUK (Abdelmalek Essaadi University)

Dr. Mehmet ACI (Mersin University)

Dr. Mehmet Emin Tağluk (İnönü University)

Dr. Mehmet Karaköse (Firat University)

Dr. Mehmet Kaya (Firat University)

Dr. Morten Goodwin (University Of Agder)

Dr. M. Sıraç Özerdem (Dicle University)

Dr. Muhammed Fatih Talu (İnönü University)

Dr. Murat Canayaz (Yuzuncu Yil University)

Dr. Murat Demir (Mus Alpaslan University)

Dr. Murat Karabatak (Firat University)

Dr. Musa Çıbuk (Bitlis University)

Dr. Mustafa Türk (Firat University)

Dr. Ömer Faruk Ertuğrul (Batman University)

Dr. Omer Faruk Ozguven (İnönü University)

Dr. Prabir Bhattacharya (Morgan State University)

Dr. Recep Halicioğlu (Osmaniye Korkut Ata University)

Dr. Recep Ozdag (Yuzuncu Yil University)

Dr. Resul Daş (Firat University)

Dr. Ruksar Fatima (KBN College of Engineering)

Dr. Sabri Koçer (Necmettin Erbakan University)

Dr. Seda Arslan Tuncer (Firat University)

Dr. Selman Yakut (İnönü University)

Dr. Serdar Ethem Hamamci (İnönü University)

Dr. Taner Tuncer (Firat University)

Dr. Tolga Aydın (Atatürk University)

Dr. Ulaş Baran Baloğlu (University of Bristol)

Dr. Walter Boles (Middle Tennessee State University)

Dr. Yanhui Guo (University Of Illinois Springfield)

CONTENTS

Ahmet Güner , Evre Uyumlu Optik OFDM Haberleşme Sistemleri için k -En Yakın Komşuluk Algoritması ile Doğrusal Denkleştirci Verimliliğinin Artırılması	1
Abdullah Şener, Burhan Ergen , Weather Prediction from Multi-Class Images Using DenseNet Deep Learning Model and Augmentation Method	8
Seda Varol, Cengiz Hark, Soner Kızılok , Geri Dönüştürülebilir Atıkların Sınıflandırılması	19
Abdullah Şener, Burhan Ergen , Beyin MR Görüntüleri Üzerinde Tümör Tespitinde VGG-19 Model Tabanlı Yeni Bir Yaklaşım	26
Fatih Adıgüzel , Otonom Araçlar için Doğrusal Karesel Optimal Regülatör Tasarımına Dayalı Uyarlamalı Hız Kontrol Sistemi	34
Furkan Öztemiz , Label Propagation Community Optimization Via Boundary Nodes Transfers	40
Bekir Parlak , Makine Öğrenmesi Algoritmaları kullanarak Türkçe istenmeyen e-posta filtreleme	48
Barış Cincioğlu, Kaan Özdemir, Kağan Can Şit, Osman Altay , Predicting Sleep Routines After COVID-19 Using Machine Learning Methods	57
Esra Yüzgeç, Muhammed Talo , Derin Öğrenme Teknikleri Kullanılarak Alzheimer Hastalığı Aşamalarının Sınıflandırılması	64
Zeynep Aslanpençesi, Muhammet Baykara , Twitter Verileri Kullanılarak Kısa Metinler Üzerinde GRU ile Nefret Söylemi Tespiti	70
Sabit Babaoğlu, Mehmet Emin Tağluk , Nesne Yönünün Ayrık Fourier Dönüşümü ile Belirlenmesi: Biber Örneği	78
Musa Kaplan, Emrullah Acar, Ömer Türk , Pirinç Türlerinin HOG Temelli Öznitelik Vektörleri ve Farklı Makine Öğrenme Teknikleriyle Sınıflandırılması	84
Hülya Hark, Cengiz Hark, Ali Karcı , Türkçe Haber Başlıklarından Konu Tespiti	92
Ensar Arif Sağbaş , Rastgele Alt Uzay ve Lojistik Regresyon Yöntemleri Kullanılarak Duygu Analizi	100
Ömer Faruk Söylemez , Turkish news category classification using deep learning approaches: An evaluation of vocabulary size and text length	105
Bünyamin Kuzu, Ozan Akdağ, Mustafa Nurmhammed, Teoman Karadağ , A Simulation Study on Vehicle-to-Grid Implementation and Environmental Impacts	110

Serkan Koca, Mustafa Şeker, Hülya Doğan , Radyal Elektrik Dağıtım Sistemlerinde Gerilim Profillerinin İyileştirilmesi ve İletim Kayıplarının Azaltılması için Sistem Yapılandırmasına Bağlı Optimal Kapasitör Yerleşimi	120
Edanur Özdemir, İbrahim Türkoğlu , Yazılım Güvenlik Açıklarının Derin Öğrenme Kullanılarak Sınıflandırılması	133
Erkan Günerhan, Cemal Köse , LSTM tabanlı ağlarda ilave hiper parametre ile konuşmacı tanıma	141
Sinem Melike Turan, Mustafa Şeker , Fotovoltaik Sistemlerde Kullanılan Geleneksel MPPT Metotlarının Uniform Radyasyon ve Parçalı Gölgeleme Durumundaki Performanslarının Matlab/Simulink Yardımıyla İncelenmesi	148
Selman Yakut , Steganography Approach Based on the Least Significant Bit Technique	165
Fatih Okumuş , Deep Learning for Mobile Robot Position Prediction in RSSI Based Positioning Systems	170
Elşad Safiyev, Elbrus Ahmedov, Sona Rzayeva , AddIM GərgİnlİYİ Təhlükəsi və ondan etibarlı mühafizə	176
Gültekin Hasanova , Metropolitenin elektrik təchizatı sistemində reaktiv enerjinin kompensasiyasının idarə olunması	182
Zakir Hasanov, Samira Khanahmedova, Sara Alimamrdova, Saida Kerimova , Logical Engine Overheating Protection Program	190
Gülşen Kerimzade , Cərəyan Stabilizatorla İdarə Sisteminin Xüsusiyyətləri	194
Güləye Memmedova , Levitasiya Elementli Elektromexaniki Çeviricilərin Hesabında Nəzərə Alınan Faktorlar	200
Sevda Yaqub qızı Eliyeva , Dərin Quyların Qazılmasında Tətbiq Olunan Qazma Qurğusu Bucurqadının Kınematik Sxeminin Tərtibi	206
Tural Aliyev , Həll olmuş qazların analizi metodu əsasında güc transformatorlarındakı nasazlıqların qeyri-səlis məntiq nəzəriyyəsi ilə diaqnostikası	213
Hanife Göker , Multifractal Analysis and Ensemble Learning Approach for Diagnosing Developmental Coordination Disorder from EEG Signals	220
Dursun Öztürk, Kader Ozan , Derin Öğrenme Yöntemleri İle Rüzgâr Hızı Tahmini Üzerine Bir Derleme	229

Evre Uyumlu Optik OFDM Haberleşme Sistemleri için k -En Yakın Komşuluk Algoritması ile Doğrusal Denkleştirici Verimliliğinin Artırılması

Improving the Efficiency of Linear Equalizer with k -Nearest Neighbor Algorithm for Coherent Optical OFDM Communication Systems

Ahmet GÜNER¹ 

¹Elektrik-Elektronik Mühendisliği Bölümü, Bingöl Üniversitesi, Bingöl, Türkiye

(aguner@bingol.edu.tr)

Özetçe— Bu çalışmada, k -En Yakın Komşuluk (KNN) algoritması temelli evre uyumlu optik OFDM alıcı yapısı önerilmiştir. Önerilen alıcı yapısı içerisinde, KNN algoritması kullanılarak frekans düzlemi doğrusal kanal denkleştirici performansı iyileştirilmiştir. Buradaki yenilik, çok taşıyıcı modülasyon yapısı içerisinde KNN algoritmasının frekans düzlemi kanal denkleştiricisinden sonra bir hata detektörü olarak kullanılmasıdır. Benzetim sonuçları, önerilen yapının yüksek başlatma gücü seviyelerinde iyileştirme başarımlarını göstermektedir.

Anahtar Kelimeler : Evre uyumlu optik OFDM sistem, fiber doğrusal olmayan etki, k -En Yakın Komşuluk algoritması.

Abstract— In this paper, it is proposed a coherent optical OFDM receiver scheme based on k -Nearest Neighborhood (KNN) algorithm. In the proposed receiver scheme, the performance of the frequency domain channel equalizer is improved by using the KNN algorithm. The novelty is the KNN using as an error detector after the frequency domain channel equalizer in the multicarrier modulation scheme. Simulation results show the effectiveness of the proposed scheme at high launch power levels.

Keywords : Coherent optical OFDM system, fiber nonlinearity effect, k -Nearest Neighbors algorithm.

1. Giriş

Yüksek spektral verimlilik gerektiren optik haberleşme sistemlerinde, sinyal işleme tekniklerinin kullanımının artması ile M-QAM gibi gelişmiş modülasyon yapılarının önemi artmıştır. Fakat modülasyon seviyesinin artmasıyla istenilen performansa ulaşmak, daha yüksek optik sinyal gürültü oranı (OSNR) seviyelerinde mümkün olmaktadır ve yüksek OSNR, yüksek iletim gücü anlamına gelmektedir (Winzer 2012). Optik iletim kanallarında, yüksek iletim gücü, fiberlerde Kerr doğrusal olmayan bozulmalara neden olmaktadır (Zhang et al. 2017).

Fiber doğrusal olmayan etkiyi azaltmak, optik haberleşme sistemlerinin kapasitesinin artırılması için önemli bir süreçtir. Doğrusal olmayan bozulmaları kompanze etmek için birçok sinyal işleme teknikleri önerilmiştir (Dar et al. 2017, Amari et al. 2017). Sinyal işleme tekniklerinden birisi olan makine öğrenme teknikleri, otomatik modülasyon sınıflama, örüntü tanıma, görüntü işleme gibi farklı birçok alanda doğrusal olmayan dinamik sistemlere uygulanmaktadır (Güner et al. 2019). Özellikle optik haberleşme sistemlerinde, makine öğrenme teknikleri fiber doğrusal olmayan etkisinin etkin olduğu bölgelerde sistem performansını iyileştirmek için kullanılmaktadır (Mrabet et al. 2017, Giacomidis et al. 2015, Amari et al. 2019).


Günümüzde, fiber doğrusal olmayan etkiden kaynaklı sinyal bozulmalarını azaltmak için hesaplama karmaşıklığı azaltılmış ve uygulaması basit olan yeni sinyal işleme tekniklerini araştırmak önemli bir hale gelmiştir. (Amari et al. 2017)'te, doğrusal olmayan etkiyi azaltmak için destek vektör makinesinin

(Support Vector Machine-SVM) uygulanabilirliği gösterilmiştir. Ancak, SVM yalnızca ikili sınıflandırıcıdır ve bu nedenle yüksek dereceli modülasyon yapıları için birçok SVM gerekmektedir. (Mrabet et al. 2017)'te, yapay sinir ağı (YSA) kullanılmıştır fakat YSA kullanımı, çok daha uzun eğitim süresi gerektirmektedir.

Herhangi bir ön bilgi ve uzun eğitim süreci olmadan, k-en yakın komşuluk (K-Nearest Neighbors-KNN) algoritması sadece küçük bir etiketlenmiş veri kümesinden özelliklerini öğrenmektedir. (Jiang et al. 2018)'de, tek-taşıyıcılı optik haberleşme sistemlerinde genlik ve faz gürültüsünden kaynaklanan hataları önlemek için doğrusal olmayan bir karar sınırı oluşturulmuştur. Geleneksel yöntemle karşılaştırıldığında, KNN daha uzun iletim mesafesi ve fiber doğrusal olmayan etkiye karşı daha yüksek tolerans sağladığı gösterilmiştir.

OFDM tekniği, yüksek spektral verimliliğe sahip ve semboller arası girişime karşı dayanıklı çoklu taşıyıcılı modülasyon tekniğidir. Evre uyumlu optik OFDM yapıları, hem evre uyumlu optik alıcıların ve hem de OFDM tekniğini birleştirmesinden dolayı her iki yapının avantajlarını kullanabilmektedir (Güner 2022). Bu nedenle, iletilen sinyal üzerindeki optik kanalın doğrusal ve doğrusal olmayan bozucu etkilerini kompanze etmek için alıcı tarafta denkleştirici kullanımına imkan sağlamaktadır.

Optik kanalın doğrusal olmayan bozucu etkisini kompanze etmek için denkleştiricilerde daha karmaşık yapılar yada doğrusal olmayan fonksiyonlar kullanılmaktadır. Bu durum denkleştiricinin performansını artırdığı gibi beraberinde hesaplama karmaşıklığını da artırmaktadır. Bu çalışmada, evre uyumlu optik OFDM haberleşme sistemleri için tek-taplı frekans düzlemi kanal denkleştirici çıkışında bir detektör olarak KNN yönteminin uygulanarak, fiber doğrusal olmayan etkinin etkin olduğu bölgede BER başarımının artırılması amaçlanmıştır ve gerçek uygulamalarda kullanılabilir hesaplama karmaşıklığı düşük yeni bir yapı önerilmiştir.



Şekil 1. Evre uyumlu Optik OFDM sisteminin blok gösterimi

2. Evre Uyumlu Optik OFDM Sistemi (Coherent Optical OFDM System, CO-OFDM)

Evre uyumlu optik OFDM sistemine ait blok diyagram Şekil 1'de gösterilmektedir. CO-OFDM sisteminde veri setleri, kullanılacak semboller için seçilen M-QAM modülasyon yapısına göre eşleştirilerek oluşturulmaktadır. Ters-FFT (IFFT) işlemi uygulanarak oluşturulan OFDM sembolleri, elektriksel sinyalden optik sinyale iki IQ optik modülatör (Mach-Zehnder Modulator-MZM) kullanılarak dönüştürülmektedir.

Fiber optik iletim hattı, eşit uzunluklu birden çok fiberden oluşmaktadır. Literatürde bulunan çalışmalar incelendiğinde, optik ağlar ve fiber optik iletişim sistemlerinin standart tek modlu fiber (standard single mode fiber-SSMF) temelli olduğu görülmektedir. Optik kanallarda, eşit uzunluklu her bir fiber boyunca iletilen sinyalin hat zayıflamalarını kompanze etmek için erbiyum katkılı fiber kuvvetlendirici (erbium-doped fiber amplifier-EDFA) kullanılmaktadır.

Alıcıda optik sinyal, 90° optik hibrit kullanılarak elektriksel sinyale dönüştürülmekte ve elektriksel sinyallerden FFT işlemi ile frekans düzleminde OFDM sinyaline ait her bir alt taşıyıcı ile iletilen veri

setleri elde edilmektedir. Optik iletim ortamının veri setleri üzerindeki bozucu etkilerinin giderilmesi için sinyal işleme yöntemleri kullanılmaktadır (Güner 2022).

3. Frekans Düzlemi Doğrusal Kanal Denkleştirici

Çoklu-taşıyıcılı modülasyon yapılarında, alıcıda gönderilen sinyalin doğru olarak elde edilebilmesi için her bir alt taşıyıcı ait kanal kazancını kestirebilmek önemlidir. OFDM sinyallerinde, yayılım ortamının bozucu etkilerini kompanze etmek için tek-taplı frekans düzlemi denkleştirici kullanılmaktadır.

$$\hat{X}_l = \frac{Y_l}{H_l} \quad (1)$$

burada l parametresi alt-taşıyıcı indeksini, $\hat{X}_l$ ifadesi denkleştirilmiş sinyali, H_l ifadesi l .alt-taşıyıcı için kestirilen kanal katsayısı ve Y_l ifadesi FFT işleminden sonra alınan sinyali temsil etmektedir.


$$\hat{H}_l = \frac{Y_{TSI}}{X_{TSI}} \quad (2)$$

Kanal katsayıları, (2) denklemi ile hesaplanmaktadır. Her bir alt taşıyıcıya ait kanal katsayılarının hesaplandığı işlem, alınan ve gönderilmiş eğitim dizilerinin doğrusal olarak bir birlerine oranlanmasından ibarettir. Bundan dolayı yayılım ortamının doğrusal olmayan etkileri doğrusal denkleştirici yapısı ile düzeltilememektedir (Güner 2022).

4. k -En Yakın Komşuluk Algoritması

k -En yakın komşuluk (KNN) algoritması, en popüler parametrik olmayan metotlardan birisidir. KNN algoritmasının avantajı, etiketlenmiş verilerin sembol kararı için yeterli olması ve algoritmanın başka ek parametrelere ihtiyaç duymamasıdır. Bu nedenle KNN algoritması nispeten basittir.

Basitliği ve esnekliği sayesinde, KNN algoritması örüntülerin sınıflandırılmasında sıkça kullanılmaktadır. SVM algoritmasından farklı olarak, KNN algoritması çok sınıflı bir sınıflayıcıdır. Örüntüler iki boyutlu uzayda noktalar olduğu zaman, KNN algoritması aynı anda birden fazla veri türünü sınıflandırabilir (Şekil 2’de gösterildiği gibi). KNN algoritması, etiketli verilerin k en yakın komşuları arasındaki çoğunluk oylama kuralı ile test verisini sınıflandırır. KNN algoritması, test verisinin etiketini yalnızca en yakın k etiketlenmiş verilere göre tanımlar (Wang et al. 2016, Zhang et al. 2018).



Şekil 2. QPSK yıldız kümesi diyagramı ve KNN tarafından tespit edilen bir test veri noktası örneği

Şekil 2’de, KNN algoritmasının şematik diyagramı gösterilmektedir. Şekil 2’de, m_1 , m_2 , m_3 ve m_4 kategorileri içerisinde sırasıyla mavi, mor, kırmızı ve yeşil renklerle gösterilen etiketlenmiş verilerden dört set vardır. Belirlenen kategorilerin dışında bir noktada bulunan ve Şekil 2’de yıldız ile gösterilen bir test verisinin olduğu kabul edilirse, test verisinin bu kategorilerden hangisine nasıl sınıflandırılacağı;

İlk olarak test verisi ile her bir etiketlenmiş veri arasındaki Öklid mesafesinin hesaplanması gerekmektedir. y_{train} ve y_{test} arasındaki Öklid mesafesi (3) denklemi ile hesaplanmaktadır,

$$D_i = \text{sqrt} \left(\left(\text{Re}(y_{train}^i) - \text{Re}(y_{test}) \right)^2 + \left(\text{Im}(y_{train}^i) - \text{Im}(y_{test}) \right)^2 \right) \quad (3)$$

Burada, Re ve Im , gerçel ve sanal kısımları göstermektedir. Sonra test verisinden en kısa mesafedeki k en yakın etiketlenmiş verilerin belirlenmesi gerekmektedir. Tahmin süreci, en yakın komşularda en çok üyeye sahip olan sınıf olacaktır. Örneğin Şekil 2’de, kırmızı kesik çizgili daire içerisinde 5 en yakın komşu ($k=5$) algoritması sınıflandırıcı yapılırsa, bu örneğin 5 en yakın komşusunun üçü ikinci sınıfa, diğer ikisinden birisi birinci sınıfa ve diğeri dördüncü sınıfa aitse, test örneğinin ikinci sınıfa ait olduğu sonucuna varılır.

Her hangi bir test verisi için, sadece test verisi ve etiketlenmiş veriler arasındaki Öklid mesafesinin hesaplanması gerekmektedir. Oluşturulan Öklid mesafe metriğine göre karşılık gelen test verisinin kategorisi belirlenir.

KNN algoritmasında, k değerinin belirlenmesi önemli bir adımdır. k ’nın farklı değerleri farklı sonuçlara neden olmaktadır. Bu nedenle, yüksek bir doğruluk elde etmek için, ilgili duruma göre uygun k değerinin seçilmesi önemlidir. Eğitim süreci boyunca sınıflandırıcı parametrelerini öğrenmek zorunda olan diğer makine öğrenme yöntemlerinden farklı olarak, KNN algoritmasının test verilerini etiketli verilere göre doğrudan sınıflandırabilmesinden dolayı gerçek uygulamalarda kullanılabilir düşük hesaplama karmaşıklığına sahiptir.

Şekil 2’de gösterildiği gibi QPSK modülasyon yapısının yıldız kümesi noktaları iki boyutlu bir alanda farklı veri sınıfları olarak kabul edilirse, KNN dört sembol sınıfı için karar sınırı oluşturmak için kullanılabilir. Karar sınırı oluşturulurken, (m_1, m_2, m_3 ve m_4) ilgili etiketleri içeren bazı semboller etiketli veri olarak kullanılır. Daha sonra, test verileri KNN tarafından oluşturulan karar sınırı ile sınıflandırılabilir.

Tablo 1. OFDM Parametreleri

Parametre	Değer
FFT/IFFT uzunluğu (N_{FFT})	256
Çevrimsel önek	% 6.25
Modülasyon	QPSK,16QAM
OFDM simge hızı	39.06 MHz

5. Benzetim

Evre uyumlu optik OFDM sistemi üzerinde optik kanal bozucu etkilerini araştırmak için Şekil 1’de gösterilen blokların MATLAB platformunda benzetimi oluşturuldu. Oluşturulan benzetimde, ilk olarak random ikili dizi üretilir ve M-QAM modülasyon ile semboller üretilir. Sonra Tablo 1’de belirtilen parametre değerlerine sahip OFDM modülatör çıkışında elektriksel sinyal üretilir. Ayrık zamanlı OFDM sinyali, (4) denklemi ile gösterilebilir.

$$s[k] = \sum_n \sum_{m=0}^{N-1} a_{m,n} g \left[k - n \frac{N}{2} \right] e^{j \frac{2\pi m k}{N}} e^{j \frac{\pi}{2} (m+n)} \quad (4)$$


Burada N her bir OFDM sembolünde kullanılan alt-taşıyıcı sayısını, $a_{m,n}$ n .OFDM sembolündeki m .alt-taşıyıcı ile iletilen karmaşık değerli sembolü ve g darbe şekillendirici filtrenin birim vuruş cevabını göstermektedir (Fang et al. 2016).

Benzetim sürecinde optik sinyal, her biri 0.1ps/√km polarizasyon-mod dispersiyona sahip 100 km standart tek modlu fiberden oluşan bir iletim hattı üzerinden iletilmektedir. Ayrıca optik sinyal, her 100 km standart tek modlu fiber içerisinde 5dB gürültü değerine sahip erbiyum katkılı fiber kuvvetlendirici ile güçlendirilmektedir. Standart tek modlu fibere ait parametreler ise, zayıflama $\alpha = 0.2$ dB/km, kromatik dispersiyon $D = 18$ ps/nm.km ve doğrusal olmayan katsayı $\gamma = 1.2$ W⁻¹km⁻¹. Fiber içerisinde optik sinyal yayılımı, doğrusal olmayan Schrödinger denklemi (Non-Linear Schrödinger Equation-NLSE) ile modellenmektedir (Jiang et al. 2017).

$$\frac{\partial A}{\partial z} + \frac{j\beta_2}{2} \frac{\partial^2 A}{\partial t^2} + \frac{\alpha}{2} A = j\gamma A|A|^2 \quad (5)$$

Burada β_2 parametresi grup hız yayılımını, z parametresi iletim mesafesini ve A parametresi sinyalin zarfını ifade etmektedir. Yayılım ortamı, bölünmüş adım Fourier yöntemi (Split-Step Fourier Method-SSFM) kullanılarak benzetimi gerçekleştirilmiştir (Ma et al. 2004). Alıcı tarafında, 90° optik hibrit ile optik sinyaller elektriksel sinyale dönüştürülür. Bundan sonraki süreç Şekil 1’de gösterilen işlem adımlarını içermektedir. İşlem adımları, OFDM demodülatör, frekans düzlemi doğrusal kanal denkleştirici (FDDKD), KNN detektörü, demodülasyon ve son olarak bit hata oranı (BER) değerlendirmesidir.

Benzetimler, bir birinden bağımsız 100 kanal ile gerçekleştirilmiştir. Gürültü olarak toplanır beyaz Gauss gürültüsü kullanılmıştır. Vericide veriler, sözde rasgele ikili dizi (Pseudorandom Binary Sequence-PRBS) üretici ile üretilip sonra QPSK modülasyon sembolleri ile eşleştirilmesiyle elde edildi. Benzetimlerde, senkronizasyon hatasının ve taşıyıcı frekans kayma etkisinin olmadığı kabul edilmiştir. Ayrıca KNN algoritmasında kullanılan en yakın komşuluk sayısı 5 ($k=5$) seçilmiştir.



Şekil 3. 900 km iletimden sonra QPSK için başlatma gücünün değişimine karşı BER başarımları

6. Benzetim Sonuçları ve Tartışma


Yüksek başlatma gücü daha fazla doğrusal olmayan bozulmaya neden olmaktadır. Bu nedenle başlatma gücü arttıkça yıldız-kümesi noktalarında artan saçılmalar görülmektedir.

Doğrusal olmayan etki, doğrusal olmayan Schrödinger denklemine göre sinyalin anlık gücüne bağlıdır. Bu nedenle başlatma gücü, sistemin performansını doğrudan etkiler. Daha yüksek güce sahip sinyal, gürültüye karşı daha büyük bir toleransa sahiptir, ancak daha yüksek güç doğrusal olmayan bozulmalara da neden olabilir. Bu nedenle, modülasyon yapısına göre değişen minimum bir-hata-oranlarına (BER) ulaşmak için optimum bir başlatma gücü seviyesi gereklidir.

QPSK modülasyonu için başlatma gücüne karşı BER performansları Şekil 3’de gösterilmektedir. BER performansı, optimum başlatma gücü seviyesinden daha düşük seviyelerde artarken, optimum başlatma gücü seviyesinden daha yüksek seviyelerde düşmektedir. Çünkü düşük başlatma gücü seviyelerindeki fiber kablo doğrusal filtre olarak modellenmiş ve doğrusal bozulma ve gürültü

etkilerinin mevcut olduğu tespit edilmiştir. Ancak optimum fırlatma gücü değerine ulaşıldıktan sonra fiber doğrusal olmayan etkisinin daha güçlü olduğu görülmüştür.

FDDKD ile FDDKD-KNN'nin performansları karşılaştırıldığında, yüksek başlatma gücü seviyelerinde FDDKD-KNN, FDDKD'den daha iyi performans göstermektedir. İleri hata düzeltme sınırı ($BER=10^{-3}$) için QPSK modülasyonunda FDDKD-KNN ile FDDKD karşılaştırıldığında başlatma gücünde yaklaşık 1dB'lik genişleme olduğu Şekil 3'deki değişimlerde görülmektedir.



Şekil 4. QPSK için OSNR değişimine karşı BER başarımları

Fiber doğrusal olmayan etkinin düşük olduğu durumu analiz etmek için, optimum başlatma gücü seviyesinde ve QPSK modülasyonlu sinyallerde BER performansları, farklı optik gürültü seviyeleri aracılığıyla karşılaştırılmıştır. QPSK modülasyonu için farklı optik sinyal-gürültü oranı (OSNR) seviyelerine karşılık kanal denkleştiricilerin BER performansları, Şekil 4'de gösterilmektedir.

Denkleştiricileri karşılaştırdığımız zaman, ileri hata düzeltme sınırı için önerilen FDDKD-KNN ile QPSK modülasyonunda yaklaşık 1.5dB'lik bir kazanç elde edilmektedir.

7. Sonuç

Optik haberleşme sistemlerinde evre uyumlu OFDM alıcılar için doğrusal olmayan bozucu etkinin etkin olduğu bölgelerde kullanılan frekans düzlemi doğrusal kanal denkleştiricinin performansını iyileştirmek amacıyla KNN temelli bir alıcı yapısı önerilmiştir. Önerilen yapının daha başarılı olduğu yapılan analizlerle gösterilmiştir. OFDM sisteminde kullanılan klasik frekans düzlemi doğrusal kanal denkleştiricisi ile önerilen denkleştirici, farklı başlatma gücü ve optik gürültü seviyelerinde karşılaştırıldığı zaman önerilen yapının sağlamış olduğu avantajlar başarımlarıyla gösterilmiştir.

Kaynaklar

- Winzer P. J. (2012) High-Spectral-Efficiency Optical Modulation Formats. *Journal of Lightwave Technology* 30(24): 3824-3835.
- Zhang J., Chen W., Gao M., and Shen G. (2017) K-means-clustering-based fiber nonlinearity equalization techniques for 64-QAM coherent optical communication system. *Optics Express* 25: 27570-27580.

- Dar R. and Winzer P. J. (2017) Nonlinear interference mitigation: Methods and potential gain. *Journal of Lightwave Technology* 35(4): 903-930.
- Amari A., Dobre O. A., Venkatesan R., Kumar O. S. S., Ciblat P. and Jaouen Y. (2017) A Survey on Fiber Nonlinearity Compensation for 400 Gb/s and Beyond Optical Communication Systems. *IEEE Communications Surveys & Tutorials* 19(4): 3097-3113.
- Güner A., Alçin Ö.F., Şengür A. (2019) Automatic digital modulation classification using extreme learning machine with local binary pattern histogram features. *Measurement* 145: 214-225.
- Mrabet H., Dayoub I., Haxha S., Attia R., Mhatli S., Giacomidis E. (2017) A novel support vector machine robust model based electrical equaliser for coherent optical orthogonal frequency division multiplexing systems. *IET Communications* 11(7): 1091-1096.
- Giacomidis E., Le S. T., Ghanbarisabagh M., McCarthy M., Aldaya I., Mhatli S., Jarajreh M. A., Haigh P. A., Doran N. J., Ellis A. D., and Eggleton B. J. (2015) Fiber nonlinearity-induced penalty reduction in CO-OFDM by ANN-based nonlinear equalization. *Optics Letters* 40: 5113-5116.
- Amari A., Lin X., Dobre O. A., Venkatesan R. and Alvarado A. (2019) A Machine Learning-Based Detection Technique for Optical Fiber Nonlinearity Mitigation. *IEEE Photonics Technology Letters* 31(8): 627-630.
- Jiang L., Yan L., Yi A., Pan Y., Pan W. and Luo B. (2018) K-Nearest Neighbor Detector for Enhancing Performance of Optical Phase Conjugation System in the Presence of Nonlinear Phase Noise. *IEEE Photonics Journal* 10(2): 1-8.
- Güner, A. (2022). Evre Uyumlu Optik OFDM Sistemler için Karmaşık Aşırı Öğrenme Makinası Tabanlı Doğrusal Olmayan Denkleştirici. *Avrupa Bilim ve Teknoloji Dergisi* 33: 26-31.
- Wang D. et al. (2016) Nonlinearity Mitigation Using a Machine Learning Detector Based on k -Nearest Neighbors. *IEEE Photonics Technology Letters* 28(19): 2102-2105.
- Zhang J., Gao M., Chen W. and Shen G. (2018) Non-Data-Aided k -Nearest Neighbors Technique for Optical Fiber Nonlinearity Mitigation. *Journal of Lightwave Technology* 36(17): 3564-3572.
- Fang X., Xu Y., Chen Z., and Zhang F. (2016) Time-domain least square channel estimation for Polarization-Division-Multiplexed CO-OFDM/OQAM systems. *Journal of Lightwave Technology* 34(3): 891-900.
- Jiang L., Yan L., Yi A., Pan Y., Hao M., Pan W., Luo B., and Jaouen Y. (2017). Chromatic Dispersion, Nonlinear Parameter, and Modulation Format Monitoring Based on Godard's Error for Coherent Optical Transmission Systems. *IEEE Photonics Journal* 10(1): 1-12.
- Ma C. P. and Kuo J. W. (2004). Orthogonal frequency division multiplex with multi-level technology in optical storage application. *Japanese Journal of Applied Physics* 43: 4876-4878.

Weather Prediction from Multi-Class Images Using DenseNet Deep Learning Model and Augmentation Method

Abdullah ŞENER^{*1} , Burhan ERGEN² 

¹Department of Computer Technologies, Genc Vocational School, Bingol University, Bingol, Turkey

²Department of Computer Engineering, Faculty of Engineering, Firat University, Elazig, Turkey

(asener@bingol.edu.tr, bergen@firat.edu.tr)

Abstract— Weather conditions, by their very nature, cannot be changed. However, knowing the weather conditions in advance can help people plan their physical activities. In the study, we attempted to make weather predictions using sky images taken from Earth using the methods of multiclass image classification and data augmentation, which are popular research topics. A dataset of 1800 images with different weather conditions and resolutions was used for the study. Feature maps of the images were created by applying image processing methods to the images. In the next step, classification was performed with a hit rate of 91.6%. Considering the success in classification, weather conditions provide us with a different prediction method.

Keywords : *Image Classification, Artificial Neural Networks, Deep Learning, DenseNet.*

1. Introduction

Physical environmental factors have important effects on an individual's life. Individuals usually plan their daily lives with the elements of the physical environment in mind. Weather conditions are at the top of the list of physical environmental factors. Weather conditions are often one of the factors that individuals consider when determining their daily activities. The prediction of this structure, which is important to the individual's life, has a significant impact on facilitating the individual's life. Scientifically, weather forecasts are made in various ways. Current weather forecasting systems use a number of expensive sensors to determine weather conditions. In addition, the information provided by these sensors must be interpreted according to human experience. Performing these operations on a single image using computer vision techniques is more advantageous in terms of both cost and time. Recognising weather conditions on a single image is a simple and easy task for humans. For an autonomous system, this process is more difficult. Accurate weather predictions can be achieved by developing a good weather classification system that uses a single image as input data. In this study, an attempt was made to determine weather conditions by applying image classification methods to sky images with different weather conditions, and successful results were obtained.

Image classification applications have become popular studies in light of recent findings (Liu and etc., 2019). Image classification involves grouping images with similar features. In image classification, the gray values of individual pixels are converted into meaningful information and used. Image classification can be done using rules that take into account the spectral values of the pixels on the image, or based on shapes, patterns, neighborhoods of pixels, etc. generated by the pixels. It is the process of classifying images into classes based on features such as (Gao, 2009). The main purpose of image classification is to collect and group images with the same spectral features by examining the images (Campbell, 1996). Image classification is the process of determining which class a pixel belongs to after mathematical operations are applied to the pixel, based on the reflection of objects from different angles in images with the goal of remote sensing, based on the values in different channels for each pixel in the image. In image classification, different methods are used for simple image recognition. Image classification involves detecting pixels with similar features and merging these pixels. The information about the accuracy of the extracted feature map of a target region is the final result that is sought in classification (Wilkie, 1996). The steps of the image classification process are shown in Figure 1.




Figure 1. Image Classification Steps

In the literature review, many studies have been conducted on the classification of images of different weather conditions using Deep Learning methods. Some of these studies were investigated by M. Roser et al. In their study, they classified weather conditions on monochrome images (Martin and Frank, 2008). Their study showed an error rate of less than 1% in distinguishing between clear weather and heavy rain. Mohammed E. et al. worked on weather classification using deep evolutionary neural networks (Mohamed and etc., 2015). The classification process was performed with 82.2% accuracy in their study. Jeong A. et al. worked on weather classification using convolutional neural networks (Jehong and etc., 2018). In their study, Alexnet and multi-class SVM (Alexnet MCSVM) were used together. The results were accuracy rates of 86% and 75% for image classification, respectively. The accuracy rates of Resnet together with Multi-Class SVM (Resnet-MCSVM) were reported to be 92% and 88%, respectively. Li-Wei K. et al. worked on weather image recognition based on Deep Learning (Kang and etc., 2018). In their study, an accuracy rate of 92% was achieved. Jose C. et al. Weather classification: they studied the new multi-class dataset, a data augmentation approach and comprehensive Convolutional Neural Networks evaluations (Jose and etc., 2018). The highest success rate in their classification studies was achieved with ResNet-50. An accuracy rate of 80% was achieved with ResNet-50.

In the study, the sky images with different classes and weather conditions were first reduced from the Earth and the data were enlarged. Then the classification process was performed using CNN and DenseNet methods. Based on the obtained results, the weather conditions are determined.

As for the other parts of the study, the materials and methods are mentioned in the second part. This section also contains information about the proposed method. The results of the experimental analysis can be found in the third section. Discussion and results can be found in the 4th section.

2. Material and Method

This section contains information about the dataset used for classification and the model used for classification.

2.1. Data Set:

In the study, a dataset of sky images taken from the ground was used to evaluate the performance of the model under test. This dataset consists of 6 categories: Cloudy, Foggy, Rain, Shimmer, Snow, and Sunrise. These categories also include 1800 images with different resolutions (Data set, 2021). Example images for the dataset used in the study are shown in Figure 2.




Figure 2. Example images representing classes of weather data: a) cloudy b) foggy c) rainy d) shine e) snow f) sunrise (Data set, 2021).

2.2. Augmentation:

One of the biggest problems with machine learning and deep learning studies is the lack of training data for the network. Due to the lack of data, the network created by rote learning has problems recognizing and classifying data outside of the dataset. One way to solve this problem is to increase the number of training data, and another way is the augmentation method. In this method, more artificial images are obtained by applying some operations to the images in the existing dataset. In data augmentation, artificial images are obtained by applying Horizontal Flip, Shift Scale Rotate, Random Rotate 90, Random Brightness Contrast, Transpose, Shift Scale Rotate, Blur, Optical Distortion and Grid Distortion data augmentation methods to the images.

2.3. Deep Learning:

Deep Learning is an artificial neural network consisting of one or more hidden layers and includes machine learning methods similar to these neural networks. The purpose of Deep Learning is to obtain new information that is different from the information that at least one artificial neural network contains. There are supervised, semi-supervised and unsupervised Deep Learning methods (Bengio and etc., 2015). Artificial neural networks were created by modeling the learning of information in biological domains and drawing new conclusions from the information. The learning process of computers and drawing new conclusions was developed similar to the working principle of the human brain. Although they try to perform the same task, there are some differences between artificial neural networks and the human brain. Comparing the two structures, the brain is dynamic and analog, while neural networks are static and symbolic (Marblestone and etc., 2016; Olshausen, 1996; Bengio, 2015).

One of the most popular methods among Deep Learning methods is the CNN architecture (Gu and etc., 2018). When classifying images, CNN architecture draws on the visual cortex of the brain to collect similar features and recognize objects (Min and etc., 2017; Milletari and etc., 2016). The CNN architecture performs various explorations of images in different layers. The CNN architecture is a combination of convolutional layer, nonlinear layer, pooling layer, smoothing layer and fully linked layers (Hanbay, 2020).

Let's now consider the structure of the CNN architecture and the characteristics of each layer: The layer where the most intensive mathematical operations are performed is the convolutional layer. The convolutional layer is the foundation of the CNN architecture. In this layer, low and high level feature detection is performed by applying some filters to the images. In the nonlinear layer, the nonlinearity in the system is determined. The ReLU function gives the best results in this layer. The ReLU function is shown in equation 1:

$$(f * g)(t) = \int_{-\infty}^{+\infty} f(T)g(t - T)dT \quad (1)$$

The output of the function is as shown in equation 2:

$$f(x) = maks(0, x) \quad (2)$$

The process of reducing the number of parameters in the network by reducing the size of the feature maps and reducing the number of weights in the system takes place in the pooling layer. The task of the Flattening layer is to prepare the data for input to the Fully Connected layer, the final layer of the CNN architecture. Typically, this is done by having this layer convert the received data into a one-dimensional matrix. It establishes the relationship between the input layer and the output layer in the fully connected layer (Niepert and etc., 2016; Kurt, 2018).

2.4. DenseNet

In a densely interconnected convolutional network, each layer of the network takes the previous layer's information as input, adds its own layer's information to that information, and passes it on to the next layer as input data. In this way, layers are forward connected in densely connected convolutional networks (Kumar, 2019). The main feature of the densely connected convolutional network is that it allows the reuse of features through propagation. In this way, the number of parameters in the system decreases (Huang and etc., 2017). A densely connected convolutional network is shown in Figure 3 (Li and etc., 2020).




Figure 3. DenseNet Architecture [24].

2.4.1. Structure of DenseNet

Conventional feedforward neural networks connect the output of the l^{th} layer to the next $(l + 1)^{\text{th}}$ layer after applying a combination of $H_l(-)$ operations. Typically, this combination includes mass normalization and activation functions in a convolutional operation or a combination of layers. An example of a 5-layer DenseNet architecture with 4 extensions is shown in Figure 4. The equation of the DenseNet structure is shown in equation 3:

$$x_l = H_l(x_{l-1}) \quad (3)$$




Figure 4. 5 Layer DenseNet with 4 Extensions (Huang and etc., 2018).

The structure of ResNet is created by including the jump link in the structure described above. The equation of ResNet is as shown in equation 4:

$$x_l = H_l(x_{l-1}) + x_{l-1} \quad (4)$$

The first difference 1 between DenseNet and ResNet can be seen in the equations above. DenseNet outputs the layer by combining feature maps with incoming feature maps instead of collecting them. Taking this information into account, the updated version of the DenseNet equation is as shown in equation 5:

$$x_l = H_l([x_0, x_1, x_2, \dots, x_{l-1}]) \quad (5)$$

In studies of ResNet, the problem often arises as to whether the grouping in these feature maps is an addition or a merger. This problem does not arise with DenseNet because the dimensions are different. Just as in ResNet the size of the feature maps within a block remains constant, in DenseNet the size of the feature maps remains constant, but the number of filters and between them the feature maps must be divided into DenseBlocks. The layers between the blocks are called transition layers and deal with subsampling by applying bulk normalization, 1 convolution and 2x2 pooling layers. The channel size increases with each layer as the feature maps are combined. Each time k is created to generate feature maps, the equation for the l^{th} layer is as shown in equation 6:

$$k_l = k_0 + k * (l - 1) \quad (6)$$

In the equation 6, the parameter k is the growth rate. The growth rate determines how much information is added to the network at each level. The information of a network is expressed by feature maps. In the DenseNet, each layer has access to the feature maps of the previous layer. Each layer of the DenseNet adds new information to the information it receives from the previous layer. It then transfers this information to the next layer.

2.4.2. DenseNet-B

DenseNet-B is a DenseNet that uses 1x1 convolution to increase efficiency and reduce the size of feature maps.

2.4.3. DenseNet-BC

As with DenseNet-B, DenseNets-C can be used to reduce the number of feature maps. The compression factor (Θ) determines the reduction process. The compression factor (Θ) is in the range of [0-1]. Thanks to the compression factor, the feature maps have Θm feature maps instead of m features. The architecture of Dense-121 is shown in Figure 5.




Figure 5. Dense-121 Architecture.

2.4.4. Dense and Transition Blocks

The volume of increase after each Dense Block is obtained by multiplying the growth rate by the number of Dense Levels in the Dense Block. The architecture of DenseNet-121, which has been deepened by one level, is shown in Figure 6.




Figure 6. One level deepened DenseNet-121 architecture.

2.4.5. Dense Layers

Considering the information mentioned above, Dense Block volume increases as the number of Dense Tiers is multiplied by the growth rate. Each layer adds 32 new feature maps to the previous density. So after 6 layers feature maps become 256. Also, the Transition Block consists of 128 filters and 1x1 convolutions. After the Transition Block comes to the 2-step 2x2 pooling layer. In the Pooling layer, the Density Block volume and the size of the feature maps are halved. A full schematic illustration of the DenseNet-121 with 2 depth levels is shown in Figure 7.




Figure 7. 2 Levels of Depth. Full Schematic Demonstration of DenseNet-121.

2.5. Proposed Approach

The structure of the deep neural network-based model proposed for the classification of celestial images from Earth is shown in Figure 8. In the study, the images must first be resized after input, which is important for both computer memory and faster classification. To train deep neural networks, the dimensions of the images that serve as input must be the same. The images that serve as input are resized to a fixed size before being processed in the convolutional neural network (CNN) architecture. While the images are resized to a fixed size, they should not be resized too much. If the image is reduced more than necessary, it is difficult to extract the information needed to classify the image. Considering these warnings, images with different resolutions were downsized to a resolution of 240x240. Then, feature extraction was performed by transferring the reduced images to the DenseNet neural convolutional network.




Figure 8. General design and process steps of the proposed approach

3. Experimental Results and Research Findings

The performance of the models created was evaluated using the complexity matrix method. Consider some terms used in the creation of the complexity matrix: TP: true positive, FP: false positive, TN: true negative, and FN: false negative. The probability that the model predicts the positive class label from the inputs is given by the sensitivity. The mathematical operation required to calculate the sensitivity is as shown in equation 7.

$$Sensitivity = \frac{TP}{TP + FP} \quad (7)$$

The probability that the model can predict the negative class label from the inputs is expressed by the specificity. The mathematical operation required to calculate the specificity is as shown in equation 8.

$$Specificity = \frac{TN}{TN + FN} \quad (8)$$

It is expressed with accuracy whether the model is correct or not. The mathematical operation required to calculate accuracy is as shown in equation 9.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

The F1-score is another evaluation criterion used to measure the precision and sensitivity of the generated model (Aksoy and etc., 2020). The mathematical operation required to calculate the F-score is as shown in equation 10 (Ruuska and etc., 2018).

$$F1 - Skor = \frac{2TP}{TP + FP + FN} \quad (10)$$

The equations shown above are commonly used for binary classifications. By using the average of the values calculated for the classes, the performance of the model containing two or more classes can be calculated (Peldek and Becerikli, 2019). The average accuracy, specificity, sensitivity, and F1-score ratios of these classes are calculated by the mathematical operations given in 11, 12, 13, 14 (Sokolova and Lapalme, 2009; Ballabio and etc., 2018).

$$Average Accuracy = \frac{\sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + FN_i + FP_i + TN_i}}{l} \quad (11)$$

$$Average Specificity = \frac{\sum_{i=1}^l \frac{TN_i}{TN_i + FN_i}}{l} \quad (12)$$

$$Average Sensitivity = \frac{\sum_{i=1}^l \frac{TP_i}{TP_i + FN_i}}{l} \quad (13)$$

$$Average F - Skor = \frac{\sum_{i=1}^l \frac{2TP_i}{2TP_i + FP_i + FN_i}}{l} \quad (14)$$

In this study, CNN and DenseNet models were trained and tested using PyCharm 2021. Python 3.6 was used to process the data set files used in the CNN model. The operating system of the computer used in the study is 64-bit Windows 10. Other hardware information includes NVIDIA GeForce® RTX™ 3060 6GB graphics, 11th Gen Intel® Core™ i7 2.3GHz (24M cache, up to 4.6GHz, 8 cores) processor, and 16GB memory.

In the first training and testing phase, which included a total of 25 steps, the training loss and validation loss values were 1.095 and 0.77, respectively, while the training accuracy and validation accuracy values were 64.65 and 78.33, respectively. After the first five steps, the values for training loss and validation loss were 0.38 and 0.41, respectively, while the values for training accuracy and validation accuracy were 88.12 and 87.77, respectively. As can be seen from the values, the data loss decreased and the accuracy increased.

After the first ten steps, the training loss and validation loss showed values of 0.27 and 0.32, while the training accuracy and validation accuracy showed 92.2 and 90 values. As seen from the values, the validation and accuracy rates increased in the first five steps to 90 after the first ten steps. After the first fifteen steps, the training loss and validation loss showed 0.28 and 0.28 values, while the training accuracy and validation accuracy showed 90.7 and 91.6 values. As you can see from the values, the validation accuracy, which increased in the first ten steps, continued to increase after the first fifteen steps and showed a value of 91.6.

After the first twenty steps, the training loss and validation loss showed values of 0.24 and 0.27, while the training accuracy and validation accuracy showed values of 91.6 and 91.1.

While the training loss and validation loss continued to decrease in the first twenty steps, the validation accuracy showed a slight decrease compared to the first fifteen steps. After twenty-five steps, the training loss and validation loss values were 0.23 and 0.26, while the training accuracy and validation accuracy values were 92.6 and 91.6, respectively.

4. Discussion and Conclusion

Weather is a meteorological event that occurs in a region at a particular time. Weather cannot be changed, but it can be predicted. Weather forecasting is the prediction of meteorological events that may occur in a region at a particular time, based on observations and analysis. Individuals benefit from weather forecasts to plan their activities in daily life. In this study, CNN and DenseNet models were used together to produce weather forecasts from sky images. In this study, high accuracy was achieved by using CNN models with DenseNet. However, the number of images in the dataset and the resolution quality of the images directly affect the performance of the developed model. The complexity matrix showing the real class and the class predicted by the classifier of the developed model is shown in Figure 9.




Figure 9. Confusion Matrix.

The training-validation accuracy graph and the training-validation loss graph of the developed model are shown in Figure 10.




Figure 10. Training vs. validation accuracy and Training vs. validation loss.

In the study, a different method than the known methods was used to make weather forecasts based on sky images taken from the ground. This method is based on categorizing the images in the computer environment according to their common characteristics and then predicting the class of the next image. 6 different weather conditions with different resolutions were taken from the ground. A total of 1800 images, including clouds, fog, rain, sunshine, snow, and sunrise, were used to train and test this method. In the study, the images were first resized and enriched with data. In the next step, the feature maps of the images were extracted and the classification process was performed. A hit rate of 91.66% was obtained in the classification process. Considering the success in classification, we have a promising opportunity with different methods for weather conditions that are both less costly and provide results in a shorter time.

5. References

- X. Liu, Z. Deng, Y. Yang (2019) Recent progress in semantic image segmentation, *Artif. Intell. Rev.* 52 1089–1106, <https://doi.org/10.1007/s10462-018-9641-3>.
- Gao J. (2009) *Digital analysis of remotely sensed imagery*, The Mc Graw-Hill Companies, USA.
- Campbell, J.B (1996) “*Introduction to Remote Sensing*”, Guilford Press, New York, 621 s.
- Wilkie, D. S.(1996) *Remote sensing imagery for natural resources monitoring: a guide for first-time users*. Columbia Univ. Press.
- Martin Roser, Frank Moosmann (2008) Classification of weather situations on single-color images.2008 IEEE Intelligent Vehicles Symposium. <https://doi.org/10.1109/IVS.2008.4621205>.
- Mohamed E, Sheng H, Ahmed E. (2015) Weather classification with deep convolutional neural networks. 2015 IEEE International Conference on Image Processing (ICIP). <https://doi.org/10.1109/ICIP.2015.7351424>.
- Jehong An, Yunfan Chen, Hyunchul Shin (2018) Weather Classification using Convolutional Neural Networks. 2018 International SoC Design Conference (ISOCC). <https://doi.org/10.1109/ISOCC.2018.8649921>.
- Li-Wei Kang, Ke-Lin Chou, Ru-Hong Fu (2018) Deep Learning-Based Weather Image Recognition. 2018 International Symposium on Computer, Consumer and Control (IS3C). <https://doi.org/10.1109/IS3C.2018.00103>.
- Jose Carlos Villarreal Guerra, Zeba Khanam, Shoaib Ehsan, Rustam Stolkin, Klaus McDonald-Maier (2018) Weather Classification: A new multi-class dataset, data augmentation approach and

- comprehensive evaluations of Convolutional Neural Networks. 2018 NASA/ESA Conference on Adaptive Hardware and Systems (AHS). <https://doi.org/10.1109/AHS.2018.8541482>.
- Data Set: <https://www.kaggle.com/vijaygiitk/multiclass-weather-dataset> Accessed: 15 Oct 2021.
- Bengio, Yoshua; LeCun, Yann; Hinton, Geoffrey (2015). Deep Learning. *Nature*. 521 (7553). ss. 436-444. Bibcode:2015Natur.521..436L. doi:10.1038/nature14539.
- Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, Chen T, et al. (2018) Recent advances in convolutional neural networks. *Pattern Recognition* ;77,:354-377.
- Min S, Lee B, Yoon S. (2017) Deep learning in bioinformatics. *Briefings in bioinformatics*;18(5):851-869.
- Milletari F. Navab N. Ahmadi SA. (2016) V-net: Fully convolutional neural networks for volumetric medical image segmentation. Fourth International Conference on 3D Vision, 3DV 2016. ABD: IEEE; p. 565- 571.
- Hanbay K. (2020) Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform. *Journal of the faculty of engineering and architecture of gazi university*.35(1):443-456.
- Niepert M. Ahmed M. Kutzkov K. (2016) Learning convolutional neural networks for graphs. In International conference on machine learning. Germany. p. 2014-2023.
- Kurt F. (2018) Evrivsimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi [master's thesis]. Ankara: Hacettepe University.
- Kumar R. (2020) Adding binary search connections to improve decent performance. 5th International Conference on Next Generation Computing Technologies. Dehradun: NGCT- 2019;2019. SSRN: <https://ssrn.com/abstract=3545071>.
- Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. (2017) Densely connected convolutional networks. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: I EEE;. p. 4700-4708.
- Li X, Shen X, Zhou Y, Wang X, Li TQ. (2020) Classification of breast cancer histopathological images using interleaved DenseNet with SENet (IDSNet). *PloS One*.;15(5):e0232127.
- G. Huang, Z. Liu, and L. van der Maaten (2018) "Densely Connected Convolutional Networks".
- Aksoy, B. , Halis, H. D. , Salman, O. K. M. (2020). Elma Bitkisindeki Hastalıkların Yapay Zekâ Yöntemleri ile Tespiti ve Yapay Zekâ Yöntemlerinin Performanslarının Karşılaştırılması . *International Journal of Engineering and Innovative Research* , 2 (3) , 194-210 . DOI: 10.47933/ijeir.772514.
- Ruuska S, Haˆmäläinen W, Kajava S, Mughal M, Matilainen P, Mononen J. (2018) Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behavior of cattle. *Behavioral Processes*.148:56-62.
- Peldek S, Becerikli Y. (2019) Recognition of human action in motion detected images with GMACA. *Journal of the Faculty of Engineering and Architecture of Gazi University*. 34(2):1025-1043.
- Sokolova M, Lapalme G. (2009) A systematic analysis of performance measures for classification tasks. *Information processing and management*. 45(4): 427- 437.
- Ballabio D, Grisoni F, Todeschini R. (2018) Multivariate comparison of classification performance measures. *Chemometrics and Intelligent Laboratory Systems*. 2018;174:33-44.

GERİ DÖNÜŞTÜRÜLEBİLİR ATIKLARIN SINIFLANDIRILMASI CLASSIFICATION OF RECYCLABLE WASTE

Seda Varol^{*1} , Cengiz Hark² , Soner Kızıloluk³ 

¹Enformatik Bölümü, Turgut Özal Üniversitesi, Malatya, Türkiye

²Bilgisayar Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

³Bilgisayar Mühendisliği Bölümü, Turgut Özal Üniversitesi, Malatya, Türkiye

(varoll.seda@gmail.com, cengiz.hark@inonu.edu.tr, soner.kiziloluk@ozal.edu.tr)

Özetçe— Doğada sınırlı sayıda bulunan materyallerin yeniden kullanılabilmesi için ortaya çıkan “geri dönüşüm” kavramı her geçen gün daha önemli hale gelmektedir. Sürekli artan atıklar ve beraberinde oluşan kirlilik sorunu; kişileri, aileleri ve toplumları olumsuz şekilde etkilemektedir. Bu olumsuz etkiyi azaltmak için insanlar geri dönüşüm konusunda özendirilmeye çalışılmaktadır. Çalışma kapsamında, geri dönüşüm uygulamalarında kullanılmak üzere cam ve kâğıt atıklarının görüntü işleme teknikleri ile ayrıştırılması hedeflenmiştir. Atık görüntülerinin sınıflandırılması için açık erişimli Garbage Classification adlı veri seti çalışmaya uygun olarak düzenlenerek kullanılmıştır. Deneyisel süreçlerde nitelik çıkarımı için derin öğrenme modellerinden Evrişimsel Sinir Ağları (ESA) mimarilerinden DarkNet-19 modeli kullanılmıştır. Başarım çeşitli performans metrikleri ile ölçülmüştür ve %96 lara varan doğruluk değerleri elde edilmiştir.

Anahtar Kelimeler : Geri Dönüşüm, Görüntü İşleme, Evrişimsel Sinir Ağları.

Abstract— The concept of "recycling", which emerged to reinforce the limited amount of materials in nature, has been one of the most important issues in recent years. The issue of rapid waste formation has impacts on individuals, families and societies. To reduce this impact, people are trying to be encouraged to recycle. In this study, the images of glass and paper waste are identified and classified for use in recycling projects, separated and classified by image processing technology. For the classification of waste images, the dataset that is accessible on the internet is used in order to be organized according to the study. In the obtained dataset, convolutional neural network (CNN), one of the deep learning models, was used for feature extraction. The CNN architectures DarNet19 are used in this study. Performance measured with a variety of performance metrics and accuracy of up to 96%.

Keywords : Recycling, Image Processing, Convolutional Neural Network.

1.Giriş

Dünyada uzun yıllardır devam etmekte olan nüfus artışı, kentleşme ve sanayileşmenin tesiriyle beraber yüksek oranda kaynak kullanılmakta ve bunun neticesinde de yoğun miktarda atık oluşmaktadır. Gün geçtikçe fazlalaşan atıklar, insanları ve doğayı fazlasıyla negatif biçimde etkilemektedir (A. A. Gündüzalp & Güven, 2016). Bütün atıkların çöp arazilerine tekrar kullanılmamak üzere bırakılması, plastik çöpler gibi tabiatta sonsuza dek varlığını devam ettirebilen atıkların var olması, tabiattaki canlılar için fazlasıyla tehlikeli durumlar ortaya koymaktadır.(Rosevelt, 2011), (Yüce.2016)

Atık, ülkemiz yazılı hukukunda ilk kez 1983 tarihli ve 2872 sayılı Çevre Kanunu’nda “Herhangi bir faaliyet sonucunda çevreye atılan veya bırakılan zararlı maddeler” olarak ifade edilmiştir (Kanun, 1983.). Çevre ve toplum problemi olan katı çöpler; atık döngüsü içinde, üretildikleri andan, son uzaklaştırma adımına kadar çevre ve toplumla doğrudan ya da dolaylı etkileşim içindedir. Katı çöpler, gerek muhtevalarındaki hastalığa sebep olan veya hastalığın yayılmasına neden olan maddelerle

doğrudan; aynı zamanda fare, sinek vb. diğer canlılar için beslenme ve üreme kaynağı olması sebebiyle dolaylı olarak çevre ve toplum sağlığına zararlı hale gelebilmektedir(Ç.Güler & Z.Çobanoğlu., 1996). Bunun yanında, bu çalışma genelinde üstünde durulan cam ve kâğıt gibi atık maddelerinin elde edilmesi aşamasında küresel ısınma artış göstermekte, enerji kaynakları azalmakta, ormanlar yüksek bir hızla yok olmakta ve atmosfer kirlenmektedir. İlaveten bu kaynakların yeniden elde edilmesi ve üretiminden dolayı memleketlerin ekonomisinde azalmalar meydana gelmektedir (Pekküçükşen et al., 2018).

Bugün ekonomisini ve tabiatı güvende tutmak isteyen birçok ülke geri dönüşüm konusuyla ilgilenmekte, devlet kurumları ve mahalli yönetimler iş birliği içerisinde bu konuyla alakalı projeler geliştirmektedir(A. A. Gündüzalp & Güven, 2016),(Kaçtioğlu et al., 2010). İlerlemiş toplumlarda insanlar da geri dönüştürülebilir atıkların bir araya getirilmesi konusunda bilgi sahibi olmalarını sağlamakta ve insanları bu konuda özendirilmektedir. Geri dönüştürülebilir atıklar için yaşam alanlarının hedeflenen konumlarına geri dönüşüm kutuları bırakılmakta ve bu yerlerden geri dönüştürülebilir atıklar toplanmaktadır. Bu konuda yapılan çalışmalar teorik ve pratik bazlı çalışmalardır. Teknolojik gelişmelerden yararlanılarak bazı yazılım kaynaklı çözümlerde sunulmaya çalışılmıştır(Sağlam et al., 2020). Bu konuda yardım alınabilecek kaynaklardan biride her geçen gün gelişmekte olan ve ilginin yoğunlaştığı görüntü işleme kavramıdır.

Görüntü işleme, insan gözünün gerçekleştirdiği fonksiyonları bilgisayar ortamında çeşitli ara yüz yazılımlarıyla daha çabuk çıktılar sağlanan bir teknolojidir (Parabhu,2016). Bu teknolojiye bazı farklı modeller geliştirilmiştir. Geliştirilen bu modeller ile yapılan bilimsel araştırmalar da fayda sağlamıştır (Zhang et al., 2017.). Son zamanlarda, yapılmış olan bu inceleme sonuçlarında en çok rağbet gören model, derin öğrenme modelidir ve bu model makine öğrenmesinin bir aşamasıdır. Makine öğrenmesi tekniğine oranla çok katmanlı bir yapıda olan derin öğrenme, insan beyninin çalışma şekline ilham alınarak, son zamanlarda epeyce artan bir alaka görmektedir (Koitka et al., 2016).

Bu çalışmada, insanların geri dönüştürülebilir atıkları bir arada çöplere atıp, bunların doğada birikip zararlı hale gelmesinin önüne geçmek amacıyla çöplerini belli sınıflar halinde ayırmaları amaçlanmıştır. Bu kapsamda gerekli yazılım aşamaları gerçekleştirilmiş ve nesnelerin ne olduğunun bulunması için eğitilmiştir. Cam ve kâğıt gibi atık maddelerin bulunduğu görseller elde edilerek eğitim, geçerleme ve test adımlarında kullanılmıştır.

2. İlişkili Çalışmalar

Günümüz teknolojisinin gelişmesi ile geri dönüşüm üzerine çok sayıda çalışma yapılırken çeşitli yöntemler kullanılmaktadır.

Gündüzalp ve Güven'in (A. A. Gündüzalp & Güven, 2016.), yaptıkları araştırmada atıkların sınıflandırması için çeşitli yaklaşımlar mevcuttur. Katı çöpler, meydana geldikleri yere göre ayrıldıklarında yedi alt başlığa ayrılmaktadır. Bunlar; evsel katı çöpler, endüstriyel çöpler, tehlikeli atıklar, tarımsal ve bahçe atıkları, medikal atıklar, özel atıklar, inşaat artığı ve moloz atıkları olarak belirtilmektedir.


Sağlam ve ark.(Sağlam et al., 2020) bilgi girdisi ve çıktısı temin edebilecek çeşitli donanım elemanları (kamera, LCD ekran ve hoparlör) kullanarak ve Raspberry Pi bilgisayarı üzerinde çalışan bir düzenek hazırlamışlardır ve bu düzeneği çöp kutuları üstünde eş zamanlı olarak çalışabilecek duruma getirilmiştir. Hazırlanan donanımın gerekli fonksiyonları yerine getirmesi için gömülü yazılım tasarlanmıştır ve malzemelerin ne olduğunun anlaşılabilmesi için eğitilmiş. Cam, plastik ve kâğıttan üretilmiş olan nesnelerin bulunduğu görseller elde edilerek eğitim ve test adımlarında kullanılmıştır. Üzerinde çalışılan düzeneğe, kutular içerisine yerleştirilen donanım elemanları (Raspberry Pi 3 mini bilgisayar, kamera, LED, IR alıcı-verici kızılötesi LED ve devre tahtası) ile dış tarafa koyulan LCD ekran bağlantıları yapılarak, dışardan kutuya koyulan çöpün malzemesine göre kullanıcıya bilgiyi aktaran bir donanım tasarlanmıştır. Ekranda yazan ilgili materyale göre kullanıcının hesabına bakiye transferi yapıldığı gösterilmektedir. Tasarlanan donanımda gerçek kullanıcı hesabı kullanmamıştır; bu uygulama gerçek hayattaki kullanım için bir simülasyon özelliği taşımaktadır.

Bu makalenin kalan kısımları şu şekilde organize edilmiştir; Bölüm 3'te yapılan çalışmanın deneysel süreci anlatıldı. Kullanılan yazılım elemanları hakkında bilgi verildi. Bölüm 4'te tartışma ve sonuç verilerek makale sonuçlandırılmıştır.

3. Materyal ve Metotlar

3.1. Derin Öğrenme ve Evrişimsel Sinir Ağları

Günümüzde popüler konulardan biri olan ve makine öğrenmesi konusunun bir alt dalı olan derin öğrenme, yapay sinir ağları algoritmalarını kullanarak çok katmanlı mimarilerde çok boyutlu veriler ile çalışma olanağı oluşturur. Derin öğrenme yöntemleri aracılığıyla görsel nesne tespiti, doğal dil işleme, ilaç keşfi, görüntü işleme vb. konularda önemli bir oranda başarımlar elde edilmiştir (LeCun et al., 2015). Esnek hesaplama yöntemlerinin en son geldiği raddelerden birisi de derin öğrenmedir. Yapay sinir ağları (YSA), ilk esnek hesaplama modellerinden biridir ve YSA'lar zaman içinde geliştirilerek Evrişimsel Sinir Ağı (ESA) modellerini ortaya çıkarmışlardır. Geliştirilen ESA'lar da derin öğrenme mimarisinin esasını oluşturmaktadır. Başlangıçtaki YSA'larda geliştiriciler sırasıyla, öznetelik elde etme ve en iyi öznetelikleri seçme işlemlerini hayata geçirdiler (LeCun et al., 1989). Daha sonraki geliştirilen ESA'larda ise, geliştiriciler bu kez ellerindeki verilerden öznetelik çıkarma işlemini, ESA modelinin içerisinde bulunan filtreler aracılığıyla yapmaktadır. Aynı zamanda, bu filtreler aracılığıyla elde edilen veriler ESA modelinde doğrudan kullanılmaktadır. ESA modeli sayesinde elde edilen bu veriler ihtiyaç halinde çeşitli sınıflandırma algoritmalarında da kullanabilmektedir. Derin öğrenme algoritmalarında ise, geliştirilen ESA modellerinde olduğu gibi filtreler aracılığıyla kendiliğinden tüm öznetelik çıkarma işlemleri yapılmaktadır (Lippmann, 1989).



Şekil 1. Derin Öğrenme Mimarisi.

Çalışmada ESA modellerinden biri olan DarkNet-19 modeli tercih edilerek öznetelik çıkarımı elde edildi. DarkNet19 mimarisi, “Sadece Bir Kez Bak -v2 (YOLOv2)’nin (Redmon, Farhadi, 2017) temeli olarak kullanabilmek için yeni bir sınıflandırma modeli olarak teklif edilmiştir. Görsel Geometri Grubu (VGG) modeline eş değer şekilde 3x3 evrişim filtresi kullanılmaktadır ve modelde her en büyük değer ortaklaması katmanından sonra belirlenen filtre sayısı ikiye katlanmaktadır. Modelde ortalama ortaklama katmanı sınıflandırma katmanında önce kullanılmaktadır ve özellik temsili ortaya çıkarılmak için de ortalama ortaklama ile 3x3 boyutlu evrişim katmanı arasında 1x1 boyutlu evrişim filtresi kullanılmıştır (Lin et al., 2014). DarkNet19 mimarisi, 19 adet evrişim katmanı ve 5 adet en büyük ortalama katmanı içermektedir.

3.2. Veri Seti

Deneyisel çalışmalar Garbage Classification veri seti kullanılarak gerçekleştirilmiştir (Kaggle, 2018). Veri seti Kaggle platformu üzerinde açık erişime sahiptir. Google LLC'nin bir yan kuruluşu olan Kaggle, makine öğrenmesi, veri analizi, yapay zekâ, istatistik, veri görselleştirme, matematik gibi bilimlere bir araya getiren bir yapılaşmadır (Dağ, 2020). Edinilen veri seti çalışmaya uygun şekilde ön-işleme tabi tutulmuş ve Garbage Classification veri seti ile modellenen yapay sinir ağı eğitilmiştir. Giriş görüntüsü olarak veri setinde bulunan giriş görüntü verileri kullanıma hazır hale getirilmiştir. Deneyisel çalışma veri setinde bulunan iki sınıf ile sınırlı tutularak ikili sınıflandırma işlemi gerçekleştirilmiştir.

Tablo 1. Cam ve Kâğıt veri setine ait istatistiki bilgiler

Veri Kümeleri	Cam	Kâğıt	Toplam
Eğitim	375	375	750
Doğrulama	26	26	52
Test	100	100	200

Tablo 1’de görüldüğü gibi veri seti, cam ve kâğıt olmak üzere iki sınıfa ayrılmıştır. 501 cam ve 501 kâğıt olmak üzere toplamda 1002 veri üzerinde işlem yapılmaktadır. Resimlerin dosya uzantısı JPEG, derinliği 24 bit ve çözünürlüğü 512×384’ tür. DarkNet-19 CNN modeli kullanılarak öznitelik çıkarımı elde edilmiştir. Kullanılan veri setine ait bazı görseller Şekil 2’de gösterilmiştir.

**Şekil 2.** Eğitim için kullanılacak bazı veri örnekleri

3.2. Performans Metrikleri

Hazırlanan 750 verinin 550 tanesi eğitim, 52 tanesi geçerleme ve 200 tanesi ise test verisi olarak kullanılmıştır. Kullanılan veriler için model eğitildi. Bu çalışmanın geçerli olma durumunun hesaplanabilmesi; duyarlılık, özgüllük ve doğruluk ile alakalı olarak doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP), yanlış negatif (YN) anlamına gelmektedir (Çakarcı,2018).

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (1)$$

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (2)$$


$$\text{Doğruluk} = \frac{DP + DN}{DP + YN + YP + DN} \quad (3)$$

4. Bulgular

Modelin eğitimi için görüntüsü alınan nesnelerin belirlenen standartlara göre MATLAB programı ile sınıflandırılması yapılmıştır. Verileri eğitmek için bir ESA modeli olan DarkNet-19 kullanılmıştır. Modelin eğitim sonuçları Tablo 2.’de verilmiştir.


Model eğitilirken verilerin tamamı eğitimde kullanılmamıştır. Belli sayıda parçalar halinde eğitimde yer almışlardır. İlk parça eğitilmiştir, modelin başarımı test edilmiştir, başarıma göre geriye yayılım (“backpropagation”) ile ağırlıklar güncellenmiştir. Sonrasında yeni eğitim kümesi ile model yeniden eğitilip ağırlıklar bir daha güncellenmiştir. Yöntem her bir eğitim adımında yinelenerek model için en uygun ağırlık değerleri ölçülmeye çalışılmıştır. Bu eğitim adımlarının her birine “epoch” denilmektedir

(Kızrak,2018). Bu çalışmada eğitim adımı sayısı 5 olarak belirlenmiştir ve her bir eğitim adımında 10 defa 25 görüntü alınması amaçlanmıştır. Model için sırasıyla en yüksek devirme değeri (the max epoch value), mini toplu boyut değeri (the mini-batch size value) ve ilk öğrenme hızı değeri sırası ile (the initial learning rate value) 5, 25 ve 0.0005 olarak seçilmiştir. Bu şekilde modelin eğitimi tamamlanmıştır.




Şekil 3. Modelin Eğitim ve test kümeleri için doğruluk ve kayıp grafikleri

Bu çalışmada, görüntü kümesinin %20' si test, %80'i eğitim kümesi şeklinde ayarlanmıştır. Eğitim sonuçları kayıt edilmiştir. Bu eğitimler ile modeller için Şekil 4'teki Karışıklık matrisi hesaplanmıştır ve Şekil.5'teki alıcı işlem karakteristikleri çizdirilmiştir.



Şekil 4. Modelin test aşamasına ait karışıklık matrisi.

Karışıklık matrisi, bir modelin performansını her sınıftaki doğruluk oranlarına bakarak açıklamak için kullanılan bir tablodur. Karışıklık matrisindeki satırlar tahmini sınıfı (Output Class) ve sütunlar gerçek sınıfı (Target Class) gösterir.



Şekil 5. Elde edilen alıcı işlem karakteristikleri.

Cam ve kâğıt veri setlerinden elde edilen alıcı işlem karakteristikleri Şekil 5'te gösterilmiştir. Alıcı işlem karakteristikleri, yanlış pozitif oran (FPR) ile gerçek pozitif oran (TPR) arasındaki ilişkiyi gösterir.

Tablo 2. Performans sonuçları.

Sınıf	Hassasiyet (%)	Duyarlılık (%)	f-puanı (%)
Cam	0.98	0.96	0.97
Kâğıt	0.96	0.97	0.96
Ort.	97	97	96

4. Tartışma ve Sonuç

Atık konusu iktisadi ve çevresel açıdan ele alınmaktadır. Yaşamımızda ürünlerin tüketilmesiyle oluşan katı çöpler, ambalaj çöpleri, tehlikeli atıklar, medikal çöpler, özel atıklar gibi birçok atık çeşidi ve bu atıkların taşınması, bir araya getirilmesi, imha edilmesi ve yönetimi fazlasıyla önemlidir. Özellikle katı çöplerin yönetimi üzerinde durmak gerekmektedir. Çünkü içerisinde birçok çeşidi bulunduran bu atık çeşidi; insanı, doğayı, sağlığı, çevreyi ve ekonomiyi büyük ölçüde etkilemektedir. Bu etkileri en aza indirmek için bir takım farklı çalışmalar yapılmaktadır. Bu alandaki çalışmalar derin öğrenme üzerinde yoğunlaşmaktadır.

Son zamanlarda çeşitli birçok konuda derin öğrenme modeliyle ilgili çok farklı çalışmalar gerçekleştirilmiştir. Derin öğrenmenin ilgi çekici sonuçlar verdiği yapılan çalışmaların inceleme sonuçlarından anlaşılmıştır. Bu çalışmada da erişime açık görüntü kümelerini kullanarak, atıkların ayrıştırılması için katkıda bulunuldu. Gerçekleştirilen deneysel çalışmalar sonunda %96 sınıflandırma başarımları rapor edilmiştir. Bu değerler belirlenen eğitim adımına göre alınan sonuçlardır. Bu sonuçlara göre eğitim işlemi başarılı bir şekilde tamamlandığı söylenebilir.

Kaynakça

- Çakarcı, N. (2018, January 22). *Derin öğrenme uygulamalarında en sık kullanılan hiper-parametreler*, Medium, <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4>
- Dağ, B., (2020, May 23), *Veri bilimi için Kaggle*, Data Science Earth, <https://www.datascienceearth.com/veri-bilimi-icin-kaggle/>
- Güler, Ç., & Çobanoğlu, Z.. (1996). *Sağlık Açısından Çöp, Tıbbi Dokümantasyon Merkezi Toplum Sağlığı Dizisi* (14).
- Gündüzalp, A. A., & Güven, S. (2016). *Atık, Çeşitleri, Atık Yönetimi, Geri Dönüşüm ve Tüketici: Çankaya Belediyesi ve Semt Tüketicileri Örneği*.
- Kaçtıoğlu, S., Bilimler, Ü. Ş.-A. Ü. İ. ve İ., & 2010, undefined. (n.d.). Erzurum kenti ambalaj atıklarının geri dönüşümü için tersine lojistik ağı tasarımı ve bir karma tamsayılı programlama modeli. *Dergipark.Org.Tr*. Retrieved June 30, 2022, from <https://dergipark.org.tr/en/pub/atauniiibd/issue/2698/35571>
- Kanun. (1983). *ÇEVRE KANUNU*.
- Kızrak, A. (2018, May 28) *Derine daha derine: Evrişimli sinir ağları*, Medium, <https://ayyucekizrak.medium.com/deri%CC%87ne-daha-deri%CC%87ne-evri%CC%87Fimli-sinir-a%C4%9Flar%C4%B1-2813a2c8b2a9>
- Koitka, S., Notes), C. F.-C. (Working, & 2016, undefined. (n.d.). Traditional feature engineering and deep learning approaches at medical classification task of imageclef 2016. *Citeseer*. Retrieved June 30, 2022, from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.1071.8596&rep=rep1&type=pdf>
- LeCun, Y., Bengio, Y., nature, G. H.-, & 2015, undefined. (2015). Deep learning. *Nature.Com*. <https://doi.org/10.1038/nature14539>
- LeCun, Y., Boser, B., Denker, J., ... D. H.-N., & 1989, undefined. (n.d.). Backpropagation applied to handwritten zip code recognition. *Ieeexplore.Ieee.Org*. Retrieved June 30, 2022, from <https://ieeexplore.ieee.org/abstract/document/6795724/>
- Lin, M., Chen, Q., & Yan, S. (2014). Network in network. *2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings*.
- Özbay, Ş., (2010), *Fen ve teknoloji programı içinde kompost hakkında verilen etkinliklerin öğrencilerin akademik başarılarına ve çevreye tutumlarına etkisi*, Çanakkale Onsekiz Mart Üniversitesi.
- Parabhu, P., (2016) "Digital image processing techniques – A survey," vol. 5, no. 11, pp.1-5
- Pekküçükşen, Ş., Solak, S., & Oktay, E. (2018). *Karamanoğlu Mehmetbey Üniversitesi öğrencilerinin Karaman kent algısı*. <https://www.acarindex.com/pdf/acarindex-53a6764f-69dd.pdf>
- Redmon, J., Farhadi, A., & - of the IEEE conference on computer. (2017.). YOLO9000: better, faster, stronger. *Openaccess.Thecvf. Com*. Retrieved June 30, 2022, from http://openaccess.thecvf.com/content_cvpr_2017/html/Redmon_YOLO9000_Better_Faster_CVPR_2017_paper.html
- Rosevelt, C. (2011). *Digital Commons @ CSUMB Digital Commons @ CSUMB Abundance of Beach Litter in Monterey Bay, CA Abundance of Beach Litter in Monterey Bay, CA*.
- RP Lippmann - Neural, & 1989. (n.d.). Review of neural networks for speech recognition. *Ieeexplore.Ieee.Org*. Retrieved June 30, 2022, from <https://ieeexplore.ieee.org/abstract/document/6796621/>
- Sağlam A, Taş, M., Baykan, N. A., Üniversitesi, K. T., Ve Doğa, M., Fakültesi, B., Bölümü, M., & Konya, T. (2020). Geri Dönüştürülebilir Atıkların Materyallerine Göre Sınıflandırılması için Raspberry Pi Tabanlı Donanım Geliştirilmesi. *Dergipark.Org.Tr*, 30–38. <https://doi.org/10.31590/ejosat>
- Yüce, A. E. (n.d.). *Ultrafine grinding of industrial materials View project PET ve PVC artıklarının ayrılmasında kolon flotasyonu kullanılarak optimum ayırma parametreleri incelenmesi View project*. <https://doi.org/10.21605/cukurovaummfd.242825>
- Zhang, J., Xia, Y., Xie, Y., ... M. F.-I. journal of, & 2017, undefined. (n.d.). Classification of medical images in the biomedical literature by jointly using deep and handcrafted visual features. *Ieeexplore.Ieee.Org*. Retrieved June 30, 2022, from <https://ieeexplore.ieee.org/abstract/document/8115141/>

Beyin MR Görüntüleri Üzerinde Tümör Tespitinde VGG-19 Model Tabanlı Yeni Bir Yaklaşım

Abdullah ŞENER^{*1} , Burhan ERGEN² 

¹Bilgisayar Teknolojileri Bölümü, Genç Meslek Yüksekokulu, Bingöl Üniversitesi, Bingöl, Türkiye

²Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

(asener@bingol.edu.tr, bergen@firat.edu.tr)

Öz— Beyin kanseri; beyinde bulunan anormal hücrelerin kontrolsüz bir şekilde büyümesi sonucunda ortaya çıkan bir hastalıktır. Teknolojinin gelişmesi beyin kanseri tespitinin kolaylaşmasına ve yüksek doğruluk oranında sonuçlar vermesine imkân sağlamaktadır. Bilgisayar ortamında MRI görüntülerinin yüksek doğruluk oranında sınıflandırmasını yapan sistemlerin gelişmesi ve otonom hale gelmesi hatalı kanser teşhislerinin önüne geçmesinde önemli etkileri olacağı aşikârdır. Yapılan çalışmada beyin kanseri teşhisinin yüksek doğruluk oranında tespitini gerçekleştirebilmek için evrişimli sinir ağı modellerinden VGG-19 mimarisini temel alınarak bir model geliştirilmiştir. Yapılan çalışmada beyin kanserine neden olan glioma, meningioma ve hipofiz görüntülerine ilave olarak beyin tümörüne rastlanmayan görüntüleri de içeren açık kaynaklı bir veriseti kullanılmıştır. Geliştirilen modelin başarısını ölçmek için kullanılan veriseti üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma sonucunda geliştirilen model % 95 doğruluk oranı elde etmiştir. Yapılan çalışmanın metrik değerleri göz önüne alındığında; beyin tümörü tespitinde tıbbi kararları desteklemek için klinik ortamlarda önerilen yaklaşımın kullanılabilirliğini göstermektedir.

Keywords : *Görüntü Sınıflandırma, VGG-19, Derin Öğrenme, Makine Öğrenmesi.*

1. Giriş

Vücudun herhangi bir bölgesinde bulunan hücreler üzerinde meydana gelen genetik bozulmalar sonucunda hücrelerin kontrolsüz ve sınırsız bir şekilde büyümesine kanser denir. Kontrolsüz ve sınırsız şekilde çoğalan hücreler, öncelikle tümör adı verilen kitleler oluşturur ve zamanla çevre dokulara, hatta uzak vücut dokularına yayılım göstermeye başlar. Gerçekleşen hücre bozulmalarının beyinde meydana gelmesi ile beyin kanseri oluşmaktadır. Beyin kanseri, hem erkeklerde hem de kadınlarda önde gelen ölüm nedenleri listesinde onuncu sırada yer alıyor. Biyopsi, kanser teşhisinde en çok kullanılan yöntemlerden biridir. Ancak biyopsi süreci oldukça tehlikelidir ve karara varmak uzun zaman alır (Gupta ve ark., 2022). Bu tür vakaların klinik muayenesinde kullanılan diğer bir tanı yöntemi hastanın manyetik rezonans görüntüleme (MRI) alarak uzman doktor ve radyologlar tarafından incelenmesidir. Beyin tümörleri genel olarak iyi huylu ve kötü huylu olmak üzere iki sınıfa ayrılır. MRI ile tümör tespiti yapılabilmekte ve bu tümörlerin iyi huylu/kötü huylu olduğu belirlenebilmektedir. Bu nedenle beyin tümörü tedavisinde izlenecek prosedür, doktorun deneyim ve bilgisine bağlıdır. Derin öğrenmenin amacı, MRI'den elde edilen sonuçları doktorlara kusursuz ve otomatik bir şekilde sunmak ve teşhis sürecini desteklemektir. Son yıllarda kanserleri tespit etmek ve sınıflandırmak için Makine Öğrenimi ve Derin Öğrenmeye (DL) dayalı teknikler son yıllarda dikkate değer bir başarı kazanmıştır (Gupta ve ark., 2022).

MRI görüntülerinin sınıflandırılması ile beyin tümörü tespiti gerçekleştiren literatürdeki çalışmalara bakıldığında; Toğaçar ve ark. yaptıkları çalışmada geliştirdikleri yeni evrişimli sinir ağı modeli ile Beyin tümörü tespiti işlemi gerçekleştirmişlerdir (Toğaçar ve ark., 2020). Dong ve ark. U-Net tabanlı tam evrişimsel ağları kullanarak otomatik beyin tümörü tespiti ve segmentasyonu konusu üzerine çalışmışlardır (Dong ve ark., 2017). Amin ve ark. MRI görüntülerini kullanarak beyin tümörü tespiti ve sınıflandırmasında ayırt edici bir yaklaşım sunmuşlardır (Amin ve ark., 2020). Arif ve ark. yaptıkları çalışmada biyolojiden esinlenmiş ortogonal dalgacık dönüşümü ve derin öğrenme teknikleri kullanılarak MRI ile beyin tümörü tespiti ve sınıflandırılması işlemini gerçekleştirmişlerdir (Arif ve ark., 2022). Amin ve ark. Ensemble transfer learning ve kuantum değişken sınıflandırıcı kullanarak beyin tümörü

tespiti için yeni bir model önermişlerdir (Amin ve ark., 2022). Qureshi ve ark. çok sınıflı beyin tümörü tespiti için akıllı ultra hafif derin öğrenme modeli üzerine çalışmışlardır (Qureshi ve ark., 2022). Anaya-Isaza ve ark. MRI görüntüleme beyin tümörü tespiti için veri büyütme ve transfer öğrenimi konusu üzerine çalışmışlardır (Anaya-Isaza ve ark., 2022). Sharma ve ark. beyin tümörü tespiti için gelişmiş Watershed segmentation algoritmasına dayalı modifiye ResNet50 modeli geliştirmişlerdir (Sharma ve ark., 2022). Kumar ve ark. yaptıkları çalışmada optimum özellik seçimi ve optimize edilmiş derin inanç ağı kullanılarak beyin tümörü tespiti için bir yaklaşım sunmaktadırlar (Kumar ve ark., 2022). Dehkordi ve ark. yaptıkları çalışmada yeni evrimsel evrişimsel sinir ağı kullanılarak beyin tümörü tespiti ve sınıflandırılması işlemlerini gerçekleştirmişlerdir (Dehkordi ve ark., 2022).


Yapılan çalışmada; içerisinde 4 sınıfa ait MRI görüntüleri bulunan açık kaynaklı bir veri seti kullanılmıştır. Veri setindeki görüntüler aracılığıyla beyin tümörü tespiti ve türünün belirlenmesi için VGG-19 mimarisi temel alınarak yeni bir model önerilmiştir. Önerilen modelde %95 doğruluk oranı elde edilmiştir. Elde edilen sonuçlar doktorların teşhis sürecini desteklemekte ve yardımcı olmaktadır.

2. Materyal ve Metod

Bu bölümde sınıflandırma işlemini gerçekleştirilen veri seti ve sınıflandırma işleminde kullanılan modeller hakkında bilgiler içermektedir.

2.1. Veri Seti:

Yapılan çalışmada kullanılacak sınıflandırma modellerinin performanslarını değerlendirmek için içerisinde 4 sınıfa ait MRI görüntüleri içeren açık kaynaklı bir veri seti kullanılmıştır (Veri Seti, 2022). Veri setini hipofiz, meningiom, glioma ve sağlıklı beyin MRI görüntüleri oluşturmaktadır. Veri setini oluşturan görüntülerin bazıları Şekil 1’de gösterilmektedir.



Şekil 1. Çalışmada kullanılan veri setinden örnek görüntüler (Veri Seti, 2022).


Veri setinde 1796 Glioma, 1784 Meningiom, 2162 Sağlıklı ve 1936 Hipofiz MRI görüntüleri olmak üzere toplamda 7678 farklı çözünürlüklere sahip görüntülerden oluşmaktadır. Görüntüler gri tonlamalıdır. Veri setindeki görüntülerin %74’ü eğitim, %17’si test ve %9’u ise doğrulama işlemleri için kullanılmıştır. Glioma tümörü; kötü huyludur ve beyinde veya omurilikte Glioma hücrelerinin anormal büyümesinden oluşur. Hipofiz tümörü; hipofiz bezinde bulunur. Tümör iyi huyludur ve hipofiz bezi hücrelerinin anormal büyümesinden kaynaklanır. Meningiom tümörü; çoğu iyi huyludur ve beyni ve omuriliği kaplayan zarlarda oluşur.

2.2. Derin Öğrenme:

Derin öğrenme, birden fazla katmandan oluşmuş üzerinde çalıştığı veri setine uygun tahminler yapabilen veya sonuçlar üretebilen bir makine öğrenme yöntemleridir. Derin öğrenmedeki amaç, temelinde içerdiği yapay sinir ağını kullanarak üzerinde çalıştığı verilerden yeni veriler türetmektir. Derin öğrenme yöntemleri arasında popülerliği en yüksek olan yöntem Evrişimli Sinir Ağları (CNN) mimarisidir (Gu ve ark., 2018). CNN mimarisi insan beyninin görsel korteksinin çalışma prensibine benzer şekilde ortak özelliklere sahip görüntüleri tanımakta ve bir araya getirerek görüntüler üzerinde sınıflandırma işlemlerini gerçekleştirir (Min ve ark, 2017). CNN mimarisi evrişim katmanı, doğrusal olmayan katman, havuzlama katmanı, düzleştirme katmanı ve tamamen bağlı katmanlarının birleşiminden oluşmaktadır (Hanbay, 2020). CNN mimarisinin yapısına ve katmanların özelliklerine bakılacak olursa; en yoğun matematiksel işlemlerin gerçekleştiği katman evrişim katmanıdır. Evrişim katmanı CNN mimarisinin temelini oluşturmaktadır. Bu katmanda görüntülere bazı filtreler uygulanarak düşük ve yüksek seviyeli özellik saptama işlemi gerçekleştirilir. Doğrusal olmayan katmanda sistemde doğrusal olmayan durumların belirlenmesi gerçekleştirilmektedir. Havuzlama katmanında ise özellik haritalarının boyutu küçültülüp sistem üzerindeki ağırlık sayısı azaltılarak ağ içerisindeki parametrelerin sayısının azaltılması işlemi gerçekleştirilmektedir. Bu işlemleri maximum havuzlama (görüntü $n \times n$ matrislere bölünerek bu matrisler içindeki en yüksek değer alınarak) veya ortalama havuzlama (görüntü $n \times n$ matrislere bölünerek bu matrisler içindeki değerlerin ortalaması alınarak) işlemi ile gerçekleştirilmektedir. Düzleştirme Katmanının görevi CNN mimarisinin son katmanı olan tam bağlı katmanın girişi için verileri hazırlamaktır. Genellikle bu katman kendisine gelen verileri tek boyutlu bir matrise dönüştürerek bu işlemi gerçekleştirir. Tam bağlı katman giriş katmanı ve çıkış katmanı arasında ilişki kurma işlemini gerçekleştirilmektedir (Niepert ve ark., 2016; Kurt, 2017).

2.3. VGG-19:

VGG-19, 24 katman derinliğine sahip evrişimsel bir sinir ağıdır. Bu katmanları 16 evrişimsel, 5 havuzlama ve 3 tam bağlantılı katmandan oluşmaktadır (Toğaçar ve ark., 2020). ImageNet veritabanında bulunan bir milyondan fazla görüntü üzerinde önceden eğitilmiştir. VGG-19 ağı, 224×224 piksel boyutlarında bir görüntü girişine sahiptir. VGG-19 mimarisi incelendiğinde yaklaşık olarak 138 milyon parametreden oluştuğu görülmektedir (Mateen ve ark., 2018). VGG-19, parametre sayısını azaltmak için evrişimsel katmanda 3×3 piksel boyutunda filtreler kullanmaktadır. Şekil 2 'de VGG-19 mimarisi gösterilmektedir.




Şekil 2. VGG-19 mimarisi (Mostafiz ve ark., 2020).

2.4. Önerilen Yaklaşım

Yapılan çalışmada VGG-19 mimarisi temel alınarak yeni bir model önerilmiştir. Modelin performansını değerlendirmek için veri setindeki görüntüler kullanılmıştır. Veri setindeki görüntülerin %74'ü eğitim, %17'si test ve %9'u doğrulama işlemleri için kullanılmıştır. Çalışmanın ilk aşamasında farklı çözünürlük ve boyutlara sahip görüntülerin çözünürlükleri, modelin giriş boyutu olan 224×224 piksel çözünürlüğe ayarlanmıştır. Bu işlemin yapılma amacı sınıflandırma işlemini hızlandırmak ve bilgisayar hafızasında fazla yer tüketmesini önlemektir. Yeniden boyutlandırma işleminde görüntüler önceden belirlenmiş sabit bir boyuta getirilir. Görüntü boyutları sabitleştirilirken gereğinden fazla küçülmemesine dikkat edilmelidir. Görüntüler gereğinden fazla küçültülürse bu sefer görüntünün sınıflandırılması için gerekli olan bilgi çıkarımı zorlaşacaktır. Çalışmanın bir sonraki aşamasında sabit

boyut ve çözünürlüğe ayarlanan görüntüler üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yaklaşımın genel tasarımı Şekil 3'te gösterilmektedir.



Şekil 3. Önerilen yaklaşımın genel tasarımı.

Şekil 3'te gösterilen model toplamda 24 katmandan oluşmaktadır. Model 13 Evrişim (Convolution), 5 Maksimum havuzlama (Maximum), 2 Unutma (Droupout), 2 Toplu Normalleştirme (BatchNormalization), 2 Tam Bağlantı (Fully Connected) ve 1 Çıkış (Softmax) katmanlarından oluşmaktadır. Modelin parametre sayısı 134.309.700'dir.

Geliştirilen model incelendiğinde; modele gri formatta gelen beyin MRI giriş görüntüsüne 13 evrişim ve 5 havuzlama (maksimum) katmanı uygulanır. Evrişim ve havuzlama katmanları tamamlandıktan sonra düzleştirme ve tam bağlantı katmanı uygulanmaktadır. Tam bağlantı-1 (FC1) katmanı ve toplu normalleştirme-1 katmanlarına düzleştirme işlemi sonucunda geçilir. Bu katmanlardan sonra 0,3 ile 0,5 arasında bırakma oranını ile unutma işlemi gerçekleştirilir. Geliştirilen modelde ağız ezberlemesi engellemek için unutma katmanı kullanılmaktadır. Daha sonra tam bağlantı-2 katmanına ve toplu normalleştirme-2 katmanlarına geçilir. Bir sonraki aşamada tekrar 0,3 ile 0,5 arasında bırakma oranını ile unutma işlemi gerçekleştirilir. Modelin son kısmında 4 sınıflı bir çıkış elde etmek için Softmax optimizasyon algoritması kullanılmaktadır. Ayrıca modelin evrişim katmanlarında ReLU aktivasyon fonksiyonu kullanılmaktadır.

2.5. Kullanılan Ortam ve Kütüphaneler

Geliştirilen VGG-19 temelli modelin eğitim ve test işlemleri PyCharm 2021 ile gerçekleştirilmiştir. Modellerde kullanılan veri seti dosyalarının işlenmesi için Python 3.6 ile OpenCV, Sklearn, Keras, Imageio, Matplotlib, NumPy, PIL ve Os kütüphaneleri kullanılmıştır. Çalışmada kullanılan bilgisayarın işletim sistemi 64-bit Windows 10'dur. Diğer donanım bilgileri ise NVIDIA GeForce® RTX™ 3060 6 GB ekran kartı, 11. Nesil Intel® Core™ i7 2,3 GHz (24M Önbellek, 4,6 GHz'e kadar, 8 Çekirdek) işlemci ve 16 GB bellek.


3. Bulgular ve Tartışma

Yapılan çalışmada veri集中的 görüntüler %74 eğitim, %17 test ve %9 doğrulama veri kümesi olmak üzere üçe bölünmüştür. Çalışmada 5712 eğitim, 1311 test ve 655 doğrulama olmak üzere toplamda 7678 görüntü kullanılmıştır. Geliştirilen modelin eğitim parametreleri Tablo 1’de gösterilmektedir.

Tablo 1. Geliştirilen modelin eğitim parametreleri

Parametre	Değer
Epoch	150
Mini Batch Size	32
Unutma (Dropout)	0,3 - 0,5
Aktivasyon Fonksiyonu	ReLU
Optimizasyon Algoritması	Softmax

Şekil 4’te geliştirilen modelinin eğitim (train) ve test veri kümesiyle eğitilmesi sırasında elde edilen doğruluk (accuracy) oranı ve kayıp (loss) değeri grafiksel olarak gösterilmiştir. Grafikler incelendiğinde; ağırlıklı bir şekilde öğrendiği görülmektedir. 10. iterasyondan 150. iterasyona kadar iniş çıkışlardan da anlaşıldığı üzere ağırlıklı öğrenmeye devam ettiği görülmektedir. Modelin eğitimi bittikten sonra %95 doğruluk oranı elde edilmiştir.



Şekil 4. Geliştirilen modelin modelinin doğruluk ve kayıp grafiği.

Yapılan çalışmada sınıflandırma işlemlerini gerçekleştirilen modellerin performanslarını değerlendirmek için karmaşıklık matrisi kullanılmıştır. Karmaşıklık matrisi oluşturulurken kullanılan terimler; DP: Doğru Pozitif, YP: Yanlış Pozitif, DY: Doğru Negatif ve YN: Yanlış Negatiftir. Bu terimler kullanılarak ayrıca modelin Kesinlik, Duyarlılık, Doğruluk ve F1-Skor değerleri hesaplanabilir. Bu değerleri hesaplamak için denklem 1, 2, 3 ve 4’ te verilen matematiksel işlemler kullanılmaktadır.

$$Kesinlik = \frac{DP}{DP + YP} \quad (1)$$

$$Duyarluluk = \frac{DP}{DP + YN} \quad (2)$$

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (3)$$


$$F1 - Skor = \frac{2DP}{DP + YP + YN} \quad (4)$$

Önerilen modelin test verileri kullanılarak elde edilen sınıflandırma işlemlerinin analiz sonuçları Tablo 2’de gösterilmektedir.

Tablo 2. Sınıflandırma işlemlerinin analiz sonuçları

Sınıflar	Destek	Duyarlılık %	Kesinlik %	F1-Skor %	Doğruluk %
Glioma	300	97	83	89	95
Meningioma	306	83	97	90	
Sağlıklı	405	100	99	99	
Hipofiz	300	100	97	98	

Sınıflandırma işlemlerinde sonra elde edilen sonuçlara göre önerilen yöntemin karmaşıklık matrisi Şekil 5’te gösterilmektedir.



Şekil 5. Modelin karmaşıklık matrisi.

Yapılan çalışmada kullanılan veri seti ve benzeri veri setleri üzerinde gerçekleştirilen beyin tümörü tespiti çalışmalarının önerilen model ile karşılaştırılması Tablo 3’te gösterilmektedir.

Tablo 3. Benzer veri setleri ile gerçekleştirilmiş çalışmaların karşılaştırılması.

Makale	Mimari/Yöntem	Değer (%)
Sharma ve ark.	ResNet50 model and the EWS-based modified ResNet50	92 - 90
Fajar Akbar ve ark.	Naif Bayes	84.17
Önerilen model	VGG-19	95

Tablo 3'teki değerleri incelendiğinde; (Fajar Ekber ve ark., 2019) beyin tümör görüntüleri üzerinde bölütleme işlemi gerçekleştirmişlerdir. Ayrıca veri arttırma yöntemi sayesinde yeni görüntüler elde etmişlerdir. Çalışmalarında kullanılan görüntüler üzerinde öznelik çıkarımı gerçekleştirmiş ve ardından Naif Bayes yöntemi kullanılarak elde ettikleri yeni görüntüleri sınıflandırmışlardır. Önerilen modelin sınıflandırma başarı oranları %84.17'dir. (Sharma ve ark., 2022) değiştirilmiş bir ResNet50 mimarisi ile entegre edilmiş gelişmiş Watershed segmentation (EWS) yardımıyla beyin tümörünü tespit etmek için yeni bir teknik sunmuşlardır. Önerilen model, beş evrimsel katman ve üç tam bağlantılı katman içeren değiştirilmiş bir katman mimarisine sahip ResNet50 modelini kullanmaktadır. Önerilen hibrit derin öznelik tabanlı modifiye ResNet50 modeli ve EWS tabanlı modifiye ResNet50 modeli ile sırasıyla %92 ve %90 doğruluk oranları elde etmişlerdir.

4. Sonuç

Yapılan çalışmada beyin MRI görüntülerini içeren açık kaynaklı veri seti kullanılarak beyin tümörü tespitinde tümörü türlerini ayırt edebilen yeni bir VGG-19 mimarisi tabanlı model önerilmiştir. Kullanılan veri setindeki görüntüler 4 sınıftan oluşmaktadır. Veri setini glioma, meningioma, hipofiz ve sağlıklı beyin MRI görüntüleri oluşturmaktadır. Önerilen modelinin sınıflandırma doğruluğu, benzer veri setini kullanan önceki çalışmalara karşılaştırıldığında daha iyi sonuçlar elde edildiği görülmektedir. Çalışmada elde edilen sınıflandırma başarısı %95'tir.

Gelecek çalışmalarda önerilen modelin üzerinde değişikliklerle elde edilen doğruluk oranının iyileştirilmesi ve farklı alanlarda kullanılarak test edilmesi hedeflenmektedir.

5. Kaynaklar

- Gupta, R. K., Bharti, S., Kunhare, N., Sahu, Y., & Pathik, N. (2022). Brain Tumor Detection and Classification Using Cycle Generative Adversarial Networks. *Interdisciplinary Sciences: Computational Life Sciences*, 1-18.
- Toğaçar, M., Ergen, B., & Cömert, Z. (2020). BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model. *Medical hypotheses*, 134, 109531.
- Dong, H., Yang, G., Liu, F., Mo, Y., & Guo, Y. (2017, July). Automatic brain tumor detection and segmentation using U-Net based fully convolutional networks. In *annual conference on medical image understanding and analysis* (pp. 506-517). Springer, Cham.
- Amin, J., Sharif, M., Yasmin, M., & Fernandes, S. L. (2020). A distinctive approach in brain tumor detection and classification using MRI. *Pattern Recognition Letters*, 139, 118-127.
- Arif, M., Ajesh, F., Shamsudheen, S., Geman, O., Izdrui, D., & Vicoveanu, D. (2022). Brain tumor detection and classification by MRI using biologically inspired orthogonal wavelet transform and deep learning techniques. *Journal of Healthcare Engineering*, 2022.
- Amin, J., Anjum, M. A., Sharif, M., Jabeen, S., Kadry, S., & Moreno Ger, P. (2022). A New Model for Brain Tumor Detection Using Ensemble Transfer Learning and Quantum Variational Classifier. *Computational Intelligence and Neuroscience*, 2022.

- Qureshi, S. A., Raza, S. E. A., Hussain, L., Malibari, A. A., Nour, M. K., Rehman, A. U., ... & Hilal, A. M. (2022). Intelligent Ultra-Light Deep Learning Model for Multi-Class Brain Tumor Detection. *Applied Sciences*, 12(8), 3715.
- Anaya-Isaza, A., & Mera-Jiménez, L. (2022). Data Augmentation and Transfer Learning for Brain Tumor Detection in Magnetic Resonance Imaging. *IEEE Access*, 10, 23217-23233.
- Sharma, A. K., Nandal, A., Dhaka, A., Koundal, D., Bogatinoska, D. C., & Alyami, H. (2022). Enhanced watershed segmentation algorithm-based modified ResNet50 model for brain tumor detection. *BioMed Research International*, 2022.
- Kumar, T. S., Arun, C., & Ezhumalai, P. (2022). An approach for brain tumor detection using optimal feature selection and optimized deep belief network. *Biomedical Signal Processing and Control*, 73, 103440.
- Dehkordi, A. A., Hashemi, M., Neshat, M., Mirjalili, S., & Sadiq, A. S. (2022). Brain Tumor Detection and Classification Using a New Evolutionary Convolutional Neural Network. *arXiv preprint arXiv:2204.12297*.
- Veri Seti : <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri> Erişim Tarihi: 05.07.2022.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
- Min, S., Lee, B., & Yoon, S. (2017). Deep learning in bioinformatics. *Briefings in bioinformatics*, 18(5), 851-869.
- Hanbay, K. (2020). Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35(1), 443-456.
- Niepert, M., Ahmed, M., & Kutzkov, K. (2016, June). Learning convolutional neural networks for graphs. In *International conference on machine learning* (pp. 2014-2023). PMLR.
- Kurt, F. (2018). Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi.
- Toğaçar, M., Ergen, B., & Özyurt, F. (2020). Evrişimsel Sinir Ağı Modellerinde Özellik Seçim Yöntemlerini Kullanarak Çiçek Görüntülerinin Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(1), 47-56.
- Mateen, M., Wen, J., Song, S., & Huang, Z. (2018). Fundus image classification using VGG-19 architecture with PCA and SVD. *Symmetry*, 11(1), 1.
- Mostafiz, R., Rahman, M. M., Islam, A. K., & Belkasim, S. (2020). Focal liver lesion detection in ultrasound image using deep feature fusions and super resolution. *Machine Learning and Knowledge Extraction*, 2(3), 10.
- Akbar, F., Rais, A. N., Sobari, I. A., Zuama, R. A., & Rudiarto, B. (2019). Analisis performa algoritma naïve Bayes pada deteksi otomatis citra mri. *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, 5(1), 37-42.

Otonom Araçlar için Doğrusal Karesel Optimal Regülatör Tasarımına Dayalı Uyarlamalı Hız Kontrol Sistemi

An Adaptive Cruise Control System Based on Linear Quadratic Optimal Regulator Design for Autonomous Vehicles

Fatih ADIGÜZEL^{*1} 

¹Elektrik ve Elektronik Mühendisliği, İstanbul Üniversitesi-Cerrahpaşa, İstanbul, Türkiye

(fatihadiguzel1@iuc.edu.tr)

Özetçe— Bu çalışmada, belli sayıda araç takımından oluşan uyarlamalı hız kontrol sistemlerinin kendiliğinden sürülmesi için doğrusal bir kontrolcü tasarımı ele alınmaktadır. N , araç konvoyundaki araç sayısı olmak üzere, araçlar arasındaki uzunlamasına yönde matematiksel model N tane araç için elde edilmektedir. Sonrasında, doğrusal karesel optimal regülatör ile araç konvoyunun hız kontrolü gerçekleştirilmektedir. Elde edilen kontrolcü üç araçlı bir konvoy için sayısal benzetim çalışmaları ile test edilmektedir.

Anahtar Kelimeler : Doğrusal karesel regülatör, Uyarlamalı hız kontrolü, Otonom araç kontrol sistemleri

Abstract— This paper tackles the design of a linear controller for self-driving adaptive cruise control systems consisting of platoons of vehicles in a given number. The mathematical model is obtained for N vehicles in the longitudinal direction between vehicles, where N is the number of vehicles in the vehicle convoy. Afterward, the speed control of the vehicle convoy is performed with the linear-quadratic optimal regulator. The devised controller has been tested with numerical simulation studies for a three-vehicle convoy.

Keywords : Linear quadratic regulator, Adaptive cruise control, Autonomous vehicle control systems

1.Giriş

Otonom araç kontrol sistemleri otomatikleştirilmiş modern araçlar için bir araç kontrol sistemidir. Uyarlamalı hız kontrol sistemine sahip bir araç önündeki bir araca göre belli hız, belli aralıkta (zaman veya mesafe) takibi gerçekleştirebilmektedir (Jiang, 2006). Uyarlamalı hız kontrol sistemleri araçların uzun süreli tam otomatik sürüş hedefine ulaşması için etkili bir sürüş sağlamaktadır ve araştırmacılar bu sistemler üzerine oldukça fazla eğilmişlerdir (He, 2019). Araçlar arasındaki güvenliğin devam ettirilmesi için otonom araçlarda en genel olarak PID (proportional-integral-derivative) kontrol yöntemi araç hızlarını ve araçlar arasındaki iç mesafeyi düzenlemek için kullanılmaktadır (Shladover, 2015; Levent, 2012; Tolga, 2018). Doğrusal kontrolcülerin yanında kestirime dayalı model öngörülü kontrol yöntemleri (Geiger, 2011; Weißmann, 2012) ve bulanık mantık kontrolcüler literatürde ilgi görmüş diğer öne çıkan yöntemlerdir (Prabhakar, 2019; Mao, 2021). Bu çalışmalarda model öngörülü kontrol yöntemlerinin model doğruluğuna hassasiyeti ve ağır işlem yüküne sahip olması ve bulanık kontrol tabanlı yöntemlerde optimal sonuçların zorluğu ve çok parametreliliği yapıda bir kontrolcü olması bahsedilen bu iki yöntemin PID kontrolcü yöntemine göre dezavantajlarıdır. Diğer taraftan, PID kontrolcünde de kontrol parametrelerinin belirlenmesi geçici durum cevabında zorluklar yaratmaktadır. Bunların dışında, hem uygulama kolaylığı hem de optimal sonuç verebilmesi yönüyle doğrusal karesel

optimal regülatör kontrol metodu öne çıkmaktadır. Ayrıca, PID kazanç parametrelerinin belirlenmesinde de doğrusal karesel regülatör kullanılmaktadır (Kim, 2012).

Bu çalışmada otonom sürüş durumunda olan N tane araçtan oluşan bir homojen araç konvoyunun sabit zaman aralığında araçların takibi için bir geri beslemeli doğrusal kontrol yöntemi (doğrusal karesel optimal regülatör) tasarımı gerçekleştirilmektedir. Araç konvoyu için doğrusal model dinamiği durum uzay gösteriminde elde edildikten sonra doğrusal kontrol yöntemi tasarımı verilmektedir. Ayrıca, sayısal benzetim sonuçları ile kontrolcü performansı test edilmektedir.

Bu çalışmanın devamı şu şekilde organize edilmektedir. Bir sonraki başlıkta araç üst seviyeli kontrolü için dinamik model verilmektedir ve sonrasında buna uygun olarak doğrusal karesel kontrolcü inşası sunulmaktadır. Devamındaki başlıkta, üç araca sahip bir konvoy için gerçekleştirilen bilgisayar tabanlı benzetim çalışmaları verilmektedir ve kontrolcü başarısı gösterilmektedir. Son olarak, bu çalışmanın öne çıkan sonuçlarından bahsedilmektedir.

2. Araç Dinamiği Ve Modellemesi

Araç hız kontrol sistemlerinde üst seviyeli ve alt seviyeli iki kontrolcü yapısı bulunmaktadır (Tolga, 2018). Üst seviyeli kontrolcü yapısı araç konvoyundaki araçlar için istenilen ivmelenmenin hesaplanmasında devredeyken, alt seviyeli kontrolcü yapısı istenilen ivmelenmenin veya yavaşlamanın gerçekleştirilmesi/takip edilmesi için gerekli gaz ve fren durumlarını ayarlanmasında kullanılmaktadır. Bu çalışmada ele alınan, üst seviyeli bir kontrol yapısı tasarlayabilmek için temel bir araç dinamiği


$$\alpha_i(t) = \ddot{x}_i(t) \quad (1)$$

$$\tau_i \dot{\alpha}_i(t) + \alpha_i(t) = u_i(t) \quad (2)$$

şeklinde elde edilmektedir ki burada α_i araç konvoyundaki i . aracın ivmesini, x_i araç konvoyundaki i . aracın konumunu, τ_i zaman gecikmesini, u_i ivmelendirme giriş sinyali göstermektedir. Bu durumda, araç dinamiğinin birinci dereceden transfer fonksiyonu

$$G_i(s) = \frac{X_i(s)}{U_i(s)} = \frac{1}{s^2(\tau_i s + 1)} \quad (3)$$

biçiminde elde edilmektedir.



Şekil 1. Araç konvoyundaki sıralı araçların temsili gösterimi (Ploeg, 2015).

3. Doğrusal Karesel Regülatör (DKR) Tasarımı

Bu başlıkta N tane araçtan oluşan bir otonom konvoy sisteminin kontrolü için doğrusal karesel optimal regülatör tasarımı ve analizleri verilmektedir. Bu tasarım ve analizlerin N tane araç için geliştirilmesi için araçlar arasındaki uzaklık hesaplama felsefesinin, araçlar arasındaki mesafe hesaplamalarının ve araç konvoy modelinin oluşturulması gerekmektedir.

Literatürde otonom araç konvoylarındaki araçların uzaklıkları üzerine farklı yakınlık/uzaklık yöntemleri bulunmaktadır (Jiang, 2006). Araç konvoyunu temsili gösterimi Şekil 1'de gösterilmektedir. Şekil 1'de N tane araçtan oluşan konvoydaki i . araç için araç hızları (v_{i+1} , v_i , v_{i-1}) ve herhangi iki araç

arasındaki uzaklılık (d_{i+1}, d_i, d_{i-1}) gösterilmektedir. Araçlar arasında sabit zaman aralığı politikası düşünülerek, i . araç için istenilen görece konum farkı $(d_{d,i})$

$$d_{d,i} = p_i + \dot{x}_i t_{hd,i} \quad (4)$$

biçiminde yazılabilmektedir ki burada p_i durma mesafesini, $\dot{x}_i$ ifadesi i . aracın hızını, $t_{hd,i}$ ifadesi i . aracın istenilen zaman aralığını göstermektedir. Tasarımların basitliği için durma mesafesi sıfır olarak ayarlanabilmektedir (Tolga, 2018). İki araç arasındaki görece gerçek uzaklık

$$d_i = x_{i-1} - x_i \quad (5)$$

olarak yazılmaktadır. (4) ve (5) kullanılarak gerçek ve istenilen görece uzaklık hata dinamiği, e_i ifadesi i . araç için hata değişkeni olmak üzere

$$\begin{aligned} e_i &= d_i - d_{d,i} \\ e_i &= x_{i-1} - x_i - \dot{x}_i t_{hd,i} \end{aligned} \quad (6)$$

olarak elde edilmektedir. N tane araçtan oluşan konvoydaki tüm araçları ve araçlar arasındaki uzaklıklarının doğrusal modeli uygun derecelerle ifade edilmiş A, B, C matrisleri ile

$$\dot{X}(t) = AX(t) + BU(t) \quad (7)$$

$$Y(t) = CX(t) \quad (8)$$

olarak yazılabilmektedir. Burada x_d konvoyun takip ettiği araç konumunu, v_d konvoyun takip ettiği aracın hızını, a_d konvoyun takip ettiği aracın ivmesini göstermek üzere

$$\begin{aligned} X(t) &= \begin{bmatrix} x_d(t) - x_1(t) \\ x_1(t) - x_2(t) \\ \vdots \\ x_{N-2}(t) - x_{N-1}(t) \\ v_d(t) - v_1(t) \\ v_1(t) - v_2(t) \\ \vdots \\ v_{N-2}(t) - v_{N-1}(t) \end{bmatrix} \\ U(t) &= [a_d(t) \quad a_1(t) \quad \cdots \quad a_{N-1}] \\ Y(t) &= \begin{bmatrix} x_d(t) - x_1(t) \\ x_1(t) - x_2(t) \\ \vdots \\ x_{N-2}(t) - x_{N-1}(t) \end{bmatrix} \\ A &= \begin{bmatrix} 0_{(N-1 \times N-1)} & I_{(N-1 \times N-1)} \\ 0_{(N-1 \times N-1)} & 0_{(N-1 \times N-1)} \end{bmatrix} \\ B &= \begin{bmatrix} 0_{(N-1 \times 1)} & -t_{hd} I_{(N-1 \times N-1)} \\ [I_{(N-1 \times N-1)} & 0_{(N-1 \times 1)}] + [0_{(1 \times N-1)} & -I_{(N-1 \times N-1)}] \end{bmatrix} \\ C &= [-I_{(N-1 \times N-1)} \quad 0_{(N-1 \times N-1)}] \end{aligned}$$

biçiminde yazılabilmektedir ki $0_{(*) \times (*)}$ ve $I_{(*) \times (*)}$ sırasıyla sıfır ve birim matrisleri ve alt indisleri ise boyutlarını göstermektedir. Böylece N tane araçtan oluşan bir konvoy sistemi için doğrusal bir model oluşturulmuştur. Bu noktada, oluşturulan doğrusal modelde ((7)-(8)) kontrol edilebilirlik ve gözlenilebilirlik testlerinin yapılması (Gruyitch, 2018) sonrasında sistem her iki test için tam ranklı olarak elde edilmektedir. Devamında DKR kontrolcüsü tasarımına geçilebilmektedir. DKR kontrolcüsü maliyet fonksiyoneli

$$J = \int_{t_0}^{\infty} (X^T(t)QX(t) + U^T(t)RU(t))dt \quad (9)$$

şeklinde yazıldığında $Q = C^T C$ ve R sırasıyla durumlar üzerinde ve kontrol girişi üzerinde ceza katsayıları olmak üzere yazılmaktadır. Ayrıca, R ceza kazancı

$$R = \gamma \begin{bmatrix} \frac{1}{\epsilon} & 0_{(1 \times N-1)} \\ 0_{(N-1 \times 1)} & I_{(N-1 \times N-1)} \end{bmatrix}$$

olarak tasarlanmaktadır ki γ sistem çıkışını ayarlayabilmek için bir kontrolcü kazancı, ϵ oldukça küçük pozitif bir sayıyı göstermektedir. Bu değerler, mevcut hesaplama yüküne bağlı olarak artırılabilir. Geri beslemeli kontrolcü

$$\begin{aligned} U(t) &= -R^{-1}B^T P X(t) \\ &= -KX(t) \end{aligned} \quad (10)$$

sinyali, P pozitif sabit değerlere sahip bir matris olmak üzere,

$$0 = PA + AP^T - PBR^{-1}B^T P + Q \quad (11)$$

biçiminde tanımlanan matematiksel bir diferansiyel denklemin çözümü sonucunda elde edilmektedir.



4. Benzetim Çalışmaları


Bu alt başlıkta otonom araç konvoyu için tasarlanan DKR kontrolcüsünün uygulanabilirliğinin gösterilmesi için MATLAB ortamında gerçekleştirilen sayısal benzetimler sunulmaktadır. N tane araç için gerçekleştirilen tasarımda $N = 4, i = \{1,2,3\}$ ve $\tau_i = 0.3$ için benzetimler sunulmaktadır. t_{hdi} ifadesi istenilen zaman aralığı tüm araçlar için aynı değerde ve 0.6 olarak alınmıştır. Kontrolcü kazançları $\gamma = 0.02, \epsilon = 1e - 5$ olarak atanmaktadır. Benzetim sonuçlarında hız kontrolcü kazançları

$$K = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ -7.0026 & 0.9698 & 0.1500 & 0.0325 & 0.0011 & -0.0075 \\ -0.9390 & -6.9676 & 0.9820 & 0.1502 & 0.0288 & -0.0029 \\ -0.2718 & -0.9230 & -6.9348 & 0.9801 & 0.1455 & 0.0232 \\ -0.0885 & -0.2645 & -0.9206 & -6.9357 & 0.9756 & 0.1378 \\ -0.0236 & -0.0829 & -0.2603 & -0.9184 & -6.9376 & 0.9673 \end{bmatrix}$$

olarak hesaplanmıştır. Burada belirtmek gerekir ki kontrol kazancının ilk satırı istenilen araç ivmesi, konvoyun kontrolü için gerekli değildir, ilk satır değerleri sıfıra yuvarlanmaktadır. Gerçekleştirilen benzetim çalışmaları farklı hızlanma profili içeren hız şekilleri için sunulmaktadır (bkz Şekil 1(b)). Benzetim çalışmaları ile sunulan sonuçlarda, araç konumları (bkz Şekil 1(a)), araç hızları (bkz Şekil 1(b)), araç ivmeleri (bkz Şekil 1(c)) ve son olarak 0.6 olarak ayarlanan sabit zaman aralığının takibini göstermek için araç ilerleme zamanları (bkz Şekil 1(d)) verilmektedir.

Benzetim sonuçları incelendiğinde istenilen hızlanma profilinde konvoydaki araçların başarılı takipleri görülmektedir. Ayrıca, bu sonuçlara bakıldığında sabit zaman aralığı düşünülerek tasarlanan doğrusal karesel optimal regülatör kontrolcüsünün otonom araçlardan oluşan bir homojen araç konvoyunda başarısı gözlenmektedir.





Şekil 2. Benzetim Sonuçları: Araç konumları (a), Araç hızları (b), Araç ivmeleri (c), 50 sn -60 sn için araç ilerleme zamanları (d)

4. Sonuç

Bu çalışmada otonom bir araç konvoyunda araçların sabit zaman aralığında birbirlerini ardışık takip edebilme problemi doğrusal karesel optimal regülatör kontrolcüsü ile incelenmektedir. Otonom araç konvoyu sisteminin dinamik modeli, araç konvoyundaki araç sayısının değişebilir olduğu düşünülerek genelleştirilmiş bir doğrusal durum uzay modeli ile elde edilmiştir. Sonrasında, genelleştirilmiş doğrusal sistem dinamiği için doğrusal karesel regülatör tasarımı gerçekleştirilmiştir. Kontrolcü genel tasarım prosedürü sunulduktan sonra dört araçtan oluşan bir konvoy için elde edilen yöntem başarılı benzetim çalışmaları ile desteklenmiştir. Sayısal benzetimlerle sunulan sonuçlar yöntemin uygulanabilirliği ve başarısını göstermektedir. Bu çalışma göstermektedir ki doğrusal karesel optimal regülatör bir araç konvoyunun otonom kontrolü için başarılı bir şekilde kullanılabilir. Diğer taraftan, bu sonuçların ortam ve kullanılan donanım ekipmanlarının eksik ve/veya devre dışı olduğu durumlar için takviye edici kontrol tasarımlarına ve gerçekçi benzetim çalışmalarına ihtiyaç duyulacaktır. Bahsedilen bu ilerlemelerin gerçekleştirilmesi bu çalışma sonrasında hedeflenmektedir.

Kaynaklar

- R. Jiang, Q. S. Wu, Q. S. (2016), The adaptive cruise control vehicles in the cellular automata model. Physics Letters A, 2006, vol. 359(2), pp.99-102.
- Y. He, B. Ciuffo, Q. Zhou, M. Makridis, K. Mattas, J. Li, ..., H. Xu, (2019). Adaptive cruise control strategies implemented on experimental vehicles: A review. IFAC-PapersOnLine, 2019, vol. 52(5), pp. 21-27.
- S. E. Shladover, C. Nowakowski, X. Y. Lu, R. Ferlis, R. (2015), Cooperative adaptive cruise control: Definitions and operating concepts. Transportation Research Record, 2015, vol. 2489(1), pp. 145-152.
- L. Güvenç, I.M.C. Uygan, K. Kahraman, R. Karaahmetoglu, I. Altay, M. Sentürk, ..., B. Efendioğlu, (2012), Cooperative adaptive cruise control implementation of team mekar at the grand cooperative driving challenge. IEEE Transactions on Intelligent Transportation Systems, vol. 13(3), pp. 1062-1074.
- M.T. Emirler, L. Güvenç, B. A. Güvenç, Design and evaluation of robust cooperative adaptive cruise control systems in parameter space. International Journal of Automotive Technology, 2018, vol. 19(2), pp. 359-367.

- A. Geiger, M. Lauer, F. Moosmann, B. Ranft, H. Rapp, C. Stiller, J. Ziegler, (2012), Team AnnieWAY's entry to the 2011 grand cooperative driving challenge. *IEEE Transactions on Intelligent Transportation Systems*, 2012, vol. 13(3), pp. 1008-1017.
- A. Weißmann, D. Görge, X. Lin, (2018) Energy-optimal adaptive cruise control combining model predictive control and dynamic programming. *Control Engineering Practice*, vol. 72, pp. 125-137.
- G. Prabhakar, S. Selvaperumal, P. Nedumal Pugazhenth, (2019), Fuzzy PD plus I control-based adaptive cruise control system in simulation and real-time environment. *IETE Journal of Research*, vol. 65(1), pp. 69-79.
- J. Mao, L. Yang, Y. Hu, K. Liu, J. Du, (2021) Research on Vehicle Adaptive Cruise Control Method Based on Fuzzy Model Predictive Control. *Machines*, vol. 9(8), pp. 160.
- S. Kim, (2012), Design of the adaptive cruise control systems: An optimal control approach. University of California, Berkeley.
- J. Ploeg, E. Semsar-Kazerooni, G. Lijster, N. van de Wouw, H. Nijmeijer, (2018) Graceful degradation of cooperative adaptive cruise control. *IEEE Transactions on Intelligent Transportation Systems*, vol. 16(1), pp. 488-497.
- L. T., Gruyitch, (2018) Control of Linear Systems: Observability and Controllability of General Linear Systems., CRC Press.

Label Propagation Community Optimization Via Boundary Nodes Transfers

Furkan ÖZTEMİZ 

Yazılım Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

(furkan.oztemiz@inonu.edu.tr)

Abstract— Many methods have been developed for community detection. These methods show performance differences according to the structure of the networks. These performance differences are determined by measuring the modularity value of the communities. The modularity value measures the quality of a network's segmentation into communities. This study presents a modularity improvement method to improve the quality of the clustering operations performed by the Label Propagation community detection algorithm. The presented approach aims to transfer border nodes to neighboring communities to increase the modularity value in line with the determined criteria. The proposed method has been applied on Zebra, Zachary Karate Club, and Claw Free networks, which are very popular in the literature, and the results are given. When the results are examined, the optimization method applied on the three networks increased the modularity values of the Label Propagation algorithm at varying rates (6.1%, 6.5%, 20.26%).

Keywords: *Community Detection, Label Propagation, Modularity Optimization*

1. Introduction

Clustering operations on the network are carried out with community detection algorithms. Network communities provide many benefits for classification and pattern discovery [1]. Community detection algorithms in the literature can show different successes due to their unique approaches. The success of a community detection algorithm is directly proportional to the high modularity values of the communities [2]. One of the most popular clustering metrics [3]. This study proposes a method that aims to increase the modularity value independently from the data set. The proposed method performs the transfer of border nodes to neighboring communities in line with the criteria determined to increase the modularity value. The study focuses on improving the modularity results of the Label Propagation [4] community detection algorithm. Label propagation algorithm produces no unique solution but an aggregate of many solutions. Therefore, the modularity value is not stable and may need constant optimization. The application was carried out on Zebra[5], Zachary Karate club[6], and Clawfree[7] networks used in many studies in the literature. Clustering successes of Label Propagation algorithm on different networks are examined, and comparative results are given. There are various studies in the literature to improve clustering qualities.

The fast parallel modularity optimization algorithm (FPMQA) has been proposed by Zhan Bu et al. In their study; they compared different methods using real data sets. It is stated that the proposed method detects potential online communities more successfully and accurately [8]. Shirzad et al. proposed a spectral method aimed at increasing modularity. The proposed method has been tested on seven real networks. It was stated that more successful results were obtained than the Newman-fast method [9]. Fang et al. proposed a modularity optimization landing framework, which they called a vector-label propagation algorithm (VLPA). The proposed method has successfully optimized the modularity measurement in large networks [10]. Liu and Murata combined the label propagation algorithm(LPAm) and the multistep greedy agglomerative algorithm (MSG) in their study in the field of modularity and proposed the modularity-specialized label propagation algorithm (LPAm+) algorithm. Successful results were obtained by applying the new method on two real networks [11]. Waltman and van Eck have proposed an algorithm called smart local moving. The proposed method was compared with the Louvain algorithm, which gave successful modularity results. It has been stated that the proposed method gives more successful results in non-large networks [12]. Aung and Nyunt proposed the

modularity-based artificial bee colony (MABC) algorithm. The proposed method was evaluated with modularity and normalized mutual information metrics. In the application on three data sets, better results were produced compared to the other algorithms given in the study [13].

2. Material and Method

The presented study aims to improve the quality of communities created in any network with the Label Propagation (LP) algorithm. The proposed method working process is given in Figure 1. There are sample graphs used in the application in Stage 1. Zebra network consists of 27 nodes and 111 edges, Zachary karate club network consists of 34 nodes and 78 edges, Claw free network consists of 18 nodes and 33 edge relations [14]. The three graphs are weightless and undirected. In Stage 2, the LP community detection algorithm was applied on these graphs. In Stage 3, boundary node transfer operations are carried out to increase the modularity value. In Stage 4, the final version of the network with the current modularity value was given as a result of the transfer process.




Figure 1. Modularity optimization process

2.1. Community Detection

Community detection algorithms are used to detect the clustering, consolidation, and fragmentation tendencies of nodes in the network [15]. The usage areas of community detection algorithms include social networks, stock markets, transportation networks, etc., in many fields [16,17]. Many algorithms with different approaches have been developed to detect communities in the literature.

2.1.1 Label propagation algorithm

Label Propagation Algorithm (LPA), which is popularly used in social networks, was brought to the literature by Raghavan in 2007. It is trendy because it is an easy-to-implement and performant method [18]. LPA gives a unique label for all nodes in the first step. In each iteration, it replaces the labels of all nodes with the label of the node with the highest node degree. If there is more than one node with the highest node degree, the label of any of these nodes is changed. This way, node groups with high node degrees replace their different labels with the same ones. Nodes with the same label are clustered in the same community [19]. The label update formula is given in Equation 4. $N^l(i)$ denotes the neighbor set of labeled l of v_i , w_{ij} denotes the edge weight between v_i and v_j [19].

$$c_i = \arg \max_l \sum_{j \in N^l(i)} w_{ij}. \quad (4)$$

2.2. Modularity

Modularity is a quality function used to determine how well the network is divided [20]. Improving the modularity value is an NP-Complete problem [21]. There is no deterministic method that reaches the maximum modularity value. In the literature, there are low-performance algorithms that determine the maximum modularity value in certain and small networks [22]. Practical and fast algorithms are powered by greedy, simulated annealing or spectral optimization methods that produce mostly approximate results. This situation presents differences between the speed and accuracy values in the solution approaches of the algorithms [23]. The modularity Q of a network expressed as nodes n and edges m is formulated as in equation 7 [24]. A , is the neighborhood matrix of the network, k_i is the degree of node i , C_i community to which node i is assigned ve δ_{ij} is the Kronecker delta.

$$Q = \frac{1}{2m} \sum_{ij} \left(A_{ij} - \frac{k_i k_j}{2m} \right) \delta_{C_i C_j} \quad (7)$$

2.3. Proposed Methods

The proposed method aims to transfer the boundary nodes of the communities in the network in a way that increases the modularity value. Nodes that are connected to another community other than their own are called border nodes. Nodes 1, 6, 10, and 16 indicated in yellow in the image given in Figure 2 represent boundary nodes. The transfer of border nodes takes place in the order of priority. The community with the highest sum of the degrees of the nodes in its own community takes priority. In that community, the transfer of the border node with the highest degree takes priority. The transfer process takes place with the transfer of the relevant border node to all neighboring communities with which it is connected. If the modularity value increases after this transfer process, the transfer is confirmed. If not, the transfer is canceled, and the relevant border node remains in its community. This process continues with the transfer of all border nodes to neighboring communities. If the modularity value does not increase as a result of all transfer operations, the algorithm terminates the operation. For example, when boundary node 16 in Figure 2 is examined, it is transferred to these communities because it is connected to Community A and Community B. After the transfer of both groups, the modularity value is checked. Which community the modularity is higher, node 16 will be transferred to that community. If modularity does not increase, it remains in its own community, and the transfer process of the following border node begins.




Figure 2. Boundary nodes in communities

The flow chart of the proposed method is given in Figure 3.




Figure 3. Optimization method flow cart

3. Application

Firstly, the Label Propagation algorithm was applied on the Zebra network, and the modularity value was determined as 0,2606. Community structure and modularity value are given in Figure 4a. In Figure 4b, the modularity value and the current community structure are given after the implementation of the proposed optimization algorithm. In addition, a list expressing the transfer priority of the nodes is given in Figure 4b. In the transfer priority list, while the black ones represent the boundary nodes, the red colored ones represent the nodes that increase the modularity value when transferred. In this place, nodes 13 and 18 were transferred, and the modularity value increased to 0,2768.






Figure 4. Zebra Network Modularity Optimization

In the application made in the Zachary Karate Club network, the modularity value increased from 0.3744 to 0.3990, as given in Figure 5. When the transfer priority list given in Figure 5b is examined, only node 3 has been transferred.




Şekil 5. Zachary Karate Club Network Modularity Optimization

The modularity value of the Claw-free network, which was 0.4031 in Figure 6a, increased to 0.4848, as given in Figure 6b. The proposed method performed the transfer of nodes 12, 11, and 10. The visual of the current community structure after the new modularity is given in Figure 6b.



Şekil 6. Claw-free Network Modularity Optimization

Figure 7 indicates how much it improves the quality of communities created with the Label propagation algorithm in three different networks. When the values are examined, the quality of the communities in the Zachary karate club network improved by 6.50%, the communities in the Claw free network by 20.26%, and the communities in the Zebra network by 6.10%.



Şekil 7. All Network Modularity Optimization Rate

4. Results

The presented study aims to increase the modularity value of the communities created by the Label Propagation algorithm, regardless of any network. The optimization process, performed by transferring the nodes remaining at the community boundary, has been tested in three different networks. All stages of the proposed method are given in detail in the study. As a result of the application, improvement was

provided at 6.5% in the Zachary karate club network, 6.1% in the Zebra network, and 20.26% in Claw free network. The algorithm developed as an additional method to the LP algorithm is easy in terms of applicability and has $O(n^2)$ time complexity as performance.

References

- [1]- S. Fortunato, D. Hric, (2016), Community detection in networks: A user guide, Physics Reports, Volume 659, Pages 1-44, Doi:10.1016/j.physrep.2016.09.002.
- [2]- S.Kaur, S. Singh, S. Kaushal, A.K. Sangaiah, (2016), Comparative Analysis Of Quality Metrics For Community Detection In Social Networks Using Genetic Algorithm, Neural Network World 26(6): 625-641, Doi: 10.14311/NNW.2016.26.036.
- [3]- T. Chakraborty, A. Dalmia, A. Mukherjee, and N. Ganguly. (2017). Metrics for Community Analysis: A Survey. ACM Comput. Surv. 50, 4, Article 54 (July 2018), 37 pages. Doi:10.1145/3091106
- [4]- M. Luo, Y. Xu, Community detection via network node vector label propagation, Physica A: Statistical Mechanics and its Applications, Volume 593, 2022, 126931, Doi:10.1016/j.physa.2022.126931.
- [5]- S. R Sundaresan, I. R Fischhoff, J. Dushoff, and D. I Rubenstein, (2007), Network metrics reveal differences in social organization between two fission–fusion species, Grevy's zebra and onager. Oecologia, 151 (1): 140–149.
- [6]- S. R. Chintalapudi and M. H. M. K. Prasad, (2015), A survey on community detection algorithms in large scale real world networks, 2nd International Conference on Computing for Sustainable Global Development (INDIACom), pp. 1323-1327.
- [7]- F. ÖZTEMİZ, (2021), Karmaşık Ağlarda Hakim Düğümlerin Belirlenmesi için Yeni Bir Yöntem, Doktora Tezi, İnönü Üniversitesi Fen Bilimleri Enstitüsü.
- [8]- Z. Bu, C. Zhang, Z. Xia, J. Wang, (2013), A fast parallel modularity optimization algorithm (FPMQA) for community detection in online social network, Knowledge-Based Systems, Volume 50, Pages 246-259, Doi:10.1016/j.knosys.2013.06.014.
- [9]- M. Shirzad, M. Reza, F.-Derakhshi, (2016), Community Detection in Social Networks Based On Modularity Optimization, International Journal of Advances in Electronics and Computer Science, Volume-3, Issue-4, Apr.
- [10]- W. Fang, X. Wang, L. Liu, Z. Wu, S. Tang, Z. Zheng, (2022), Community detection through vector-label propagation algorithms, Chaos, Solitons & Fractals, Volume 158, Doi:10.1016/j.chaos.2022.112066.
- [11]- X. Liu, T. Murata, (2010), Advanced modularity-specialized label propagation algorithm for detecting communities in networks, Physica A: Statistical Mechanics and its Applications, Volume 389, Issue 7, Pages 1493-1500, Doi:/10.1016/j.physa.2009.12.019.
- [12]- Waltman, L., van Eck, N.J., (2013), A smart local moving algorithm for large-scale modularity-based community detection. Eur. Phys. J. B 86, 471 Doi:10.1140/epjb/e2013-40829-0.
- [13]- T. T. Aung and T. T. Soe Nyunt, (2020), Modularity Based ABC Algorithm for Detecting Communities in Complex Networks, International Journal of Machine Learning and Computing, Vol. 10, No. 2, February, Doi: 10.18178/ijmlc.2020.10.2.938.
- [14]- Konect, <http://konect.cc/networks/> Acces date: 25.07.2022.
- [15]- Harenberg, S., Bello, G., Gjeltrema, L., Ranshous, S., Harlalka, J., Seay, R., Padmanabhan, K. and Samatova, N., (2014), Community detection in large-scale networks: a survey and empirical evaluation. WIREs Comput Stat, 6: 426-439.
- [16]- Fortunato S., (2010), Community detection in graphs, Physics Reports, Volume 486, Issues 3–5, Pages 75-174.
- [17]- F. Öztemiz ve A. Karci, (2021), Topluluk Tespiti Yöntemi ile Ulaşım Ağında Verimli Yeşil Dalga Koridorlarının Belirlenmesi, Politeknik Dergisi, ss. 1-1, Doi:10.2339/politeknik.1074962.
- [18]- E. Jokar, M. Mosleh, (2019), Community detection in social networks based on improved Label Propagation Algorithm and balanced link density, Physics Letters A, Volume 383, Issue 8, Pages 718-727, Doi: 10.1016/j.physleta.2018.11.033.

- [19]- Y. Xing, F. Meng, Y. Zhou, M. Zhu, M. Shi, G. Sun, (2014), A Node Influence Based Label Propagation Algorithm for Community Detection in Networks, The Scientific World Journal, vol. 2014, Article ID 627581, Doi:10.1155/2014/627581.
- [20]- R. Aktunc, I. Hakki Toroslu, M. Ozer, and H. Davulcu. (2015), A Dynamic Modularity Based Community Detection Algorithm for Large-scale Networks: DSLM, (ASONAM '15), New York, NY, USA, 1177–1183. Doi:10.1145/2808797.2808822.
- [21]- S. Trajanovski, F.A. Kuipers, J. Martín-Hernández, P. Van Mieghem, (2013), Generating graphs that approach a prescribed modularity, Computer Communications, Volume 36, Issue 4, Pages 363-372.
- [22]- https://igraph.org/r/doc/cluster_optimal.html, Erişim Tarihi: 25.07.2022.
- [23]- L. Danon, J. Duch, A. Díaz-Guilera, A. Arenas, (2005), Topluluk yapısı tanımlamasının karşılaştırılması, J. Stat. Mech, (9): P09008. arXiv: koşul-mat/0505245, Doi:10.1088/1742-5468/2005/09/P09008.
- [24]- Botta, F & del Genio, C (2016), Finding network communities using modularity density, Journal of Statistical Mechanics: Theory and Experiment. Doi:10.1088/1742-5468/2016/12/123402.

Makine Öğrenmesi Algoritmaları kullanarak Türkçe istenmeyen e-posta filtreleme

Turkish spam e-mail filtering using Machine Learning Algorithms

Bekir Parlak^{*1} 

¹Bilgisayar Mühendisliği Bölümü, Amasya Üniversitesi, Amasya, Türkiye
(bekir.parlak@amasya.edu.tr)

Özetçe— Bu çalışmada, Türkçe metin içerikli e-postalarda, istenmeyen e-postaların makine öğrenmesi algoritmaları kullanılarak filtrelenmesi amaçlanmıştır. Günümüzde, e-postaların gönderilmesi kolay olduğu için, yalnızca arkadaşlarla iletişim kurmak için bir araç olarak değil, aynı zamanda genellikle reklam amaçlı istenmeyen e-posta kutularını yok etmek için bir araç olarak da büyük bir popülerlik kazanmıştır. Türkçe e-postaları istenmeyen veya normal olarak sınıflandırmak için öncelikle metin tabanlı istenmeyen ve normal e-posta örneklerini içeren bir Türkçe e-posta veri kümesi kullanılmıştır. Daha sonra, her bir e-postanın içeriği analiz edilmiş ve her e-postada görünen farklı kelimeler ya da terimler bulunmuştur. Bu kelimelere bir takım ön-işleme teknikleri uygulandıktan sonra, üç adet başarılı öznitelik seçim metodları olan Gini-Endeksi(GI), Max-Min Oranı(MMR), Kapsamlı Öznitelik Seçici(EFS) ile skorlar atanmıştır. Bu metodlarla elde edilen öznitelik vektörleri sırasıyla Naive Bayes(NB), k-En Yakın Komşuluk(k-EYK) ve Destek Vektör Makinesi(DVM) ile sınıflandırılmıştır. Eğitim aşamasında 300 istenmeyen ve 300 normal Türkçe e-posta kullanılırken, test aşamasında ise 100 istenmeyen ve 100 normal Türkçe e-posta kullanılarak sınıflandırma işlemi yapılmıştır. Üç farklı örüntü sınıflandırıcı ayrı ayrı test edilmiş ve en yüksek F skor 0.991 olarak GI ve NB kombinasyonu ile elde edilmiştir.

Anahtar Kelimeler : *Türkçe e-posta filtreleme, makine öğrenmesi, öznitelik seçimi, metin sınıflandırma.*

Abstract— In this study, it is aimed to filter spam e-mails in e-mails containing Turkish text by using machine learning algorithms. Nowadays, because e-mails are easy to send, they have gained immense popularity not only as a means to communicate with friends, but also as a means to destroy spam boxes, often for advertising purposes. In order to classify Turkish e-mails as spam or normal, firstly, a Turkish e-mail dataset containing text-based spam and normal e-mail samples was used. Then, the content of each e-mail was analyzed and different words or terms appearing in each e-mail were found. After applying some preprocessing techniques to these words, scores were assigned with three successful feature selection methods, Gini-Index (GI), Max-Min Ratio (MMR), Extensive Feature Selector (EFS). The feature vectors obtained by these methods are classified by Naive Bayes (NB), k-Nearest Neighborhood (k-EYK) and Support Vector Machine (SVM), respectively. While 300 spam and 300 normal Turkish e-mails were used in the training phase, the classification process was carried out using 100 spam and 100 normal Turkish e-mails in the testing phase. Three different pattern classifiers were tested separately and the highest F score of 0.991 was obtained with the combination of GI and NB.

Keywords : *Turkish e-mail filtering, machine learning, feature selection, text classification.*

1.Giriş

E-ticaretin artmasıyla birlikte e-ticaret şirketlerinin sayısındaki sürekli artışlar, reklam e-postalarının sayısının artmasına neden oldu. Çevrimiçi alışveriş yapan müşteriler, güvenilir olmayan göndericilerden şifrelerini veya banka hesap bilgilerini avlamak için e-postalar alır. Rastgele gönderilen bu talep edilmeyen toplu e-postalara istenmeyen (spam) e-posta denir(Cormack, 2008). Symantec, 2015, 2016 ve 2017 yıllarında toplam istenmeyen e-posta oranlarının sırasıyla %52.7, %53.4 ve %54.6 olduğunu belirtmektedir(Cleary et al., 2018). Kaspersky ayrıca 2018'in üçüncü çeyreği sonunda spam e-postaların oranını %53,49 olarak bildirdi(Vergelis, Shcherbakova, Sidorina, & Kulikova, 2019).

1965 yılına dayanan Massachusetts Institute of Technology (MIT) bilgisayarlarında MAILBOX adı verilen programlar, elektronik postaların ilk örnekleridir. ARPANET tarafından ağ bağlantılı bir sistem oluşturulmuş ve 1972 yılında e-posta kullanılmaya başlanmıştır. E-postalar "kullaniciadi@bilgisayaradi" olarak tanımlanır. Birkaç yıl içinde ARPANET trafiğinin %75'i e-posta ile gönderildi. E-postanın icadı ile dünya ARPANET'ten internete geçiş yapmıştır. E-postalar, internetin keşfiyle kullanıcılara küresel düzeyde kolay bir şekilde bilgi alışverişini sağlamıştır. Basit mesaj aktarma protokolü (SMTP: Simple Mail Transfer Protocol) ilk olarak sunulan e-posta standardıdır. SMTP e-posta gönderen kişinin ilgili kişi olup olmadığını kontrol etmez. Bundan dolayı e-posta iletişimde sahtecilik, dolandırıcılık gibi birtakım sıkıntılar ortaya çıktı. SMTP protokolündeki bu basitlik virüs, sahtekarlar ve istenmeyen e-posta göndericileri tarafından kullanılmaktadır.

E-postaların kullanım kolaylığı ve aynı anda binlerce kişiye ulaşılabilmesi bazı dezavantajları da beraberinde getirmiştir. Bu dezavantajların başında istenmeyen (spam) mesajlar gelmektedir (Bhowmick & Hazarika, 2018). Maliyet ve hız avantajı sayesinde e-postalar reklam, tanıtım, pazarlama, kamuoyu oluşturma, uygunsuz içerik paylaşma, kötü amaçlı yazılımlar göndererek kişisel bilgileri elde etme gibi amaçlarla kullanılmakta ve her gün onlarca spam e-posta mail kutularına düşmektedir. Araştırma şirketlerinin birçoğunun yaptığı araştırmalarda istenmeyen e-posta oranı gittikçe artmaktadır. Bu durum kullanıcılar için zaman ve emek kaybına neden olurken, ağ trafiğinin gereksiz yere işgal edilmesine de neden olmaktadır. Ayrıca işletmeler açısından bakıldığında çok büyük mali kayıplara neden olduğu görülmektedir.

İstenmeyen e-postaları filtrelemek için birçok farklı yöntem ve teknik kullanılmakta ve başarılı sonuçlar alınmaktadır. Buna rağmen, istenmeyen e-posta kullanıcılarına uygulanan filtrelerin ya da tekniklerin üstesinden gelmek için yeni stratejiler, yöntemler geliştirerek e-posta sistemlerini kullanmaya devam ediyorlar. Bu nedenle bu alanda güncel çalışmaların yapılması, farklı yöntem ve tekniklerin geliştirilmesi, farklı veri kümelerinin oluşturulması ve analizlerin desteklenmesi esastır.

Bilgisayarlar birçok problemi çözmek için insan beyninin davranışlarından esinlenerek öğrenme, yorumlama gibi yeteneklerin makinelerle kazandırılmasını amaçlamaktadır. İstenmeyen e-postaları açığa çıkarmak için farklı yöntemler ve teknikler kullanılmaktadır. Ancak bu tür çalışmalar genellikle İngilizce veri kümeleri ile yapılmaktadır. Türkçe veri kümeleri ile ilgili çalışmalar ciddi sayıda değildir. Bunun sebebi veri kümelerinin yetersizliği ya da bu alanda çalışan araştırmacıların azlığıdır.

İstenmeyen e-postaları tespit etmek ve ayıklamak için birçok teknik bulunmaktadır. Bu teknikler genel olarak yapay zeka ve makine öğrenmesi olmak üzere iki grupta toplanabilir. Makine öğrenmesi teknikleri ise denetimli ya da denetimsiz olarak iki grupta incelenmektedir. Ancak yaygın olarak kullanılan denetimli öğrenmedir. Bir e-postanın istenmeyen e-posta ya da normal e-posta olup olmadığını tespit edebilmek için önce, her bir dokümanı sınıfına göre etiketlenmiş istenmeyen e-posta ve normal e-posta olarak geniş bir veri kümesinin hazırlanması gerekir.

Bu çalışmada ise literatürde var olan Türkçe bir veri seti kullanılarak en başarılı sınıflandırma algoritmalarını ve öznelik seçim metodlarını belirleyerek istenmeyen e-posta filtreleme çalışmalarına ve literatüre katkı sağlamayı amaçlamaktadır.

2. E-posta Sistemi ve İstenmeyen e-posta

Elektronik posta (e-posta), bir kullanıcının bir bilgisayara gönderdiği ve bir bilgisayar ağı üzerinden okuyabilen başka bir kullanıcıya ilettiği, genellikle basit bir metin, resim ya da video biçimindeki elektronik iletiye verilen addır (Altunyaprak, 2006). E-posta mesajları bir başlık ve bir gövdeden oluşur. Başlık, gönderen, alıcı, konu başlığı ve tarihi içerir.

İstenmeyen e-postalar, yabancı kişiler, zararlı yazılımlar veya bot hesapları tarafından toplu olarak gönderilen mesajlardır. Bunlar, kişinin talebi dışında e-posta hesaplarına gönderilen mesajlar olarak da tanımlanabilir. İstenmeyen e-postalar reklam, tanıtım ve propaganda gibi amaçlarla kullanıldığı gibi kişisel bilgilerin çalınması, şirketlerin sistemlerini çökertme gibi amaçlarla da kullanılabilir. Günlük hayatta e-posta adreslerimize baktığımızda, her gün onlarca reklam mesajıyla karşılaşırız ve bunların bir kısmı bilmediğimiz adreslerden geliyor. Ayrıca bazı istenmeyen iletiler, kişisel bilgilerimizi ve banka hesap bilgilerimizi ele geçirmek için virüs ya da bilgisayara zarar verebilecek bağlantı gönderebilirler. Güvenilir web adreslerini kopyalayarak ve onlara güvenmemizi sağladıklarında bilgilerimizi çalabilirler. Bugün istenmeyen iletilerle karşı karşıya kalmamızın bir başka nedeni de e-posta ticaretidir. E-posta hizmeti sunan firmalar genellikle ücretsiz olarak sunmaktadır. Ancak bu

hizmeti sunarken başta e-posta adresi olmakla birlikte birçok veriye erişim sağlayabilmektedir. Milyonlarca kişiye ait e-posta adresleri farklı işletmelere pazarlanmakta ve tanımadığımız firmalardan istenmeyen mesajlar almamıza neden olmaktadır. Firmalar, her zaman müşterileriyle daha erişilebilir, daha ucuz veya daha hızlı iletişim kurmanın yollarını ararken, internette var olan e-posta hizmetiyle her üçünü de sunar. Bu durumda, e-posta adreslerinin pazarlanması, istenmeyen e-posta sayısındaki artışın nedenlerinden bir tanesidir.

İstenmeyen e-postaları incelerken bazı ortak özellikleri bulunmaktadır. Bunlar;

- İçerikleri günceldir.
- İnsani duygular hakkında konuşabilirler ve e-postanın birçok kişiye iletilmesini isteyebilirler.
- Çoğu zaman içerikleri yanıltıcıdır.
- Tanıtım amaçlı gönderilmektedir.

Günümüzde birçok farklı yöntem kullanılmakta ve istenmeyen (spam) e-postaları filtrelemek için yeni teknikler geliştirilmektedir. Bu yöntemlerden bazıları Kelime Filtreleme, Kural Tabanlı Filtreleme, Kara Listeler ve Antivirüs Taramadır.

3. Hedef ve Katkı

Günümüzde internet teknolojilerinin ilerlemesi hayatımıza büyük kolaylıklar getirse de bu kolaylıkların yanında bazı sıkıntıları da beraberinde getirmektedir. E-posta, internetin gelişmesiyle hayatımıza girmiş ve iletişime farklı bir boyut kazandırmıştır. Kişiler arası belgeler, resimler ve ses ya da video dosyaları gibi birçok veri e-posta yoluyla hızlı ve ucuz bir şekilde paylaşılabilir. Bununla birlikte, e-posta hizmetlerinin kullanımıyla istenmeyen e-postalar ile karşılaşırız. Bu durumda kişilerin zamanını, iş verimini veya kişisel bilgilerini tehlikeye atma gibi durumlarla karşı karşıya kalıyoruz.

Bu sorunlardan kaçınmak için yeni yöntemler geliştirmek, yeni veri kümeleri oluşturmak, mevcut yöntemleri farklı veri kümeleri ile test etmek ve başarılı performans elde etmek büyük önem taşımaktadır. Bu çalışmada farklı sınıflandırma algoritmalarının test edilmesi ve daha önce literatürde kullanılan Türkçe içerikli bir veri kümesini farklı ve güncel öznitelik seçim metotları kullanılarak en başarılı sınıflandırma yönteminin seçilmesi amaçlanmıştır.

4. Literatür İncelemesi

İngilizce yazılmış istenmeyen e-postaları filtrelemek için birçok çalışma(Sharma & Kaur, 2016; Venkatraman, Surendiran, & Kumar, 2019) olmasına rağmen, İngilizce'den çok daha karmaşık bir morfolojik yapıya sahip sondan eklemeli bir dil olan Türkçe ile yapılan bu tür çalışmalar nispeten azdır(Dedetürk & Akay, 2020; Ergin & Isik, 2014; Ozgur, Gungor, & Gungen, 2004).

Özgür ve arkadaşları(Özgür, Güngör, & Gungen, 2004), Türkçe dili için spesifik olarak, Türkçe e-postaları sınıflandırmak ve uygulamalı iki farklı sınıflandırıcı için bir kök bulma operatörü kullandı ve yaklaşık %90'lık bir başarı oranı elde etti. Tunga ve Kitik(Güngör & Çıltık, 2007), n-gram yöntemine ve ilk n-kelime sezgisel yöntemine dayalı yöntemler önerdiler. Elde ettikleri yaklaşımla en iyi başarı oranları, bir Türk veri seti için yaklaşık %97 olmuştur.

Bir başka çalışmada(Renuka, Visalakshi, & Sankar, 2015), önerilen sistemde spam sınıflandırması, daha karmaşık sınıflandırma problemleri için geçerli olan koşullu olasılığa dayalı olasılıklı bir sınıflandırıcı olan Naive Bayes sınıflandırıcısı kullanılarak gerçekleştirilmiştir. Hibrit Karınca Kolonisi Optimizasyonu kullanılarak öznitelik seçiminin uygulanması, bu çalışmada önerilen sistem için iyi sonuçlar veren ve verimli olmaya da hizmet eder.

Ates(Ates, 2014) çalışmasında hem Türkçe hem de İngilizce veri kümesi kullanarak istenmeyen e-postaları tespit eden denetimli öğrenme algoritması Destek Vektör Makineleri ve denetimsiz öğrenme algoritması Gauss Karışım Modellerinin kullanıldığı içerik tabanlı iki farklı filtreleme yöntemi gerçekleştirilmiştir.

Deniz ve arkadaşları(Deniz, Erbay, & Coşar, 2019) TurkishEmail e-posta veri kümesini kullanarak öznitelik çıkarımı yapılmış ve Doc2Vec kütüphanesine ait algoritmalar kullanılmıştır. Doc2Vec, Distributed Bag of Word (DBoW) ve Distributed Memory (DM) olarak adlandırılan iki farklı algoritma içermektedir. Altı farklı örüntü sınıflandırıcı ile sınıflandırma yapılmıştır. En yüksek performans DBoW+DM öznitelik seçimi ve destek vektör makinesi makine öğrenmesi ile %78,75 skoru ortaya çıkmıştır.

Karamollaoğlu ve arkadaşları(Karamollaoğlu, Dogru, & Dorterler, 2018), makine öğrenmesi yöntemlerinden Naive Bayes Sınıflandırıcı ve Vektör Uzay Modeli yardımıyla Türkçe yazılmış e-postaların içerik bilgilerinin analiz edilmesi, bu e-postaların spam e-posta olup olmadığının belirlenmesi ve sınıflandırılması amaçlanmıştır. Her iki yöntem de farklı değerlendirme kriterlerine tabi tutulmuş ve performansları karşılaştırılmıştır. Deneysel sonuçlar, Naive Bayes Sınıflandırıcısı metodunun Vektör Uzay Modeline göre daha yüksek performans göstermiştir.

Kaynar ve arkadaşları(Kaynar, Görmez, & Işık, 2016), diğer çalışmalardan farklı olarak istenmeyen e-postaların sınıflandırılması için modern makine öğrenmesi yaklaşımlarından biri olan otomatik kodlayıcı tabanlı bir derin öğrenme makinesi önerilmiştir. Otomatik kodlayıcılar aslında giriş ve çıkışların aynı veri kümesine sahip olduğu çok katmanlı algılayıcılardır. Otomatik kodlayıcı derin öğrenme makinesini kullanan sınıflandırıcının, %98 doğru sınıflandırma gibi son derece yüksek bir başarı oranına sahip olduğu gösterilmiştir.

Eryılmaz ve diğerleri(Eryılmaz, Şahin, & Kılıç, 2020), Türkçe veri kümesi (TurkishEmail) üzerinde Keras derin öğrenme kütüphanesi ile istenmeyen e-posta tespiti yapmışlardır. Türkçe e-posta veri kümesi, yarısı istenmeyen e-posta olmak üzere 800 e-posta içermektedir. Derin öğrenme algoritması uzun kısa süreli bellek (LSTM_Long Short Term Memory) ile Türkçe e-posta veri setinde %100 doğruluk oranı elde edilmiştir. Bir diğer çalışmalarında(Eryılmaz, Şahin, & Kılıç, 2020), 800 adet Türkçe e-posta veri seti üzerinde 7 farklı makine öğrenme yöntemi kullanılarak istenmeyen e-posta tespit edilmesi sağlanmıştır. Geliştirilen yöntemde ki-kare testi ile öznitelik seçimi yapıldığında en iyi sonuç Sıralı Minimal Optimizasyon (SMO) algoritmasından alınmaktadır. Bilgi kazanımı (Information gain) yöntemi ile öznitelik seçimi yapıldığında en iyi sonuç Multi Layer Perceptron (MLP) algoritmasından alınmaktadır. SMO ve MLP algoritmalarından elde edilen performans sonuçları F-ölçütüne göre sırasıyla 0.985 ve 0.984'tür.

Ergin ve arkadaşları(Ergin, Sora Gunal, Yigit, & Aydin, 2012), metin tabanlı Türkçe spam e-postaları (önemsiz e-posta veya toplu e-posta) belirlemek için bir Türkçe anti-spam filtresi uyguladılar. Çalışmada, Türkçe istenmeyen ve normal e-posta örneklerini içeren bir veri tabanı oluşturulmuştur. Her bir e-postanın içeriği analiz edildi ve tüm e-postalardan geçen farklı kelimeler belirlendi. Her bir e-postanın içeriği analiz edildi ve tüm e-postalardan geçen farklı kelimeler belirlendi. Daha sonra farklı kelimelerin kök hallerini elde etmek için Türkçeye özgü bir kök çıkarma işlevi kullanılmıştır. Farklı kelimelerin Karşılıklı Bilgi (MI= Mutual Information) skorları hesaplandı, böylece MI skorlarına göre iki tür öznitelik vektörü oluşturuldu. Bu işlemin ardından Bayesian sınıflandırıcısının ikili ve olasılık tabanlı modelleri test edilmiş, ikili ve olasılık tabanlı modellerin başarı oranları karşılaştırılmıştır.

Venkatraman ve arkadaşları(Venkatraman, Surendiran, & Kumar, 2020), istenmeyen e-posta tespitinde çokanlamlılık yoluyla ortaya çıkan belirsizlikle mücadele etmek için Naive Bayes sınıflandırmasının kavramsal ve anlamsal benzerlik tekniği ile entegrasyonunu önerdiler. Yaklaşımın etkinliğini analiz etmek için deneyler, Spambase, PU1, Enron1 ve Lingspam gibi karşılaştırmalı veri kümeleri üzerinde yapıldı. Deneysel sonuçlardan, önerilen sistemin mevcut yaklaşımlardan %98.89 gibi yüksek bir doğruluk elde ettiği açıktır.

Bir başka çalışmada(Bhuiyan, Ashiquzzaman, Juthi, Biswas, & Ara, 2018), Naive Bayes, DVM, K-En Yakın Komşuluk, Bayes Eklemeli Regresyon, KNN Ağacı ve kurallar gibi Makine Öğrenimi Tekniği (MLT=Machine Learning Techiques) ile ilgili mevcut farklı e-posta spam filtreleme sistemine ilişkin bir anketi göstermektedir. Ancak bu çalışmada, farklı istenmeyen e-posta filtreleme sisteminin sınıflandırmasını, değerlendirmesini ve karşılaştırmasını sunulmakta ve mevcut farklı yaklaşımların doğruluk oranıyla ilgili genel senaryo özetlenmektedir.

Bhowmick ve arkadaşları(Bhowmick & Hazarika, 2018), en yeni ve başarılı içerik tabanlı istenmeyen e-posta filtreleme tekniklerinin kapsamlı bir incelemesini sundular. Odak noktaları, temel olarak makine

öğrenimi tabanlı spam filtreleri ve bunlardan ilham alan türevleridir. Teknikleri, değerlendirme ölçütlerini inceleyerek ve en son gelişmelerin gelecek vaat eden dallarını keşfederek ve gelecekteki araştırmalar için önerilerde bulunarak sonuca vardılar.

Subasi ve arkadaşları(Subasi, Alzahrani, Aljuhani, & Aljedani, 2018), basit ve daha iyi doğruluk sağlayan karar ağacı algoritmalarına dayalı istenmeyen e-posta filtrelemesi için bir yaklaşım önerdiler. Deneysel sonuçlardan, önerilen rastgele orman sınıflandırıcısı, herkese açık veri kümeleri için diğer karar ağacı yöntemlerinden daha iyi performans göstermiştir.

5. Öznitelik Çıkarımı ve Seçim Teknikleri

5.1. Öznitelik Çıkarımı:

Metin sınıflandırma çalışmalarında öznitelik çıkarma işlemi için kelime çantası yaklaşımı(BoW= Bag of Words)(Parlak & Uysal, 2021) kullanılan yöntemlerden bir tanesidir. Bu yaklaşımda, dokümanlardaki terimlerin sırası göz ardı edilirken, bunların oluşum sıklıkları yani frekansları kullanılır. Bu nedenle, bir metin koleksiyonundaki benzersiz kelimelerin her biri farklı bir öznitelik olarak kabul edilir. Sonuç olarak, bir doküman çok boyutlu bir öznitelik vektörü(Parlak & Uysal, 2015) ile temsil edilir. Bir öznitelik vektöründe, her boyut, terim frekansı (TF) ya da terim frekansı-ters doküman frekansı (TF-IDF) vb. ile ağırlıklandırılmış bir değere karşılık gelir(Parlak & Uysal, 2018).

Ayrıca metin dokümanlarından öznitelik çıkarımı sırasında bazı ön-işleme(Uysal & Gunal, 2014) adımlarının uygulanmasının performans açısından gerekli olduğu da unutulmamalıdır. Yaygın olarak kullanılan ön işleme adımları, “durak ya da gereksiz kelimelerin kaldırılması” ve “kök bulma” algoritmasıdır. Bu çalışmada, ön-işleme adımlarının her ikisi de uygulanmıştır. Kök bulma için Zemberek kök bulma algoritması(Akın & Akın, 2007) ve ağırlıklandırma yaklaşımı olarak terim frekansı-ters doküman frekansı(TF-IDF) kullanıldı.

5.2. Öznitelik Seçimi:

Öznitelik seçim teknikleri genellikle üç kategoriye ayrılır: filtreler, sarmalayıcılar ve gömülü yöntemler. Filtre teknikleri hesaplama açısından hızlıdır; ancak, genellikle öznitelik bağımlılıklarını dikkate almazlar. Filtre tabanlı teknikler özellikle metin sınıflandırma alanı için yaygın olarak tercih edilmektedir. Metin sınıflandırmasında ayırt edici özniteliklerin seçimi için çok sayıda filtre tabanlı teknik vardır. Bu çalışmada, Gini İndeksi (GI), Max-Min Oranı(MMR=Max-Min Ratio) ve Kapsamlı Öznitelik Seçici(EFS= Extensive Feature Selector) olmak üzere 3 farklı öznitelik seçim tekniği kullanılmıştır. Tablo 1’de bu yöntemlerin formüllerinde geçen notasyonlar açıklanmıştır. Ayrıca, yöntemler aşağıda ayrıntılı olarak açıklanmıştır:

Tablo 1. Öznitelik seçim yöntemleri için notasyonlar

Notasyon	Anlamı
$p(t C_j)$	C_j sınıfı mevcut olduğunda t teriminin olasılığı
$p(\bar{t} C_j)$	C_j sınıfı mevcut olduğunda t teriminin olmama olasılığı
$p(t \bar{C}_j)$	C_j sınıfı mevcut olmadığına t teriminin olma olasılığı
$p(\bar{t} \bar{C}_j)$	C_j sınıfı mevcut olmadığına t teriminin olmama olasılığı
$p(C_j t)$	t terimi mevcut olduğunda C_j sınıfının olma olasılığı
$p(\bar{C}_j t)$	t terimi mevcut olduğunda C_j sınıfının olmama olasılığı
$p(C_j \bar{t})$	t terimi mevcut olmadığına C_j sınıfının olma olasılığı
$p(\bar{C}_j \bar{t})$	t terimi mevcut olmadığına C_j sınıfının olmama olasılığı

5.2.1. Gini İndeksi(GI):

GI, karar ağaçlarındaki en iyi öznitelik dağılımını bulmak için orijinal olarak kullanılan yöntemin geliştirilmiş bir versiyonudur(Singh, Murthy, & Gonsalves, 2010). Doğru ve hızlı bir yöntemdir. Formülü aşağıdaki gibidir:

$$GI(t) = \sum_{j=1}^M P(t|c_j) * P(c_j|t) \quad (1)$$

5.2.2. Max-Min Oranı(MMR):

MMR(Rehman, Javed, Babri, & Asim, 2018), yüksek oranda çarpık sınıflar dahil olmak üzere veri kümelerinde daha iyi performans sağlar. Yöntem, doğru pozitiflerin, yanlış pozitiflerin ve bunların farklarının birleşimidir. Yönteme göre öznitelik skoru aşağıdaki gibi hesaplanmaktadır:

$$MMR(t) = \sum_{j=1}^M \frac{|P(t|c_j) - P(t|\bar{c}_j)|}{\min(P(t|c_j), P(t|\bar{c}_j))} \cdot \max(P(t|c_j), P(t|\bar{c}_j)) \quad (2)$$

5.2.3. Kapsamlı Öznitelik Seçici(EFS):

EFS(Parlak & Uysal, 2021), özniteliğin sınıf tabanlı ve derlem tabanlı ayırt ediciliği dikkate alınarak öznitelik seçimi yapmaktadır. Bu, önerilen yöntemin bir terimin önemini hem sınıf tabanlı olasılıklardan hem de derlem tabanlı olasılıklardan hesapladığı anlamına gelir. Özniteliğin sınıf tabanlı ve derlem tabanlı ayırt ediciliği dikkate alındığında; Kapsamlı Özellik Seçici (EFS) formülü aşağıdaki gibidir:

$$EFS(t) = \sum_{j=1}^M \left(\frac{P(t|c_j)}{P(\bar{t}|c_j) + P(t|\bar{c}_j) + 1} \right) \cdot \left(\frac{P(c_j|t)}{P(\bar{c}_j|t) + P(c_j|\bar{t}) + 1} \right) \quad (3)$$

6. DeneySEL Çalışmalar

Bu bölümde, öznitelik seçme yöntemlerinin ve sınıflandırıcıların performansını ölçmek için derinlemesine bir araştırma yapılmıştır. Bu amaçla, ilgili veri seti için en iyi kombinasyonu belirlemek amacıyla öznitelik seçim yöntemlerinin Naive Bayes, k-EYK ve DVM sınıflandırıcıları ile kombinasyonları analiz edilmiştir. Ayrıca, boyutların performansa etkisi deneysel sonuçlara göre çıkarılabilir. Aşağıdaki alt bölümlerde, kullanılan veri kümeleri ve başarı ölçütleri kısaca açıklanmıştır. Daha sonra deneysel sonuçlar sunulmuştur.

6.1. Veri Kümesi:

Bu çalışmada “TurkishEmail” (TürkçeE-posta)(Ergin et al., 2012) veri kümesi kullanılmıştır. Normal ve istenmeyen e-postalardan oluşan bu veri kümesinde toplam 800 adet e-posta yer almaktadır. Bu veri kümesine ait eğitim ve test verilerinin dağılımı aşağıdaki Tablo 2’de yer almaktadır.

Tablo 2. TurkishEmail Veri Kümesinin Dağılımı

	Eğitim	Test
Normal	300	100
İstenmeyen	300	100

6.2. Doğruluk Analizi:

Her bir seçim yöntemiyle seçilen özniteliklerin farklı boyuttaki vektörleri NB, k-EYK ve DVM sınıflandırıcılarıyla beslenmiştir. Deneylerde, gereksiz kelime kaldırma ve kök çıkarma uygulandı. Yaygın olarak bilinen Zemberek kök bulma, kök bulma algoritması olarak gerçekleştirilmiştir. Bu çalışmada öznitelik seçim yöntemi olarak GI, MMR ve EFS kullanılmıştır. Toplam öznitelik sayısı 18.650 adet açığa çıkmıştır. Ancak boyu olarak; 100, 250, 500 ve 1000 şeklinde öznitelik vektörleri oluşturularak boyut küçültme gerçekleştirilmiştir. Ayrıca başarı ölçüsü olarak F skoru(Goutte & Gaussier, 2005) kullanıldı. Bu skor sınıfa özel şeklinde değil ağırlıklı olarak sunulmaktadır. Elde edilen F-Skorları Tablo 3-4-5’te listelenmiştir. Sonuçlarda en iyi olanlar kalın olarak gösterilmiştir.

En yüksek ağırlıklı ortalama F skorları göz önüne alındığında, çoğu durumda GI, MMR ve EFS metodlarından daha yüksek performans göstermiştir. GI hem NB hem de k-EYK sınıflandırıcıda en yüksek performansa sahipken, MMR ise DVM sınıflandırıcıda en yüksek performansı göstermiştir. Bununla birlikte, öznitelik boyutu düşük olduğunda GI daha başarılı görünmektedir. Ancak MMR ve EFS daha yüksek boyutlarda daha yüksek performans sergilediği gözlenmiştir.

Sınıflandırma algoritmalarının performansları göz önüne alındığında, k-EYK, NB ve DVM sınıflandırıcılarından daha yüksek performans sergilemiştir. Boyutlar bazında bakıldığında k-EYK ve

NB farklı boyutlarda farklı öznitelik seçim kombinasyonu ile en yüksek performansı sergilemektedirler. Ancak, DVM en yüksek performansı genellikle MMR kombinasyonu ile göstermiştir.

Tablo 3. Naive Bayes Sınıflandırıcı ile Türkçe e-posta(Turkish) veri kümesi için F skorları

Türkçe e-posta	100	250	500	1000
GINI	0.991	0.920	0.809	0.826
MMR	0.915	0.915	0.980	0.894
EFS	0.980	0.930	0.809	0.831

Tablo 4. k-EYK Sınıflandırıcı ile Türkçe e-posta veri kümesi için F skorları (k = 5)

Türkçe e-posta	100	250	500	1000
GINI	0.990	0.970	0.960	0.970
MMR	0.975	0.925	0.980	0.975
EFS	0.970	0.970	0.965	0.970

Tablo 5. DVM Sınıflandırıcı ile Türkçe e-posta veri kümesi için F skorları (linear version)

Türkçe e-posta	100	250	500	1000
GINI	0.955	0.930	0.925	0.920
MMR	0.940	0.980	0.945	0.940
EFS	0.935	0.925	0.925	0.920

7. Sonuçlar

Bu çalışmada, yaygın olarak bilinen üç sınıflandırıcının performansları, üç farklı öznitelik seçim yöntemi kullanılarak kapsamlı bir şekilde analiz edilmiştir. Bu analiz, Türkçe e-posta dokümanlarından oluşan veri kümesi üzerinde gerçekleştirilmiştir. Deneylerde, ön işleme adımları olarak gereksiz kelimeleri kaldırma ve kök çıkarma uygulanmıştır. Deneysel sonuçlar, en başarılı ayarın NB sınıflandırıcı ve GI Öznitelik Seçici kombinasyonu ile elde edilmiştir. Gelecekteki bir çalışma olarak, bu alanda yeni bir Türkçe e-posta veri kümesi kazandırmak ve farklı öznitelik seçim teknikleriyle analiz edilecektir.

Kaynaklar

- Akın, A. A., & Akın, M. D. (2007). Zemberek, an open source NLP framework for Turkic languages. *Structure*, 10, 1-5.
- Altunyaprak, C. (2006). *Bayes yöntemi kullanarak istenmeyen elektronik postaların filtrelenmesi*. Yüksek Lisans Tezi, Muğla Üniversitesi Fen Bilimleri Enstitüsü.
- Ates, N. (2014). Support vector machine and gauss mixture model detection of unsolicited e-mails. *Master's thesis, Suleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı*.
- Bhowmick, A., & Hazarika, S. M. (2018). E-Mail Spam Filtering: A Review of Techniques and Trends *Advances in Electronics, Communication and Computing* (pp. 583-590): Springer.
- Bhuiyan, H., Ashiquzzaman, A., Juthi, T. I., Biswas, S., & Ara, J. (2018). A survey of existing e-mail spam filtering methods considering machine learning techniques. *Global Journal of Computer Science and Technology*.
- Cleary, G., Corpin, M., Cox, O., Lau, H., Nahorney, B., O'Brien, D., . . . Wood, P. (2018). Internet security threat report. *Symantec Corporation, California, USA, Tech. Rep.*
- Cormack, G. V. (2008). Email spam filtering: A systematic review. *Foundations and Trends® in Information Retrieval*, 1(4), 335-455.

- Dedetürk, B. K., & Akay, B. (2020). Spam filtering using a logistic regression model trained by an artificial bee colony algorithm. *Applied Soft Computing*, 91, 106229.
- Deniz, E., Erbay, H., & Coşar, M. (2019). Türkçe e-postaların Doc2Vec ile sınıflandırılması.
- Ergin, S., & Isik, S. (2014). *The assessment of feature selection methods on agglutinative language for spam email detection: A special case for Turkish*. Paper presented at the 2014 IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA) Proceedings.
- Ergin, S., Sora Gunal, E., Yigit, H., & Aydin, R. (2012). Turkish anti-spam filtering using binary and probabilistic models. *Global Journal on Technology*, 1.
- Eryılmaz, E. E., Şahin, D. O., & Kılıç, E. (2020). *Machine learning based spam e-mail detection system for Turkish*. Paper presented at the 2020 5th International Conference on Computer Science and Engineering (UBMK).
- Eryılmaz, E. E., Şahin, D. Ö., & Kılıç, E. (2020). *Filtering turkish spam using LSTM from deep learning techniques*. Paper presented at the 2020 8th International Symposium on Digital Forensics and Security (ISDFS).
- Goutte, C., & Gaussier, E. (2005). *A probabilistic interpretation of precision, recall and F-score, with implication for evaluation*. Paper presented at the European conference on information retrieval.
- Güngör, T., & Çıltık, A. (2007). *Developing methods and heuristics with low time complexities for filtering spam messages*. Paper presented at the International Conference on Application of Natural Language to Information Systems.
- Karamollaoglu, H., Dogru, İ. A., & Dorterler, M. (2018). *Detection of Spam E-mails with Machine Learning Methods*. Paper presented at the 2018 Innovations in Intelligent Systems and Applications Conference (ASYU).
- Kaynar, O., Görmez, Y., & Işık, Y. (2016). Oto Kodlayıcı Tabanlı Derin Öğrenme Makinaları İle Spam Tespiti. *Uluslararası Yönetim Bilişim Sistemleri Konferansı*, 44.
- Ozgun, L., Gungor, T., & Gurgen, F. (2004). Adaptive anti-spam filtering for agglutinative languages: a special case for Turkish. *Pattern Recognition Letters*, 25(16), 1819-1831. doi:<http://dx.doi.org/10.1016/j.patrec.2004.07.004>
- Özgür, L., Güngör, T., & Gürgen, F. (2004). Adaptive anti-spam filtering for agglutinative languages: a special case for Turkish. *Pattern Recognition Letters*, 25(16), 1819-1831.
- Parlak, B., & Uysal, A. K. (2015). *Classification of medical documents according to diseases*. Paper presented at the 23rd Signal Processing and Communications Applications Conference (SIU).
- Parlak, B., & Uysal, A. K. (2018). On feature weighting and selection for medical document classification *Developments and Advances in Intelligent Systems and Applications* (pp. 269-282): Springer.
- Parlak, B., & Uysal, A. K. (2021). A novel filter feature selection method for text classification: Extensive Feature Selector. *Journal of Information Science*, 0165551521991037.
- Rehman, A., Javed, K., Babri, H. A., & Asim, N. (2018). Selection of the most relevant terms based on a max-min ratio metric for text classification. *Expert Systems with Applications*, 114, 78-96.
- Renuka, D. K., Visalakshi, P., & Sankar, T. (2015). Improving E-mail spam classification using ant colony optimization algorithm. *Int. J. Comput. Appl*, 22, 26.
- Sharma, R., & Kaur, G. (2016). E-Mail Spam Detection Using SVM and RBF. *International Journal of Modern Education and Computer Science (IJMECS)*, 8(4), 57.
- Singh, S. R., Murthy, H. A., & Gonsalves, T. A. (2010). Feature Selection for Text Classification Based on Gini Coefficient of Inequality. *Fsdm*, 10, 76-85.
- Subasi, A., Alzahrani, S., Aljuhani, A., & Aljedani, M. (2018). *Comparison of decision tree algorithms for spam e-mail filtering*. Paper presented at the 2018 1st International Conference on Computer Applications & Information Security (ICCAIS).
- Uysal, A. K., & Gunal, S. (2014). The impact of preprocessing on text classification. *Information Processing & Management*, 50(1), 104-112.
- Venkatraman, S., Surendiran, B., & Kumar, P. A. R. (2019). Spam e-mail classification for the Internet of Things environment using semantic similarity approach. *The Journal of Supercomputing*, 1-21.

- Venkatraman, S., Surendiran, B., & Kumar, P. A. R. (2020). Spam e-mail classification for the internet of things environment using semantic similarity approach. *The Journal of Supercomputing*, 76(2), 756-776.
- Vergelis, M., Shcherbakova, T., Sidorina, T., & Kulikova, T. (2019). Spam and phishing in 2018. *Secure List*.

Predicting Sleep Routines After COVID-19 Using Machine Learning Methods

Baris Cincioglu, Kaan Ozdemir, Kagan Can Sit, Osman Altay⁽⁰⁰⁰⁰⁻⁰⁰⁰³⁻³⁹⁸⁹⁻²⁴³²⁾

Software Engineering Department, Manisa Celal Bayar University, Manisa, Turkey

(baris.cincioglu@outlook.com, kaanzzdemir@gmail.com, kagancansit@hotmail.com, osman.altay@cbu.edu.tr)

Abstract: Due to the COVID-19 pandemic, many individuals have been subjected to an unprecedented stressful situation under house arrest. Not only does this increase levels of daytime stress, anxiety, and depression, it also disrupts sleep. More importantly, because sleep is so important in emotion regulation, sleep disruption can have a direct impact on emotional functioning the next day. In this study, sleep pattern machine learning methods were predicted in the data set created by considering 22 different questions that may affect sleep patterns. Naive Bayes and k-nearest neighbor algorithms from machine learning methods were used. The study showed that the k-nearest neighbor algorithm performs much better in predicting sleep patterns.

Keywords: *Sleep Routine, Machine Learning, Naive Bayes Algorithm, K-Nearest Neighbor Algorithm*

1. Introduction

There are many natural human-wants that people need to continue their daily life. One of the most important of these is sleep. Sleep is one of the basic needs of human life. Physiologically, socially, and mentally, people need sleep in their lives. To meet this need in a healthy way, it is necessary for a person to devote 1/3 of the day to sleep (Özkaya et al., 2013; Aysan et al., 2014). US experts reviewed 320 studies and suggested that adults up to the age of 64 can lead a healthy life with 7-9 hours of sleep. For people over 65, they recommend 7-8 hours of sleep (Hirshkowitz et al., 2015). Various studies have revealed that when animals are deprived of sleep, they are faced with many pathophysiological events that will endanger their lives, and sleep has a very important place in the lives of animals (Karadağ and Aksoy, 2009).

The concept of sleep quality includes the depth and restfulness of sleep as well as considering the time it takes a person to fall asleep, the duration of sleep, and the number of awakenings per night. The duration of time to fall asleep is defined as the time from the moment the lights are turned off to the moment of falling asleep. Sleep time is the total time spent asleep. Effective sleep is calculated as the ratio of sleep time to the time spent in bed (Temel et al., 2013). There is a direct connection between sleep routine and sleep quality. Sleep routine, time to fall asleep, effective sleep, and sleep time are all. If a person feels sleepless, they are likely to have sleep problems such as early waking, irregular sleep, late falling, and unsustainable sleep (Temel et al., 2013).

The whole world has recently been affected by the COVID-19 pandemic. As a result, online education has gained importance around the world (Kruszewska et al., 2022). Pandemic conditions, which are also prevalent throughout our country, have forced students to take online education. Online meetings are not limited to students only; they have changed the lives of teachers, desk workers, and many professional groups. The disruption of people's working orders has also led to the deterioration of their sleep routines (Altena et al., 2020).

In this study, it was tried to predict sleep routines by using machine learning methods. The Naive Bayes (NB) and K-Nearest Neighbor Algorithm (KNN) were used. In Section 2, information about how the data set was obtained, the variety of questions asked, and the tools used in obtaining the data set were given. In Section 3, the machine learning methods used in the paper are explained in detail. In Section 4, the experimental results of the paper are given. Finally, the conclusions and future studies are included.

2. Data Acquisition

In this study, the dataset was obtained by means of a questionnaire. The 23 specially selected questions were asked to the participants who filled out the questionnaire. The questions were chosen according to the factors that may affect regular sleep; In general, it consists of general characteristics such as age, weight and height, and many different qualities such as the time people prefer to sleep, nutrition and water drinking habits. In addition, there are qualities, such as smoking, drinking alcohol, and drug use that affect sleep routines. The dataset was created using Microsoft Forms. Among the people who participated in the survey, those between the ages of 18-35 were selected. More than 95% of those chosen are undergraduate students who received their education online during the COVID-19 period. The questions and the trend of the dataset are given in Table 1. Table 1 shows the mean, standard deviation (SD), median, mode, maximum value (Max) and minimum values (Min) for each attribute.

Table 1. Statistical representation of answers in the data set

Questions	Mean	SD	Median	Mode	Max	Min
Age	21.85	3.01	21.0	21	35	18
Height	173.68	10.44	175.0	180	200	150
Weight	70.31	17.17	69.0	80	150	40
Gender	0.38	0.49	0.0	0	1	0
Write down your average sleep time in hours.	7.25	1.56	7.0	8	12	2
The period you prefer to sleep	0.91	0.29	1.0	1	1	0
Marital status	0.05	0.22	0.0	0	1	0
Rate your overall sleep quality	5.74	1.82	6.0	7	10	1
Are you waking up with an alarm?	1.64	1.01	2.0	1	3	0
Rate the comfort of your bed.	6.65	2.34	7.0	8	10	1
How much water do you drink on average per day?	1.31	1.01	1.0	1	4	0
How healthy do you think you are eating?	1.83	0.76	2.0	2	4	0
Which meals do you usually prefer?	2.34	1.27	3.0	1	4	0
How many steps do you take on average per day?	0.92	0.89	1.0	1	3	0
Do you work out regularly?	0.25	0.43	0.0	0	1	0
How much time do you spend on social media per day?	1.19	0.67	1.0	1	2	0
How much time do you spend on digital games per day?	0.67	0.78	0.0	0	2	0
Is there any medicine you use regularly?	0.2	0.4	0.0	0	1	0
Give a number to the average daily caffeine consumption (1-Less, 10- Much)	4.16	2.91	3.0	1	10	1
How stressful is your life in general?	3.68	1.03	4.0	3	5	1
Do you smoke?	0.37	0.48	0.0	0	1	0
Do you drink alcohol?	0.34	0.47	0.0	0	1	0
Do you have a regular sleep routine?	0.46	0.5	0.0	0	1	0

3. Methods of Machine Learning

Machine learning is a subfield of artificial intelligence and computer science that focuses on the use of algorithms to make smart decisions based on data for a variety of purposes, including imitating how humans learn, perceiving complex patterns, understanding the problem basis, numerical predictions, and

inferences. In this study, commonly used NB and KNN were used for classification. In the following section, these methods are explained in detail.

3.1. Naive Bayes Algorithm

Bayes theorem is an important subject studied in probability theory (Altay et al., 2019). The NB is a probabilistic approach to the pattern recognition problem that can be used with a proposition that seems rather restrictive at first glance. This proposition is that each descriptive attribute or parameter to be used in pattern recognition should be statistically independent. Although this proposition limits the use of the NB, it can find effective solutions to different problems when used by stretching the statistical independence condition. NB is a simplified version of Bayes theorem with an independence proposition. Bayes theorem is expressed by the following Eq. 1:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (1)$$

Special names are given to each term in the Bayes theorem formula:

- The term $P(A)$ is called the prior probability or marginal probability for A . This is a priori because it does not contain any prior information about event B .
- Given the term $P(A|B)$ is called the conditional probability of A for B .
- Given the term $P(B|A)$ is called the conditional probability of B for A .
- The term $P(B)$ is the 'prior' probability for event B , or the marginal probability of B , and is a constant that normalizes the mathematical role.

We can explain Bayes theorem of this form, without being too mathematical, based on intuition as follows. Bayes theorem reveals how beliefs about observation A can be updated if B is observed.

Let's have a new data named X that we don't know which class it belongs to. Let X be the properties of our data $\{X_1, X_2, X_3, \dots, X_n\}$. Assuming we have a training set named C and there is m $\{C_1, C_2, C_3, \dots, C_n\}$ classes in this training set:

According to Bayes theorem, the equation of probability of occurrence of event C_i when X event occurs (2) is as follows (Altay et al., 2019):

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \quad (2)$$

Simplification for probability $P(X)$ can be applied to get faster results during calculation. If we want to simplify, the following Eq. 3 can be used, considering that the X_i values are independent of each other.

$$P(C_i|X) = P(X|C_i) P(C_i) \quad (3)$$

During this process, if all the features are independent, then Eq. 3 should be used as follows:

$$P(X|C_i) = \prod_{k=1}^n P(x_k|C_i) = P(x_1|C_i) \times P(x_2|C_i) \times \dots \times P(x_n|C_i) \quad (4)$$

X , whose class we want to learn, can be assigned to the class to which it belongs by using only the numerator values, since the denominators in $P(C_i|X)$ are equal. By choosing the largest denominator because of the values obtained, it can be easily determined by using Eq. 5 which class it belongs to.

$$\text{argmax} = \{P(X|C_i)P(C_i)\} \quad (5)$$

3.2. K-Nearest Neighbor Algorithm

KNN is a non-parametric supervised learning algorithm. It is a type of classification where the function is only locally approximated and all calculations are deferred until function evaluation (Altay et al., 2020). Because this algorithm uses distance to classify, normalizing the training data can improve performance in how well it works if the features come in different sizes or represent different physical units.

The output of the KNN is a class membership. An object is classified by the plural of its neighbors, and the object is assigned the class most common among its KNN (k is a positive integer, typically small) (Altay et al., 2022). If $k = 1$, the object is simply assigned the class of its nearest neighbor. In

the KNN, we have used, Minkowski (Eq. 6) and Euclidean (Eq. 7) distances are used. Equations 6 and 7 are given below.

$$(\sum_{i=0}^k (|x_i - x_i|)^q)^{\frac{1}{q}} \quad (6)$$

$$\sqrt{\sum_{i=0}^k (x_i - y_i)^2} \quad (7)$$

3.3. Evaluation Metrics

In the field of machine learning, and especially in the statistical classification problem, a confusion matrix, also known as an error matrix, is a special tabular layout that allows the performance of an algorithm to be visualized. An example (Table 2) is a confusion matrix:

Table 2. Confusion Matrix

		Predict Condition	
		Positive	Negative
Actual Condition	Positive (P)	True Positive (TP)	False Negative (FN)
	Negative (N)	True Positive (FP)	False Negative (TN)

In the article, sensitivity, specificity, accuracy, balanced accuracy, and f1-score, which are commonly used evaluation metrics for evaluation of classification algorithms, were used. Their equations are given in Eqs. 8–12, respectively.

$$Sensitivity = \frac{TP}{P} = \frac{TP}{TP+FN} \quad (8)$$

$$Specificity = \frac{TN}{N} = \frac{TN}{TN+FP} \quad (9)$$

$$Accuracy = \frac{TP+TN}{P+N} = \frac{TP+TN}{TP+TN+FP+FN} \quad (10)$$

$$Balanced\ Accuracy = \frac{Sensitivity+Specificity}{2} \quad (11)$$

$$F1 - Score = \frac{2TP}{2TP+FP+FN} \quad (12)$$

3.4. Normalization

Z-Score calculated using the mean and standard deviation of the data was used for normalization (Cheadle et al., 2003). The Z-Score equation is given in Eq. 13.

$$Z = \frac{X-\mu}{\sigma} \quad (13)$$

Here X is the raw data, μ is the mean of the dataset, and σ is the standard deviation.

4. Experimental Results

In this study, the factors affecting people's sleep routines were examined using machine learning methods. The dataset consists of 163 samples and 22 features obtained from people aged 18-35 using a questionnaire. The sleep routine is taken as an output parameter. It consists of two different parameters. These are sleep regular (1) and sleep irregular (0). In this study, NB and KNN from machine learning methods were used. Algorithms were used from the “sklearn” library. NB was used in its basic form. Minkowski and Euclid were used for distance in KNN. The k value was taken as 5. The dataset was randomly divided into two parts for training and testing. Training data consists of 130 (80%) and test data consists of 33 (20%) samples. The same test and training data were chosen to ensure that the

conditions were equal in all algorithms. The confusion matrix obtained from NB in the study is given in Table 3. The confusion matrix obtained from KNN (Minkowski) in the study is given in Table 4. The confusion matrix obtained from KNN (Euclidean) in the study is given in Table 5.

Table 3. NB Confusion Matrix

	Regular (1)	Irregular (0)
Regular (1)	14	1
Irregular (0)	16	2

Table 4. KNN (Minkowski) Confusion Matrix

	Regular (1)	Irregular (0)
Regular (1)	12	3
Irregular (0)	7	11

Table 5. KNN (Euclidean) Confusion Matrix

	Regular (1)	Irregular (0)
Regular (1)	14	1
Irregular (0)	3	15

The results of the evaluation metrics of each algorithm are given in the Table 6. When the Table 6 was examined, the accuracy value of the NB algorithm was obtained as 0.49. The accuracy value of KNN using Minkowski distance was found to be 0.71. KNN accuracy using Euclidean distance achieved the best result with 0.88. When the Table 6 is analyzed according to the f1-score value, KNN using Euclidean distance gave the best result with a value of 0.88. It was followed by KNN using the Minkowski distance with a value of 0.71. The f1-score also gave the worst results with NB 0.62. When the overall performance of the models is examined according to the f1-score value, it is seen that the KNN using Euclidean distance is the algorithm that achieves the best performance. Figure 1 shows the spider graph of the metrics obtained as a result of the study.

Table 6. Evaluation Metrics Results

	Sensitivity	Specificity	Precision	Accuracy	Balanced Accuracy	F1-score
NB	0.93	0.11	0.46	0.49	0.52	0.62
KNN (Minkowski)	0.80	0.61	0.63	0.70	0.71	0.71
KNN (Euclidean)	0.93	0.83	0.82	0.88	0.88	0.88




Figure 1. Spider chart of evaluation metrics

5. Conclusion

Sleep is an indispensable part of man. In line with the efficiency obtained from sleep, people will feel rested, happy, peaceful and vigorous. In addition to sleep, the concepts of sleep routine and sleep quality are of great importance in human life. Especially after the COVID-19 pandemic, there have been changes in people's sleep routines. In this study, sleep routines were predicted with different machine learning algorithms using 22 different input parameters. In the study, 3 different models, NB and 2 different KNN, were designed. Considering the results obtained because of the study, it is seen that KNN, which uses Euclidean distance, performs best in line with accuracy, balanced accuracy and f1-score. It is thought that the performance of machine learning methods will be increased by using feature selection methods in 22 features in future studies. In addition, models with better performance can be designed using different machine learning methods or hybrid methods.

References

- Altay, O., Ulas, M., Özer, M., and Genç, E. (2019). An expert system to predict warfarin dosage in turkish patients depending on genetic and non-genetic factors. In *2019 7th International Symposium on Digital Forensics and Security (ISDFS)* (pp. 1-6). IEEE.
- Altay, O., Ulas, M., and Alyamac, K. E. (2020). Prediction of the fresh performance of steel fiber reinforced self-compacting concrete using quadratic SVM and weighted KNN models. *IEEE Access*, 8, 92647-92658.
- Altay, E. V., Gurgenc, E., Altay, O., & Dikici, A. (2022). Hybrid artificial neural network based on a metaheuristic optimization algorithm for the prediction of reservoir temperature using hydrogeochemical data of different geothermal areas in Anatolia (Turkey). *Geothermics*, 104, 102476.
- Altena, E., Baglioni, C., Espie, C. A., Ellis, J., Gavrilloff, D., Holzinger, B., Schlarb, A., Frase, L., Jernelöv, S., and Riemann, D. (2020). Dealing with sleep problems during home confinement due to the COVID- 19 outbreak: Practical recommendations from a task force of the European CBT- I Academy. *Journal of sleep research*, 29(4), e13052.
- Aysan, E., Karaköse, S., Zaybak, A., and İsmailoğlu, E. G. (2014). Üniversite öğrencilerinde uyku kalitesi ve etkileyen faktörler. *Dokuz Eylül Üniversitesi Hemşirelik Fakültesi Elektronik Dergisi*, 7(3), 193-198.

- Cheadle, C., Vawter, M. P., Freed, W. J., and Becker, K. G. (2003). Analysis of microarray data using Z score transformation. *The Journal of molecular diagnostics*, 5(2), 73-81.
- Hirshkowitz, M., Whiton, K., Albert, S. M., Alessi, C., Bruni, O., DonCarlos, L., ... & Ware, J. C. (2015). National Sleep Foundation's updated sleep duration recommendations. *Sleep health*, 1(4), 233-243.
- Karadağ, M. G. and Aksoy, M. (2009). Uyku regülasyonu ve beslenme. *Göztepe Tıp Dergisi*, 24(1), 9-15.
- Temel, A. B., Fışkın, A., and Yıldırım, J. G. (2013). HEMŞİRELERDE UYKU SORUNLARI VE ETKİLİ ETMENLER. *Ege Üniversitesi Hemşirelik Fakültesi Dergisi*, 29(2), 13-32.
- Kruszewska, A., Nazaruk, S., and Szewczyk, K. (2022). Polish teachers of early education in the face of distance learning during the COVID-19 pandemic—the difficulties experienced and suggestions for the future. *Education 3-13*, 50(3), 304-315.
- Özkaya, B. Ö., Yüce, Z., Gönenç, M., Gül, A., and Alış, H. (2013). Ameliyat sonrası erken dönemde hastanede yatan hastaların uyku düzenini etkileyen etmenler. *Bakırköy Tıp Dergisi*, 9(3), 121-125.

Derin Öğrenme Teknikleri Kullanılarak Alzheimer Hastalığı Aşamalarının Sınıflandırılması

Classification of Alzheimer's Disease Stages Using Deep Learning Techniques

Esra YÜZGEÇ^{*1} , Muhammed TALO² 

¹Bilgisayar Mühendisliği Bölümü, Bingöl Üniversitesi, Bingöl, Türkiye

²Yazılım Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

(eyuzgec@bingol.edu.tr, mtalo@firat.edu.tr)

Özetçe— Alzheimer hastalığı zamanla ilerlemesini sürdüren ve teşhisi güç olan bir hastalıktır. Alzheimer hastalığının, beyinde ne zaman ortaya çıktığı ve ilerlemeye başladığı genellikle bilinmemektedir. Alzheimer hastalığını durdurucu bir tedavi yoktur. Erken aşamada teşhis edilebilen hastalarda, sürecin yavaşlatılarak hastanın yaşam kalitesinin artması hedeflenir. Hastalığın teşhis edilebilmesi için yapılan klinik testlerin yanında bilgisayar destekli cihazların kullanımı da oldukça yaygındır. Bu çalışmada bilgisayar destekli cihazlardan alınan görüntülerden faydalanarak, derin öğrenme modeli eğitimi yapılmıştır. Çalışmada Kaggle üzerinden açık kaynaklı olarak paylaşılan Alzheimer verisi dört sınıf halinde kullanılmıştır. SqueezeNet ve VGG-16 mimarilerinin kullanımı ile eğitilen modelde SqueezeNet mimarisi için %96.38 oranında VGG-16 mimarisi için ise %99.60 oranında doğruluk elde edilmiştir ve mimari karşılaştırmaları ayrıntılı bir biçimde sunulmuştur.

Anahtar Kelimeler : Alzheimer Hastalığı, Derin Öğrenme, Transfer Öğrenme

Abstract— Alzheimer's disease is a disease that slows its progression over time and is difficult to diagnose. It is often unknown when Alzheimer's disease appears in the brain and begins to progress. There is no cure for Alzheimer's disease. It aims to slow down the process and increase the quality of life in patients who can be diagnosed early. In addition to clinical tests to diagnose the disease, the use of computer-assisted devices is also very common. In this study, deep learning models training were carried using MR images taken from computer-assisted devices. We have used Alzheimer's Dataset (four classes)" shared as open source on Kaggle. In the model trained with the use of SqueezeNet and VGG-16 architectures, 96.38% accuracy was obtained for the SqueezeNet architecture, and 99.60% for the VGG-16 architecture, and architectural comparisons were presented in detail.

Keywords : Alzheimer's Disease, Deep Learning, Transfer Learning

1.Giriş

Alzheimer hastalığı günümüz dünyasında yaygınlığı giderek artan ve ölüm oranı her geçen gün yükselen bir hastalıktır. Bu hastalık zamanla ilerler ve beyinin özellikle hafızayı etkileyen bölümlerinde bozulmaya yol açar. Alzheimer hastalığının nedeni henüz tam olarak belirlenememiş olsa da; kafa travması, depresyon, yüksek tansiyon veya genetik sebepler gibi dış sebeplerin tetikleyici olabileceği düşünülmektedir (Acharya, U. R., 2019). Nedeni belirlenememiş bir hastalık olmasının yanında, tedavi süreci de hastalığı geri döndürmeye veya tamamen ortadan kaldırmaya değil, hastalık seyrini yavaşlatıp, belirtilerin ilerleme hızını olabildiğince düşürmeye yöneliktir. Tedavi sürecinde tam bir iyileşme gözlenemeyen bu hastalığın teşhisi için hasta üzerinde çeşitli klinik testler gerçekleştirilir ve hasta yakınlarından, hastanın tıbbi geçmişi dinlenir. Bunun yanında Bilgisayarlı Tomografi (BT) ve Manyetik Rezonans (MR) gibi tıbbi görüntüleme cihazları ile hastadan alınan beyin görüntüleri uzmanlarca incelenir.

Özellikle Çok Hafif Bilişsel Bozukluk, Hafif Bilişsel Bozukluk ve Orta Seviye Bilişsel Bozukluk seviyesinde beyinde gözle görülür değişim oldukça azdır. Bu durum Alzheimer hastalığı

ilerleme seviyesinin MR ve BT görüntüleri üzerinden tespit edilmesini zorlaştırmaktadır. Bu aşamada hastadan alınan MR ve BT görüntüleri kullanılarak, uzman doktor eşliğinde bir derin sinir ağı modelinin kullanılması; hastalık teşhisi sürecinde oldukça etkili sonuçlar elde edilebilir. Eğitilen modellerin yüksek doğruluk oranı ile çalışması halinde, uzmanlara ikinci bir bakış açısı sunması söz konusudur.

Literatürde, bilgisayar destekli sistemlerden elde edilen görüntülerin kullanıldığı derin öğrenme yöntemleri geliştirilmiştir. Bu yöntemler ile Alzheimer hastalığının teşhisine yardımcı olması amaçlanan çalışmalar yapılmıştır. Bu çalışmalara örnek olarak; Jinhua Sheng ve arkadaşları 2022 yılında yayınladıkları çalışmada Alzheimer hastalığının dört farklı evresini sınıflandırmışlardır. Eğitilen altı model arasında en yüksek doğruluk oranını %98 ile İleri Seviye (AD) ve Normal (HC) sınıfları arasında elde etmişlerdir (Sheng J., 2022).

2021 yılında yayınlanan bir çalışmada Yeşim Eroğlu ve arkadaşları Alzheimer hastalığının dört aşamasını içeren bir veri seti kullanarak bir sinir ağı eğitimi gerçekleştirmişlerdir. Kullanılan veri setinde; İleri Seviye, Normal, Hafif Bilişsel Bozukluk ve İleri Bilişsel bozukluk aşamaları yer almaktaydı. Eğittikleri dört sınıflı bu sinir ağı mimarisi ile %99.1 doğruluk oranını elde etmişlerdir (Eroglu, Y., 2022).


Bu çalışmada ise Normal, Çok Hafif Seviye Bilişsel Bozukluk, Hafif Seviye Bilişsel Bozukluk ve Orta Seviye Bilişsel Bozukluk aşaması olmak üzere 4 adet sınıftan toplam 5121 eğitim verisi kullanıldı. Dört Alzheimer aşamasından oluşan, iki derin sinir ağı eğitilmiştir. Eğitilen derin sinir ağları SqueezeNet ve VGG-16 olmak üzere farklı katman sayılarına sahip iki ayrı mimari ile gerçekleştirildi. Bu sinir ağlarında eğitilen modellerin eğitim tur sayıları aynı olup, herhangi bir hiperparametre sayısı ile ilgili değişiklik gerçekleştirilmemiştir. Eğitilen modellerde, veriler üzerinde herhangi bir ön işleme adımı kullanılmamıştır. Verilerin ham hali ile kullanılması; eğitilen modellerin Tıp alanında, gerçek hayat problemleri aşamasında hızlı sonuç alınabilmesini sağlar. Bu şekilde hastadan alınan görüntü üzerinde herhangi bir işlem yapılarak zaman kaybı yaşanmaması ve gerçek veriler üzerinden yüksek doğruluk elde edilebilmesi amaçlanmıştır.

Eğitilen modellerde VGG-16 mimarisi ile %99.60 oranında SqueezeNet mimarisi ile ise %96.38 oranında doğruluk elde edilmiştir. Bu sonuçlara dayanarak Alzheimer hastalarından alınan 5121 adet veri üzerinde VGG-16 mimarisinin eşit eğitim tur sayıları ile daha başarılı sonuç verdiği görülmüştür.

2. Veri Seti

Bu çalışmada Sarvesh Dubey tarafından halka açık şekilde yayınlanan “Alzheimers Dataset (4 Classes)” isimli veri seti kullanılmıştır. Kullanılan veri seti kaggle.com adresi üzerinde 2020 yılında güncellenerek kullanıma açık bir şekilde paylaşılmıştır. Veri seti içerisinde toplam 5121 adet MR görüntüsü bulunmaktadır. Veri setine ait örnek görüntüler Şekil 1’deki gibidir.

Kullanılan veriler eğitim ve test olmak üzere iki ayrı klasör ile elde edilmektedir. Test klasöründe, eğitilen modellerin doğruluk oranlarının test edilebileceği; modele daha önce gösterilmeyen veriler bulunmaktadır. Bu sayede test aşamasında kullanılarak model başarı oranının doğruluğu test edilebilir.



Şekil 1. Veri seti sınıflarının örnek görüntüleri

Veri seti içerisinde Normal (Non Demented), Çok Hafif Seviye Bilişsel Bozukluk (Very Mild Demented), Hafif Seviye Bilişsel Bozukluk (Mild Demented) ve Orta Seviye Bilişsel Bozukluk (Moderate Demented) olmak üzere dört ayrı Alzheimer aşaması, sınıflar halinde ayrılmıştır. Normal sınıfı için, 2760 eğitim ve 640 test verisi, Çok Hafif Bilişsel Bozukluk sınıfı için, 1793 eğitim ve 448 test, Hafif Bilişsel Bozukluk sınıfı için, 717 eğitim ve 279 test, Orta Seviye Bilişsel Bozukluk sınıfı için ise 52 eğitim 12 test verisi bulunmaktadır.

3. Metot

3.1. Transfer Öğrenme

Derin öğrenme modelleri Evrişim, Havuzlama ve Tam Bağlı katmanların kullanılması ile oluşturulur. Oluşturulan bu modellerde veri sayısının az olması, sınıflar arası veri sayılarındaki tutarsızlık gibi sebeplerle aşırı uyum veya yetersiz uyum problemleri ile karşılaşılabilir (Hon M., 2017).


Yetersiz uyum problemi olarak adlandırılan derin öğrenme probleminde, eğitilen model eğitim ve test verilerini yüksek doğruluk oranı ile sınıflandıramayacak durumdadır (Li, H., 2019). Bu problemin oluşmasındaki sebep veri setindeki yetersizliğin yanında oluşturulan modelin metrik ve parametre açısından yeterli başarıyı sağlayamaması olarak da nitelendirilebilir. Aşırı uyum probleminde ise, yetersiz uyum problemine karşıt bir yaklaşım bulunmaktadır. Eğitilen model tarafından kullanılan görüntüler ezberlenerek, eğitim verileri haricinde kullanılan test verilerinin düşük bir başarı ve doğruluk oranı ile sınıflandırılması söz konusu olmaktadır (Sehara, 2021).

Derin öğrenme modellerinin eğitimi sırasında, eğitilen modelin parametre ve metrik yetersizliği veya veri seti içerisindeki dengesiz veri dağılımı sebebi ile bu gibi problemler ile karşılaşılabilir. Bu problemlere çözüm olarak transfer öğrenme yöntemi kullanılır. Transfer öğrenmede, daha önce çok daha büyük bir veri seti üzerinde eğitilmiş ve yüksek doğruluk elde etmiş mimariler yeniden kullanılır. Temel olarak yüksek boyutlu veri kümeleri üzerinde başarı sağlamış mimarilerin, modellerin Tam Bağlı katmanlarına, hedeflenen eğitim verisinin eklenmesi ve eğitilmesi sağlanır. Bu sayede küçük ölçekli veri setleri üzerinde kullanılarak daha yüksek doğruluk oranına ulaşılması amaçlanır. Bu çalışmada da 14 milyondan fazla görüntü içeren ImageNet veri seti üzerinde eğitilmiş olan VGG-16 ve SqueezeNet mimarileri transfer öğrenme yöntemi ile kullanılmıştır.

3.2 SqueezeNet

22 Evrişim katmanından oluşan SqueezeNet, aktivasyon fonksiyonu olarak ReLU kullanan bir yapıya sahiptir. Üç ayrı maksimum havuzlama katmanı içermektedir. Havuzlama katmanı olarak, mimari yapısının son evrişim katmanından sonra bir adet ortalama havuzlama katmanı da kullanılmıştır. Aşırı uyum ve yetersiz uyum problemlerini önlemek adına son katmanında ise Dropout (seyreltme) katmanı kullanılmıştır.

SqueezeNet mimarisi 2016 yılında AlexNet mimarisinin ulaştığı doğruluk oranını, çok daha az parametre ve katman kullanımı ile geçmeyi hedefleyerek öne çıkarılmış bir mimaridir. Bu mimari yapısı içerisinde Fire olarak adlandırılan evrişim ve aktivasyon katmanlarından oluşan bloklar mevcuttur. Şekil 2’de görüldüğü üzere evrişim katmanları, Fire katmanları arası değer aktarımı yaparak özellik kaybının önüne geçmektedir. Bu sayede de daha düşük parametre ile daha yüksek başarı oranı hedeflenmiştir.




Şekil 2. SqueezeNet mimari içeriği

3.3 VGG-16

VGG-16 en temel tanımı ile 16 evrişim katmanından oluşan bir sinir ağı mimarisidir. Şekil 3'te görüldüğü gibi kendi içerisinde 16 evrişim, 5 havuzlama ve 3 tam bağlı katmandan oluşmaktadır. Model içerisindeki evrişim katmanlarının her birinin çıkışında farklı ağırlıklara sahip filtreler hesaplanır. Mimari işleyişi sırasında eklenen katmanlar arttıkça; elde edilen piksel boyutu, görüntü üzerindeki değerler ve özniteliklerin derinliği daha iyi ifade edilmiş olur.

Şekil 3. VGG-16 mimari içeriği

VGG-16; "Büyük Ölçekli Görüntü Tanıma için Çok Derin Evrişimli Ağlar" makalesine Oxford




Üniversitesinden K. Simonyan ve A. Zisserman tarafından önerilen bir evrişimli sınır ağı modelidir (Simonyan, K., 2014). Bu model ImageNet veri seti kullanıldığında yüksek bir doğruluk oranını elde etmiştir. ImageNet ise 14 milyondan fazla görüntüden oluşan ve 1000 sınıfa ayrılmış bir veri setidir.

ImageNet ile yapılan Büyük Ölçekli Görsel Tanıma yarışmasının 2014 yılında sunulan en popüler modellerinden biri VGG-16 modeli olmuştur.

4. Sonuç


Bu çalışmada derin öğrenme teknikleri kullanılarak geliştirilen modellerde VGG-16 ve SqueezeNet mimarileri kullanıldı. VGG-16 mimarisi ile %99.60, SqueezeNet mimarisi ile eğitilen modelde ise %96.38 seviyesinde doğruluk oranına ulaşıldı. Elde edilen modellerin doğrulama verileri üzerinde başarı oranlarının sayısal olarak ifade edilmesi için Karmaşıklık Matrisleri Şekil 4'te verilmiştir.



Şekil 4. Eğitilen modellerin karmaşıklık matrisleri

Eğitilen modellerde 1024 adet doğrulama verisi kullanılmıştır. Doğrulama verileri üzerinden elde edilen karmaşıklık matrislerinde; VGG-16 modelinde toplam 4 adet hatalı tahmin bulunmaktadır. Karmaşıklık matrisi incelendiğinde yapılan hatalı tahminlerin, Hafif ve Çok Hafif Bilişsel Bozukluk aşamalarında olduğu gözlemlendi. SqueezeNet modelinde ise 46 adet görüntü hatalı tahmin edilmiştir. SqueezeNet mimarisinde elde edilen karmaşıklık matrisi incelendiğinde, hatalı tahmin sayısının en fazla olduğu sınıf Çok Hafif Bilişsel Bozukluk evresine aittir. Bu sonuçlara dayanarak eğitilen modellerde VGG-16 mimarisinin daha başarılı sonuç elde ettiği söylenebilir.

Modellerin eğitim tur sayısı 100 olarak seçildi. Model eğitimi boyunca kayıp oranları incelendiğinde, eğitim ve doğrulama kayıpları Şekil 5'te verildiği gibi tutarlı bir şekilde azalmıştır. Kayıp grafikleri değerlendirildiğinde modellerin aşırı öğrenme (overfitting) problemi ile karşılaşmadıkları görülmektedir.



Şekil 5. Eğitilen modellerin kayıp grafikleri

Kaynaklar

- Acharya, U. R., Fernandes, S. L., WeiKoh, J. E., Ciaccio, E. J., Fabell, M. K. M., Tanik, U. J., ... & Yeong, C. H. (2019). Automated detection of Alzheimer's disease using brain MRI images—a study with various feature extraction techniques. *Journal of Medical Systems*, 43(9), 1-14.
- Sheng, J., Xin, Y., Zhang, Q., Wang, L., Yang, Z., & Yin, J. (2022). Predictive classification of Alzheimer's disease using brain imaging and genetic data. *Scientific Reports*, 12(1), 1-9.)
- Eroglu, Y., Yildirim, M., & Cinar, A. (2022). mRMR-based hybrid convolutional neural network model for classification of Alzheimer's disease on brain magnetic resonance images. *International Journal of Imaging Systems and Technology*, 32(2), 517-527.)
- Hon, M., & Khan, N. M. (2017, November). Towards Alzheimer's disease classification through transfer learning. In *2017 IEEE International conference on bioinformatics and biomedicine (BIBM)* (pp. 1166-1169). IEEE.
- Li, H., Li, J., Guan, X., Liang, B., Lai, Y., & Luo, X. (2019, December). Research on overfitting of deep learning. In *2019 15th International Conference on Computational Intelligence and Security (CIS)* (pp. 78-81). IEEE.
- Sehra, S., Flores, D., & Montanez, G. D. (2021, January). Undecidability of Underfitting in Learning Algorithms. In *2021 2nd International Conference on Computing and Data Science (CDS)* (pp. 591-594). IEEE.

Twitter Verileri Kullanılarak Kısa Metinler Üzerinde GRU ile Nefret Söylemi Tespiti *Detection of Hate Speech with GRU on Short Texts Using Twitter Data*

Zeynep ASLANPENÇESİ*¹ , Muhammet BAYKARA*² 

^{1,2}Yazılım Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye
(202137110@firat.edu.tr, mbaykara@firat.edu.tr)

Özetçe— Gelişen teknolojiyle birlikte akıllı cihazların kullanımı oldukça yaygın hale gelmiştir. Akıllı cihazlar özellikle sosyal mecraların sıkça kullanılmasına imkân sunmaktadır. Günümüzde de oldukça yaygın kullanılan sosyal medya araçlarının başında Twitter gelmektedir. Twitter üzerinden oluşturulan içerikler her zaman iyi niyetli olmamaktadır. Kullanıcılar tarafından atılan tweetler bazen ırkçı ya da cinsiyetçi içerikler barındırabilmektedir. Bu çalışmada, doğal dil işleme teknikleri kullanılarak veri bilim platformu olan Kaggle’da yer alan 31.951 tweetten oluşan veri seti kullanılmıştır. Doğal dil işleme teknikleri kullanılarak ön işlemlerden geçirilen veri seti nefret söylemi tespiti için Tekrarlayan Sinir Ağı mimarilerinden olan GRU ile eğitilmiştir. Çalışma sonucunda %99.80’lik başarımler elde edilmiştir.

Anahtar Kelimeler : *Twitter Veri Seti, Makine Öğrenimi, Doğal Dil İşleme Teknikleri, Derin Öğrenme Yöntemleri*

Abstract— With the developing technology, the use of smart devices has become quite common. Smart devices allow the frequent use of social media. Twitter is one of the most widely used social media tools today. Content created on Twitter is not always well-intentioned. Tweets posted by users can sometimes contain racist or sexist content. In this study, a data set consisting of 31,951 tweets in Kaggle, a data science platform, was used by using natural language processing techniques. The dataset, which was preprocessed using natural language processing techniques, was trained with GRU, one of the Recurrent Neural Network architectures, for sentiment analysis. As a result of the study, 99.80% success was achieved.

Keywords : *Twitter Dataset, Machine Learning, Natural Language Processing Techniques, Deep Learning Methods*

1. Giriş

Gelişen teknoloji ile akıllı cihazların kullanımı yaygınlaşmıştır. İnsanlar akıllı cihazlar üzerinden kolayca erişebildiği birçok sosyal medya platformunu kullanmaktadır. Bu mecralardan önde gelen uygulamalar arasında Twitter yer almaktadır. Özellikle Twitter üzerinden insanlar düşüncelerini kolayca paylaşma imkanı bulmaktadırlar. Tüm bunlara bağlı olarak Twitter üzerinden nefret söylemi oldukça yaygın olarak gerçekleşmektedir. Nefret söylemi, çeşitli konularda nefret ifadeleri içeren kişilere açıkça yapılan şiddet uygulamaları olarak tanımlanır.

Kullanıcılar hedef edindikleri kişilerle yüz yüze olmama avantajından faydalanarak bu eylemleri gerçekleştirirler. Bu eylemlerin sonucunda mağdurların yaşantıları olumsuz etkilenir. Bu çalışmada toplumsal bir sorun haline gelen nefret söylemi tespitinin gerçekleştirilmesi amaçlanmıştır. Böylece sosyal medya üzerinden paylaşılan bu tarz içerikler tespit edilecektir. Ardından bu içerikleri paylaşan kişi ya da gruplara çeşitli yaptırımlar uygulanarak bu sorunla mücadele edilebilmesi hedeflenmektedir.

Bu çalışmada kullanılan veri seti cinsiyetçi ve ırkçı tweetlerden oluşmaktadır. Veri setinin etiketleri nefret söyleminin olup olmadığına göre iki sınıfta yapılmıştır. Veri setine doğal dil işleme teknikleri kullanılarak ön işlemler uygulanmıştır. Eğitim ve test veri seti olarak parçalanmıştır. Ardından Tekrarlayan Sinir Ağı algoritmalarından GRU mimarisi ile model eğitimi tamamlanmıştır. Eğitim sonunda model %99.80’lik başarıma ulaşmıştır.

Çalışma kapsamında aynı veri seti üzerinde gerçekleştirilen nefret söylemi uygulamaları incelenmiştir. Çeşitli Makine Öğrenimi ve Derin Öğrenme yöntemleri ile eğitimler yapılmıştır. Mevcut çalışma ile başarımler oranları üzerinde durulmuştur. Sonuç olarak literatürden daha başarılı bir çıktı elde edildiği saptanmıştır.

2. İlgili Çalışmalar

Literatürde bu alanda çeşitli çalışmalar yapılmıştır. Faizan Sharda Üniversitesi tarafından yapılan çalışmada tweetlerin arkasındaki duygunun türetilmesi amacıyla toplanan verilere python ile ön işleme ve çıkarma yöntemleri uygulanarak unigram, bigram ve ngram özellikleri ile KNN algoritması kullanılarak duygu analizi için bir model oluşturulmuştur. Model eğitimi ve testi #USairline veri seti üzerinde gerçekleştirilerek %65,33’lük doğruluk

oranına ulaşılmıştır [1]. Usman Naseem ve diğerleri yaptıkları çalışmada duygu analizi açısından oldukça önemli olan kısa ve resmi olmayan tweetlerin içerdikleri gürültü ve çok anlamlılık gibi dil belirsizlikleri esasen duygu analizinin yapılmasını zor bir görev haline getirdiğini belirtmişlerdir. Bu sebeple çalışmada tweetlerin kalitesini artıran ve gürültüsünü ortadan kaldıran bir yöntem olarak DICET kullanılmıştır. DICET derin akıllı bağlamsal bir yöntem uygulayan dönüştürücü tabanlı bir duygu analiz yöntemidir. Üç kıyaslama veri seti üzerinde yapılan deneylerde DICET'in son teknolojilere oranla daha iyi sonuç verdiği ve dil belirsizliklerini ortadan kaldırdığı ortaya konulmuştur. Bu sebeple DICET'in düşük kaliteli ve belirsiz veri setlerinde iyi bir veri analizi işlemi yapabileceği kanıtlanmıştır. Çalışmada doğruluk oranı %82.7 olarak belirtilmiştir [2]. Despoina Antonakaki ve arkadaşları çalışmada twitterdaki araştırma konuları sosyal grafiğin yapısı ve özellikleri, duygu analizi ve spam, botlar, sahte haberler ve nefret söylemi olmak üzere üç ana grupta inceleyerek haritalandırılmışlardır. Bu çalışma aynı zamanda Grafik Örnekleme, Doğal Dil İşleme ve Makine Öğrenimi hesaplama tekniklerinin temelini oluşturmaktadır. Çalışma neticesinde twitter üzerinde yapılan anketlerin sürekli olarak güncellenmesi ve twitterin ileride bilimsel araştırmalar için bir araştırma nesnesi olabileceği sonucuna ulaşılmıştır [3]. Femi Emmanuel Ayo ve diğerleri yaptıkları çalışmada twitter veri akışında nefret söylemi tespiti için makine öğrenimi tekniklerine ilişkin bir anket sunmuşlardır. Bu çalışma kapsamında genel üst veri mimarisini geliştirmişlerdir. Geliştirdikleri mimarinin diğer benzer yöntemlerle kıyaslandığında %95'lik doğruluk ve %91,5'lik F1 puanıyla daha iyi bir sonuç verdiğini ortaya koymuşlardır [4]. Ashwin Perti ve diğerleri çalışmalarında twitter duygu analizi için kullanılan derin öğrenme algoritmalarını ele almışlardır. Deneysel sonuçlarda tekrarlayan sinir ağlarının diğer derin öğrenme sinir ağlarına oranla daha iyi sonuç verdiği kanısına ulaştıklarını belirtmişlerdir [5]. Omar Adwan ve diğerleri bu çalışmada twitter'da duygu analizi için literatürde yer alan yöntemlerin incelemesini yapmışlardır. Çalışma neticesinde TSA yaklaşımlarına genel bir bakış açısı sunarak TSA ile yapılan çalışmalar kategorilere ayırmış ve gelecekte TSA'nın aktif bir çalışma alanı olacağı sonucuna ulaşmışlardır [6].

Shanta H. Biradar ve arkadaşları çalışmalarında marka ve hizmetleri tanımlamaya yönelik duygu analizi için yapılandırılmamış verileri toplamak ve işlemek amacıyla kullanılabilecek büyük veri teknolojisini geliştirmeyi hedeflemişlerdir. Metodoloji, veri kümelerinin önceden belirlenmesi, verilerin belirli alanlara göre kümelenmesi, n-gram modellerini kullanan özellik vektörü ve tf-idf vektörlerinin eş anlamlıları ve sınıflandırma duygu analizi ile ilgilenen müşteri inceleme sınıflandırmasını kullanan duygusal analize dayalı bir algoritma geliştirmişlerdir. Çalışma neticesinde verilerin belirli yerlerde denetlenmemiş şekilde kümelenmesiyle büyük twitter verilerini verimli olarak kullanabilecek ve %80'den fazla doğruluk oranına sahip bir algoritma olduğu sonucuna ulaşmışlardır [7]. İslam Mayda ve arkadaşları çalışmalarında Türkçe tweetler üzerinde nefret söylemi analizi yapmışlardır. Türkçe tweetlerden elde edilen verileri nefret söylemi, saldırgan ifade ve hiçbirisi olarak üç grupta etiketlemişlerdir. Farklı makine öğrenme yöntemleri ile veri seti üzerinde deneyler yapılmıştır. Üç etiketli veri seti üzerinde en yüksek performansı SMO ile gerçekleştirilen deneyde %79,9 F- ölçüm değeri olarak saptamışlardır. İki sınıflı veri seti üzerinde bu oranı %86,4 olarak belirtmişlerdir [8].


Maryum Bibi ve diğerleri çalışmalarında Twitter duygu analizi için Kavram tabanlı ve tek bağlantı, tam bağlantı ve ortalama bağlantı algoritmalarını içeren popüler hiyerarşik kümelemeye dayalı yeni bir denetimsiz öğrenme çerçevesi önermişlerdir. TF-IDF olmak üzere iki farklı özellik gösterim yöntemini inceledikleri çalışmada Naive Bayes, Neural Network ile karşılaştırmalı deneyler yapmış ve denetimli öğrenme teknikleriyle denetimsiz öğrenme tekniklerinin karşılaştırılabilir olduğu sonucuna varmışlardır [9]. Enver Yazgılı ve Muhammet Baykara yapmış oldukları çalışmada Kaggle'den elde ettikleri ve manuel olarak oluşturdukları 1497'si siber zorbalık içermeyen 1503'ü siber zorbalık içeren 3000 cümleden oluşan Türkçe veri seti üzerinde Bagging, Boosting, C4.5, LR, KNN, K-Means, Stokastik Gradient Descent gibi on üç farklı algoritmayı uygulayarak siber zorbalık tespiti gerçekleştirmişlerdir. Kullanılan bu algoritmalar ilk defa karşılaştırmalı olarak kullanılmış olup bu yöntemler üç aşamalı şekilde uygulanmıştır. Keşifsel veri analizi, veri ön işleme ve makine öğrenmesi algoritmalarının kullanılması aşamalarından geçen veri seti en yüksek başarıyı %88,35'lik başarı oranıyla LR sınıflandırma algoritmasında göstermiştir. LR algoritmasını %86'lık oranla Boosting algoritması takip etmiştir [10].

3. Materyal ve Metotlar

Kısa metinler üzerinden nefret söylemini gerçekleştirmek amacıyla yapılan çalışmada Kaggle'da [11] erişime açık olarak sunulan "train.csv" isimli veri seti kullanılmıştır. Veri seti 31.951 satır ve 3 sütundan oluşmaktadır. Sütunlar "id", "label" ve "tweet" özniteliklerine sahiptir. Veri setinde "1" etiketi tweet'in ırkçı ya da cinsiyetçi bir söyleme sahip olduğunu "0" etiketi ise böyle bir söylemin olmadığını ifade etmektedir. Veri setinin bir bölümü Şekil 1'de, etiketli verilere ait grafik Şekil 2'de verilmiştir.

id	label	tweet
1,0	0	@user when a father is dysfunctional and is so selfish he drags his kids into his dysfunction. #run
2,0	0	@user @user thanks for #lyft credit i can't use cause they don't offer wheelchair vans in pdx. #disappointed #getthankd
3,0	0	bihday your majesty
4,0	0	#model i love u take with u all the time in ur
5,0	0	factsguide: society now #motivation
6,0	0	[2/2] huge fan fare and big talking before they leave. chaos and pay disputes when they get there. #allshowandnogo
7,0	0	@user camping tomorrow @user @user @user @user @user danny
8,0	0	the next school year is the year for exams. #school #exams #hate #imagine #actorslife #revolutionschool #girl
9,0	0	we won!!! love the land!!! #allin #cavs #champions #cleveland #clevelandcavaliers
10,0	0	@user @user welcome here! i'm it's so #gr8!
11,0	0	ireland consumer price index (mom) climbed from previous 0.2% to 0.5% in may #blog #silver #gold #forex
12,0	0	we are so selfish. #orlando #standwithorlando #pulseshooting #orlandoshooting #biggerproblems #selfish #heabreaking #values #love #
13,0	0	i get to see my daddy today!! #80days #gettingfed
14,1	1	@user #cnn calls #michigan middle school 'build the wall' chant " #tcot
15,1	1	no comment! in #australia #opkillingbay #seashepherd #helpcovedolphins #thecove #helpcovedolphins
16,0	0	ouch...junior is angry
17,0	0	i am thankful for having a paner. #thankful #positive
18,1	1	retweet if you agree!
19,0	0	its #friday! smiles all around via ig user: @user #cookies make people
20,0	0	"as we all know, essential oils are not made of chemicals."
21,0	0	#euro2016 people blaming ha for conceded goal was it fat rooney who gave away free kick knowing bale can hit them from there.
22,0	0	sad little dude.. #badday #coneofshame #cats #pissed #funny #laughs
23,0	0	product of the day: happy man #wine tool who's it's the #weekend? time to open up & drink up!
24,1	1	@user @user lumpy says i am a . prove it lumpy.
25,0	0	@user #tgif #ff to my #gamedev #indiedev #indiegamedev #squad! @user @user @user @user @user

Şekil 1. Twitter Veri Seti




Şekil 2. Twitter Veri Seti Etiketlerin Dağılım Grafiği

Twitter verileri kullanılarak gerçekleştirilen çalışmada veri setinin temizlenmesi ve tokenleştirilmesi (sayısallaştırılması) için doğal dil işleme yöntemleri kullanılmıştır. Başlangıçta veri setinde yer alan satır ve sütunlarda kayıp değerler olup olmadığı pandas kütüphanesi kullanılarak taranmıştır. Veri setinde kayıp veri bulunmadığı tespit edilmiştir. Ardından veri setinin eğitimi aşamasında anlam ifade etmeyen durdurma kelimeleri “stopwords” kütüphanesi kullanılarak temizlenmiştir. Veri seti, eğitim verisi için %75 ve test verisi için %25 olacak şekilde ayrılmıştır. Modeli eğitmek için girdi olarak verilecek veri setinin tamamının kelime boyutunun aynı olması gerekmektedir. Veri setindeki her bir cümle kelimelere parçalanmış ve her bir kelimeye sayısal değer karşılıkları “Tokenizer” kütüphanesi kullanılarak verilmiştir. Bu sayısal değerler içerisinde maksimum tokene sahip olan cümlelerin boyutu 59 olarak belirlenmiştir. Veri setinde yer alan veriler cümleler 59 boyutlu olacak şekilde sıklıkla geçen 50.000 kelimedenden oluşan “Bag of Words” yöntemi kullanılarak embedding vektörlere dönüştürülmüştür. Veri seti üzerinde tokenleştirme işlemi tamamlandıktan sonra “Keras” kütüphanesinde yer alan “pad_sequences” kullanılarak eğitim ve test verilerine padding eklenmiştir. Kelime ve kelimelerin tokenlerinin yer aldığı bir liste oluşturularak geri döndürülmüştür.

Ön işlemler tamamlandıktan sonra veri setini eğitmek için Tekrarlayan Sinir Ağı algoritmalarından olan GRU mimarisi kurulmuştur. Modelde olması gereken her şeyi modele katman katman eklemek için başlangıçta sıralı bir model oluşturulmuştur. Her kelimeye karşılık gelecek vektör uzunluğu belirlenmiştir. Girdi veri setini daha dar bir alanda sıkıştırmak için Kerasta “Embedding” katmanı oluşturulmuştur. Embedding katmanına parametre olarak kelime sayıları, kelime vektörlerinin uzunluğu, gelen girdinin boyutu ve bu katmandaki ağırlıkların boyutunu daha sonra çağırmak için isim verilmiştir. Bu katman girdiyi aldıktan sonra girdi içerisindeki kelimelerin vektörlerini bir sonraki katmana gönderecektir. Embedding katmanının çıktısı bir sonraki katmanın girdi olacaktır. Ardından Yinelenen Sinir Ağı oluşturmak için üç adet GRU katmanı kullanılmıştır. Üç adet GRU katmanı kullanılmasının sebebi ise Yinelenen Sinir Ağlarında çok derin oluşturulan katmanlardan iyi sonuçlar alınamamasıdır. Keras kütüphanesinin “.add()” metodu ile GRU katmanlar sırasıyla eklenmiştir. İlk GRU katmanının nöron sayısı 16 olarak girilmiştir. Bu katmanda modele 16 tane çıktı verilecektir. İkinci GRU katmanının nöron sayısı 8 olarak

girilmiştir. Son GRU katmanında ise nöron sayısı 4 olarak girilmiştir. Bir sonraki katman tek bir nöronun oluşacağı için son GRU katmanından uygun bir çıktı üretilmesi sağlanmıştır. Bir katmandan alınan nöronun bir sonraki katmana girdi olarak verilmesini sağlamak için tek bir nöronun oluşan “Dense” katmanı modele eklenmiştir. Eğitim sonunda elde edilecek çıktı iki sınıftan oluştuğu için aktivasyon fonksiyonuna “sigmoid” verilerek çıktı “0” ile “1” arasında sıkıştırılmıştır. Optimizasyon algoritması “Adam” olarak belirlenmiştir. İki sınıf bulunduğu için Loss Fonksiyonu olarak “binary_crossentropy” ve modelin başarımlarını görebilmek için metrik olarak “accuracy” kullanılmıştır. Model 256’lık batch_size’ler halinde 10 epochs olacak şekilde eğitilmiştir. Model eğitimine ait akış şeması Şekil 3’te verilmiştir.



Şekil 3. GRU ile Twitter Veri Seti Üzerinde Nefret Söylemi Tespiti Akış Şeması

Bu çalışmada, tweetlerden oluşturulan veri seti doğal dil işleme teknikleri kullanılarak temizlenmiş, vektör uzunlukları belirlenmiş ve sayısallaştırma işlemleri gerçekleştirilmiştir. Model eğitimi için GRU mimarisi kullanılmıştır. Eğitim tamamlandıktan sonra modelin %99.80’lik bir başarıma sahip olduğu belirlenmiştir. Veri bilim platformu olan Kaggle’da yer alan veri setine [11] literatürdeki çeşitli algoritmalar kullanılarak model eğitimi gerçekleştirilmiştir. Bu algoritmalarından elde edilen başarımlar ve bu çalışmada kullanılan yaklaşımın başarımları Tablo 1’de verilmiştir.

Tablo 1. Train.csv Veri Setine Uygulanan Algoritmaların Doğruluk Performansı

Literatürde Kullanılan Algoritma	Doğruluk Ölçütü
LogisticRegression [12]	0.4879
KNN [12]	0.9423
SVM [12]	0.4809
Kernel SVM [12]	0.93
Naive Bayes [12]	0.9132
RandomForest Classifier [12]	0.9510
XG Boost Classifier [12]	0.9538
Decision Tree [12]	0.9250
Random Forest Classifier [13]	0.90
Linear SVC [14]	0.9566
Multinomial NB [1]	0.94
LSTM [15]	0.9520

Multinomial NB [16]	0.9372
Logistic Regression [16]	0.9454
Linear SVC [16]	0.9621
Bidirectional LSTM [16]	0.9522
Logistic Regression [17]	0.9316
Bu çalışma/GRU	0.9980

3.1. Algoritmanın Adımları

Doğal Dil İşleme ile Ön İşlem Adımları

1. train.csv veri seti pandas kütüphanesi ile okundu.
2. train.csv veri setinin kayıp satır ve sütunları taranıp kayıp veri olmadığı tespit edilmiştir.
3. Veri seti durdurma kelimelerinden “stopwords” kütüphanesi ile temizlenmiştir.
4. Veri setinin %75’i eğitim, %25’i test verisi olacak şekilde parçalanmıştır.
5. Veri seti içerisinde yer alan cümlelerin kelime boyutu belirlenerek “Tokenizer” kütüphanesi ile tüm veri seti sayısallaştırılmıştır.
6. Kelime vektör yöntemi olarak “Bag of Words” kullanılarak 50.000 kelimededen oluşan embedding vektörler oluşturulmuştur.
7. Tokenleştirme işlemi tamamlanan eğitim ve test veri setine Keras kütüphanesi ile padding eklenmiştir.


Eğitim Modelinin Oluşturulması

1. Sıralı bir model oluşturulmuştur.
2. Girdi veri setini daha dar bir alanda sıkıştırmak için Kerasta “Embedding” katmanı oluşturulmuştur. Embedding katmanına parametre olarak kelime sayıları, kelime vektörlerinin uzunluğu, gelen girdinin boyutu ve bu katmandaki ağırlıkların boyutunu daha sonra çağırmak için isim verilmiştir.
3. Ardından 16, 8 ve 4 nöronlu oluşan üç adet GRU katmanı oluşturulmuştur.
4. Dense katmanı oluşturulup aktivasyon fonksiyonu belirlenerek bu katmanda parametre olarak girilmiştir.
5. Optimizasyon algoritması belirlenmiştir.
6. Modeli derlemek için “model.compile” oluşturulmuştur. Parametre olarak loss fonksiyonu, optimizasyon algoritması ve başarımleri metriği girilmiştir.
7. Model 10 epochs’ta 256’lık batch_size’ler ile eğitilmiştir.

Eğitilen Modelin Test Edilmesi

1. Algoritmanın başarımleri test etmek için kullanıcıdan bir metin girmesi istenmiştir.
2. Ardından girilen metin “sent_tokenize” kütüphanesi ile cümlelere ayrılmış ve listeye içerisinde eklenmiştir.
3. Cümleleri içeren liste tokenleştirildikten sonra eğitilen modele girdi olarak verilirken metin içerisinde nefret söylemi olup olmadığı başarılı bir şekilde tespit edilmiştir.

Yukarıda adım adım verilen algoritmanın adımları Şekil 4’te detaylı olarak verilmiştir.



Şekil 4. Algoritmanın Yapısı

4. Sonuçlar

Bu çalışmada Twitter üzerinden yapılan cinsiyetçi ve ırkçı söylemleri tespit etmek amaçlanmıştır. Kısa metinlerin içeriği analiz edilerek nefret söylemi tespiti yapılmıştır. Uygulamada Kaggle’da [11] yer alan tweetleri içeren “train.csv” isimli veri seti kullanılmıştır. 31.951 adet tweetten oluşan veri seti üzerinde model eğitimi gerçekleştirilmiştir. Doğal dil işleme yöntemleri ile ön işlemesi yapılan veri seti GRU algoritması ile eğitilmiştir. Eğitim sonunda elde edilen başarımlar literatürde yer alan çalışmalara kıyasla yüksektir. Eğitilmiş modelin path’ı keras kütüphanesi ile kaydedilmiştir.

Veri seti, daha önce eğitilmiş kelime vektörleri kullanılarak değil rastgele kelimelerden oluşan “Bag of Words” kelime vektör yöntemi kullanılarak eğitilmiştir. Model ile birlikte kelime vektörlerinin de eğitilmesi model başarımının yüksek olmasında oldukça etkili olmuştur. Aynı zamanda veri setinin 256’lık batch_size’ler halinde eğitilmesi hataların azaltılmasını ve dalgalanmaların üstesinden gelinmesini sağlayarak başarımların artmasında etkili olmuştur. Eğitilen modelin başarımlarına ait sonuçlar Şekil 5’te verilmiştir.

```

/usr/local/lib/python3.7/dist-packages/tensorflow/python/keras/optimizer_v2/optimizer_v2.py:369: UserWarning: The `lr` arg
"The `lr` argument is deprecated, use `learning_rate` instead.")
Epoch 1/10
100/100 [=====] - 58s 480ms/step - loss: 0.3735 - accuracy: 0.9250
Epoch 2/10
100/100 [=====] - 48s 478ms/step - loss: 0.2022 - accuracy: 0.9486
Epoch 3/10
100/100 [=====] - 49s 489ms/step - loss: 0.1236 - accuracy: 0.9741
Epoch 4/10
100/100 [=====] - 49s 491ms/step - loss: 0.0798 - accuracy: 0.9874
Epoch 5/10
100/100 [=====] - 48s 475ms/step - loss: 0.0568 - accuracy: 0.9928
Epoch 6/10
100/100 [=====] - 56s 563ms/step - loss: 0.0426 - accuracy: 0.9955
Epoch 7/10
100/100 [=====] - 47s 471ms/step - loss: 0.0341 - accuracy: 0.9966
Epoch 8/10
100/100 [=====] - 48s 476ms/step - loss: 0.0288 - accuracy: 0.9971
Epoch 9/10
100/100 [=====] - 47s 472ms/step - loss: 0.0248 - accuracy: 0.9977
Epoch 10/10
100/100 [=====] - 48s 480ms/step - loss: 0.0215 - accuracy: 0.9980
<tensorflow.python.keras.callbacks.History at 0x7f5bd1291d50>

```

Şekil 5. Eğitilen Veri Setinin Başarımlar Ölçütü

Eğitilen modelin test aşamasında kısa metinler girdi olarak verilmiştir. Metinler ilk etapta doğal dil işleme yöntemi olan “sent_tokenize” ile cümlelere parçalanmıştır. Her bir cümlede nefret söylemi olup olmadığı tespit

edilmiştir. Nefret söylemi var ise “Pozitif” yok ise “Negatif” olarak sınıflandırılmıştır. Bu sınıflandırma sonucuna göre metin üzerinde nefret söyleminin olup olmadığı belirlenmiştir.

Modelin başarımı ve model üzerinde gerçekleştirilen test aşamasından elde edilen sonuca göre çalışmada amaçlanan nefret söylemi tespiti başarılı bir şekilde gerçekleştirilmiştir. Yapılan çalışmada ve literatürde yer alan çalışmalar doğrultusunda bir sonraki adımda Hibrit bir sistem ile model eğitimi gerçekleştirilmesi hedeflenmektedir. CNN mimarisi ile uzamsal özellikleri çıkarılan veri setinden elde edilen çıktı GRU mimarisinde eğitilerek Hibrit CNN-GRU isimli çalışma gerçekleştirilecektir.

Kaynaklar

- [1] Twitter Sentiment Analysis | Kaggle, (n.d.). <https://www.kaggle.com/code/tenzintsega/twitter-sentiment-analysis> (accessed May 6, 2022).
- [2] U. Naseem, I. Razzak, K. Musial, M. Imran, Transformer based Deep Intelligent Contextual Embedding for Twitter sentiment analysis, *Futur. Gener. Comput. Syst.* 113 (2020) 58–69. <https://doi.org/10.1016/j.future.2020.06.050>.
- [3] D. Antonakaki, P. Fragopoulou, S. Ioannidis, A survey of Twitter research: Data model, graph structure, sentiment analysis and attacks, *Expert Syst. Appl.* 164 (2021) 114006. <https://doi.org/10.1016/j.eswa.2020.114006>.
- [4] F.E. Ayo, O. Folorunso, F.T. Ibharalu, I.A. Osinuga, Machine learning techniques for hate speech classification of twitter data: State-of-The-Art, future challenges and research directions, *Comput. Sci. Rev.* 38 (2020) 100311. <https://doi.org/10.1016/j.cosrev.2020.100311>.
- [5] A. Perti, M.C. Trivedi, A. Sinha, Development of intelligent model for twitter sentiment analysis, *Mater. Today Proc.* 33 (2020) 4515–4519. <https://doi.org/10.1016/j.matpr.2020.08.004>.
- [6] O.Y. Adwan, M. Al-Tawil, A.M. Huneiti, R.A. Shahin, A.A. Abu Zayed, R.H. Al-Dibsi, Twitter sentiment analysis approaches: A survey, *Int. J. Emerg. Technol. Learn.* 15 (2020) 79–93. <https://doi.org/10.3991/ijet.v15i15.14467>.
- [7] S.H. Biradar, J.V. Gorabal, G. Gupta, Machine learning tool for exploring sentiment analysis on twitter data, *Mater. Today Proc.* 56 (2022) 1927–1934. <https://doi.org/10.1016/j.matpr.2021.11.199>.
- [8] İ. MAYDA, B. DİRİ, T. YILDIZ, Türkçe Tweetler üzerinde Makine Öğrenmesi ile Nefret Söylemi Tespiti, *Eur. J. Sci. Technol.* (2021) 328–334. <https://doi.org/10.31590/ejosat.903854>.
- [9] aryum Bibi, W.A. Abbasi, W. Aziz, S. Khalil, M. Uddin, C. Iwendi, T.R. Gadekallu, A Novel Unsupervised Ensemble Framework using Concept-based Linguistic Methods and Machine Learning for Twitter Sentiment Analysis, *Pattern Recognit. Lett.* 158 (2022) 80–86. <https://doi.org/10.1016/j.patrec.2022.04.004>.
- [10] E. YAZĞILI, M. BAYKARA, Türkçe metinlerde makine öğrenmesi yöntemleri ile siber zorbalık tespiti, *Gümüşhane Üniversitesi Fen Bilim. Enstitüsü Derg.* 12 (2022) 443–453. <https://doi.org/10.17714/gumusfenbil.935448>.
- [11] Twitter Sentiment Analysis | Kaggle, (n.d.). <https://www.kaggle.com/datasets/arkhoshghalb/twitter-sentiment-analysis-hatred-speech> (accessed May 6, 2022).
- [12] twitter-sentiment-analysis | Kaggle, (n.d.). <https://www.kaggle.com/code/aayush349/twitter-sentiment-analysis> (accessed May 6, 2022).
- [13] Twitter Duygu/Konuşma Analizi ve Modelleme | kaggle, (n.d.). <https://www.kaggle.com/code/danielbeltsazar/twitter-sentiment-speech-analysis-and-modelling> (accessed May 6, 2022).
- [14] Clasificación sentimientos | Kaggle, (n.d.). <https://www.kaggle.com/code/joseangelroyolopez/clasificaci-n-sentimientos> (accessed May 6, 2022).
- [15] Hate Speech - Tweet Classification | Kaggle, (n.d.). <https://www.kaggle.com/code/isidronavarroporto/hate-speech-tweet-classification> (accessed May 6, 2022).
- [16] Twitter Sentiment Analysis - Bidirectional LSTM | Kaggle, (n.d.). <https://www.kaggle.com/code/rashmimanwani/twitter-sentiment-analysis-bidirectional-lstm> (accessed May 6, 2022).

- [17] Twitter Sentiment Analysis-sklearn | Kaggle, (n.d.). <https://www.kaggle.com/code/tracyporter/twitter-sentiment-analysis-sklearn> (accessed May 6, 2022).

Nesne Yönünün Ayırık Fourier Dönüşümü ile Belirlenmesi: Biber Örneği

Object Direction Detection Using Discrete Fourier Transform: A Pepper Sample

Sabit Babaoğlu^{*1} , Mehmet Emin Tağluk¹ 

¹Elektrik - Elektronik Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

(sabitbabaoglu@hotmail.com)

Özetçe— Görüntü işleme alanında yapılan çalışmalar son zamanlarda yaygınlaşmış ve birçok spesifik problemin çözümü için kullanışlı teknikler geliştirilmiştir. Bu çalışma kapsamında iki boyutlu ayırık Fourier dönüşümünden faydalanılarak, farklı biber resimleri üzerinde yön bulma algoritması geliştirilmiştir. Geliştirilen bu teknik, yapay zekâ uygulamalarına göre daha hızlı ve eğitim süreci gibi bir süreç gerekmektedir. 25 farklı resim üzerinde yapılan çalışma %100 başarı sağlamıştır. Her bir resim için bu işlemin uygulanması için gereken süre sadece yaklaşık 24 ms kadardır. Bu teknik endüstriyel proseslerde kullanılmak üzere geliştirilmiştir. Ayrıca bu yöntem ile nesnelerin düzlemdeki açıları da hesaplayabilmektedir. Geliştirilen yöntem mikrodenetleyicilere kodlanabilmekte ve böylece çeşitli uygulama alanlarına yönelik pratik çözüm üretilebilmektedir.

Anahtar Kelimeler : Görüntü işleme, iki boyutlu ayırık fourier dönüşümü, nesne yönü belirleme.

Abstract— Recently, studies in the field of image processing have become prevalent and useful techniques have been developed to solve many specific problems. In this study, a method that findind the spatial direction of Peppers different Pepper pictures by making use of the two-dimensional discrete Fourier transform. The developed technique is faster than existing artificial intelligence applications and does not require a training process. The work done on 25 different pictures has achieved 100% success. The time required to perform this operation for each image is only about 24 ms. This technique was developed for use in industrial processes. In addition, with this method, it can calculate the angles of objects in the plane. The developed method can be coded to microcontrollers and thus, practical solutions for various application areas can be produced.

Keywords : image processing, two dimensional discrete Fourier transform, object direction detection.

1.Giriş

Görüntü işleme süreçleri nesne algılama, nesne takip etme, bölgeleri ayırma, filtreleme ve boyut ölçme gibi işlemlerde kullanılmaktadır (Kotyza, Machacek, and Koziorek 2018; Kubo et al. 1998; Liu, Yang, and Lunga 2021; Qureshi et al. 2021; Shao et al. 2022; Tian, Liu, and Yang 2021; Wu, Gao, and Rohani 2021). Bu işlemlerden biri olan nesne algılama görüntü işlemedeki temel alanlardan birisidir (Tian et al. 2021). Nesne algılama işlemi, aşağıda belirtildiği gibi birçok alt alana uygulanabilir. Bu alanlara örnek olarak yaya uygulaması, yüz algılama, vücut hareketi algılama, sabit ve mobil nesne algılama, insan davranışı algılama ve otonom sürüş olarak sıralanabilir (Qureshi et al. 2021).

Resim işleme süreçlerinde robotik kolların kontrolü içinde ihtiyaç duyulmaktadır (Kubo et al. 1998; Wu et al. 2021). Bazı endüstriyel proseslerde nesnelerin yönlerinin hızlı ve doğru bir şekilde tespit edilmesi gerekmektedir (Kubo et al. 1998). Bu sistemlerin çoğunda model eşleştirme gibi mantıksal işlemler kullanılır (Kubo et al. 1998). Yapay sinir ağları kullanılarak yapılan çalışmalarda model eşleştirme yöntemlerinin daha düşük performansla sahip olduğu vurgulanmıştır (Kubo et al. 1998). Ancak mevcut çalışma iki boyutlu ayırık Fourier dönüşümünü kullanarak doğru ve hızlı sonuçlar üretmektedir.

Bu çalışma kapsamında iki boyutlu ayırık Fourier dönüşümü ile kamera tarafından alınan resimlerde yer alan nesne (burada ele alınan örnek Biber) yönlerinin (sağ-sol) tayin edilmesi amaçlanmıştır. 25 farklı biber resmi elde edilerek çalışma kapsamında kullanılmıştır. Endüstriyel süreçlerde kullanılması amaçlanan bu algoritma hızlı ve doğru bir şekilde nesnenin yönünü tayin etmeye odaklanmıştır. Endüstriyel proseslerde üretim bandı üzerinde ilerleyen nesnelere gereken işlemin yapılmasına olanak sağlanacaktır. Örneğin, biber salçası yapılan bir işletmede su-jeti ile biberlerin göbeğinin kesilmesi ve temizlenmesi işleminde kolaylıkla kullanılabilir. Manuel beslemeli bir biber temizleme makinesi Şekil 6'de görülmektedir. Bu makine biberler sırasıyla ve başları temizleme bölümüne gelecek şekilde yerleştirilmektedir. Önerilen bu yöntem bu biber dizme makinenin otomatikleştirilmesi için kullanılabilir.

Görüntü işleme proseslerinde yapay sinir ağlarının kullanılması karmaşık problemlerin çözümünü sağlamaktadır. Bu çalışmada kullanılan frekans bazlı yöntem çok daha hızlı sonuç üretmesi bakımından tercih edilmiştir. Bu işlem bilindiği gibi yapay sinir ağları kullanılarak da gerçekleştirilebilir ancak hem hız hem de öz hazırlık gerektirmemesi benzer problemlerin çözümünde Fourier tabanlı uygulamaların kullanılmasını daha verimli kılmaktadır. Ayrıca bu yöntem küçük bir RAM kapasitesine sahip mikrodenetleyicilerde bile kolaylıkla uygulanabilme özelliğine sahiptir.

Bilindiği üzere üretim tesislerinde bir yöntemin doğru sonuç üretmesi kadar hızlı olması da önemlidir. Sadece resmin Fourier dönüşümünün alınmasıyla çok daha hızlı ve basit bir şekilde sonuç verecek olan bu yöntem bu alanda yapay sinir ağlarına nispeten daha verimli olacağı düşünülmektedir. Bunun yanında ön hazırlık (yapay sinir ağı eğitimi) gerektirmemesi endüstriyel uygulamalarda bu yöntemi daha öne çıkaracağı tahmin edilmektedir. Ayrıca bu yöntem tekstil işletmelerinden Ring İplik işletmelerinde bulunan bobin makinelerinde, kops haznesine dökülen kopsların yönlerinin belirlenmesi işleminde de kullanılabileceği düşünülmektedir.

2. Materyal Metot

Endüstriyel süreçlerde kullanılmak üzere, nesne yönlerinin hızlı ve doğru bir şekilde tayin edilmesini amaçlanan bu çalışma kapsamında tarafımızdan 25 adet farklı biber resmi çekilmiş ve önerdiğimiz bu algoritma uygulanmıştır. Büyüklükleri, şekilleri ve renkleri birbirinden farklı olan bu örnek biber resimleri Şekil 3'de sunulmuştur.

Bu çalışmada amaçlanan işlemin gerçekleştirilmesi için öncelikle, verilen nesnenin/nesnelerin imgeleri Şekil 3'de sunulan resim gibi siyah-beyaz resimler dönüştürülür nesne (A) ve Şekil 1'de sunulan şablon (B) resimlerinin iki boyutlu ayırık Fourier dönüşümleri elde edilmiştir. Daha sonra Fourier dönüşümlerinin eleman elamana çarpımının ayırık ters Fourier dönüşümleri elde edilir. Ardından bu dönüşümün reel kısımları elde edilir. Bu süreç Denklem 1 verilmiştir.

$$C1 = Re(\overline{\mathcal{F}_2}(\mathcal{F}_2(A) \cdot \mathcal{F}_2(B))) \quad (1)$$

Burada $\mathcal{F}_2$ iki boyutlu Fourier transformu ve $\overline{\mathcal{F}_2}$ iki boyutlu ters Fourier transformu ifade etmektedir. Aynı işlem de A matrisini 180 derece dönderip ($Q_{180}(A)$) Denklem 2'deki yapılabilir.

$$C2 = Re(\overline{\mathcal{F}_2}(\mathcal{F}_2(Q_{180}(A)) \cdot \mathcal{F}_2(B))) \quad (2)$$

Burada $Q_x(.)$ saat yönünde x derece döndürme operatörü olarak tanımlanmıştır




Şekil 1. Kullanılan biber resmi (A matrisi) ve şablonu (B matrisi).

$C1$ ve $C2$ matrislerinin elde edilmesinin ardından Denklem 3’de gösterilen eşitsizlik kullanılarak nesne yönü tayin edilir.


$$y\ddot{o}n = \begin{cases} sa\ddot{g}, & \max(C1) > \max(C2) \\ sol, & \max(C1) < \max(C2) \end{cases} \quad (3)$$

Yukarıda açıklanan metodun Şekil 3’de sunulan resimlere uygulaması sonucunda Şekil 4’de gösterilen resimler elde edilmiştir. Resimlerde görüleceği gibi biberlerin yönleri tayin edildikten sonra siyah-beyaz olarak gösterilen biber resimleri üzerine yazdırılmıştır. Tüm resimler incelendiğinde biber başlarının yönlerinin doğru bir şekilde tespit edildiği görülür.


Burada kullanılan yöntemin (algoritmanın) akış diyagramı Şekil 2’de görülmektedir. Bu işlemlerin kolay ve uygulanabilir yapısından dolayı mikrodenetleyici ve mikroişlemcilerde kolaylıkla kodlanabilir. Ayrıca çok hızlı çalışması sebebiyle robotik uygulamalarda ve endüstride yön bulma işlemlerinde verimli olacağı düşünülmektedir.




Şekil 2. Yöntemin akış diyagramı.




Şekil 3. Çalışmada kullanılan örnek resimler.



Şekil 4. Resim işleme prosesi sonrası oluşan yönsel çıktılar.





Şekil 5. Resim işleme prosesi sonrası oluşan açısal çıktılar.

Bu çalışmada kullanılan yöntemle nesne yönünün sağa doğru mu yoksa sola doğru mu olduğuna karar verilir. İki yön için yapılan bu çalışmayı daha fazla yön için genişletmek mümkündür. Ancak bu çalışmada Şekil 6’ de görüleceği biber işleme fabrikalarında bulunan bant üzerinde muhtemel iki yön bulunması nedeniyle iki yön için yapılmıştır.

Bu çalışma kapsamında ayrıca biber yönleri $x=10^\circ$ ’ar derecelik açılarla taranarak biber yönü açı olarak da hesaplanmıştır. Bu işlem ise yaklaşık 155 ms kadar zaman almıştır. Şekil 5’de biber yönleri açı olarak hesaplanmış resim üzerine yazdırılmıştır.



Şekil 6. Manuel beslemeli örnek biber temizleme makinesi (Bigtem Makine A.Ş. tarafından üretilmiştir).

3. Sonuçlar ve Tartışma

Endüstriyel süreçlerde nesne yönlerinin bulunması için ortaya koyulan bu çalışmanın sonuçlarına göre 25 farklı biber resmi tarafımızca elde edilerek mevcut çalışma yapılmıştır. Bu çalışma neticesinde bütün biberlerin yönleri sözü edilen işlem sayesinde doğru ve hızlı bir şekilde belirlenmiştir. Her bir resim için bu işlem yaklaşık 24 ms kadar bir sürede tamamlanmıştır. Ayrıca bu algoritma mikrodenetleyicilere kodlanarak kolaylıkla çalıştırabilir. Bu yöntem bant üzerinde ilerleyen nesneler üzerinde işlem yapan tesislerde kullanılabilir. Hızlı ve doğru sonuçlar üretmesi, ön işlem gerektirmemesi diğer yöntemlerden daha kullanışlı olabileceği düşünülmektedir. Söz konusu yöntemin yön bulmaya dayalı birçok endüstriyel süreçler için de kullanılabileceği tahmin edilmektedir.

3. Kaynaklar

- Kotyza, J., Z. Machacek, and J. Koziorek. 2018. “Detection of Directions in an Image as a Method for Circle Detection.” *IFAC-PapersOnLine* 51(6):496–501. doi: 10.1016/J.IFACOL.2018.07.109.
- Kubo, T., M. Obuchi, G. Ohashi, and Y. Shimodaira. 1998. “Image Processing System for Direction Detection of an Object Using Neural Network.” Pp. 571–74 in *IEEE. APCCAS 1998. 1998 IEEE Asia-Pacific Conference on Circuits and Systems. Microelectronics and Integrating Systems. Proceedings (Cat. No.98EX242)*.
- Liu, Tao, Lexie Yang, and Dalton Lunga. 2021. “Change Detection Using Deep Learning Approach with Object-Based Image Analysis.” *Remote Sensing of Environment* 256:112308. doi:

10.1016/J.RSE.2021.112308.

- Qureshi, Kashif Naseer, Omprakash Kaiwartya, Gwanggil Jeon, and Francesco Piccialli. 2021. "Neurocomputing for Internet of Things: Object Recognition and Detection Strategy." *Neurocomputing*. doi: 10.1016/J.NEUCOM.2021.04.140.
- Shao, Feifei, Long Chen, Jian Shao, Wei Ji, Shaoning Xiao, Lu Ye, Yueting Zhuang, and Jun Xiao. 2022. "Deep Learning for Weakly-Supervised Object Detection and Localization: A Survey." *Neurocomputing*. doi: 10.1016/J.NEUCOM.2022.01.095.
- Tian, Gangyi, Jianran Liu, and Wenyuan Yang. 2021. "A Dual Neural Network for Object Detection in UAV Images." *Neurocomputing* 443:292–301. doi: 10.1016/J.NEUCOM.2021.03.016.
- Wu, Yuanyi, Zhenguo Gao, and Sohrab Rohani. 2021. "Deep Learning-Based Oriented Object Detection for in Situ Image Monitoring and Analysis: A Process Analytical Technology (PAT) Application for Taurine Crystallization." *Chemical Engineering Research and Design* 170:444–55. doi: 10.1016/J.CHERD.2021.04.013.

Pirinç Türlerinin HOG Temelli Öznitelik Vektörleri ve Farklı Makine Öğrenme Teknikleriyle Sınıflandırılması

Classification of Rice Species with HOG-Based Feature Vectors and Different Machine Learning Techniques

Musa KAPLAN¹ , Emrullah ACAR² , Ömer TÜRK³ 

¹ Cizre Meslek Yüksekokulu Bilgisayar Teknolojileri Bölümü, ŞIRNAK Üniversitesi, Şırnak, TÜRKİYE

² Elektrik - Elektronik Mühendisliği Bölümü, BATMAN Üniversitesi, Batman, TÜRKİYE

³ Mardin Meslek Yüksekokulu Bilgisayar Teknolojileri Bölümü, MARDİN ARTUKLU Üniversitesi, Mardin, TÜRKİYE

(musakaplan@sirnak.edu.tr, emrullah.acar@batman.edu.tr, omerturk@artuklu.edu.tr)

Özetçe

Pirinç dünyada en çok üretilen tahıl ürünleri arasında yer almaktadır. Pirinç türleri bazı özelliklerinden dolayı birbirinden ayrılmaktadır. Pirinç türleri çeşitli morfolojik özelliklerine göre sınıflandırmak mümkündür. Bu çalışmada Türkiye'deki 5 farklı pirinç türünün sınıflandırılması amaçlanmıştır. Bu çeşitlerin her birinden 15000 imge toplamda 75000 imge görüntüsü kullanılmıştır. Bu görüntülerden toplamda 81 öznitelik çıkarılmıştır. Öznitelik çıkarımı için HOG algoritması kullanılmış olup k-NN ve DVM teknikleri yardımıyla sınıflandırma yapılmıştır. Sınıflandırma başarı oranı %95,5 olarak bulunmuştur.

Anahtar Kelimeler: Sınıflandırma, k-NN, DVM, histogram, hog.

Abstract

Rice is among the most produced grain products in the world. These varieties differ from each other due to some characteristics. It is possible to classify rice according to various morphological features. In this study, it is aimed to classify 5 different rice species in Turkey. 15000 images from each of these varieties, a total of 75000 image images were used. A total of 81 features were extracted from these images. HOG algorithm was used for feature extraction and classification was made using k-NN and DVM techniques. Classification success rate was found to be 95,5%.

Keywords : Classification, k-NN, DVM, histogram, hog.

1.Giriş

Tarımsal alanda uygulanan görüntü işleme ve bilgisayarlı görü uygulamalarının manuel çalışmalara göre düşük maliyetli olmalarından dolayı ilgi görmektedir (Cinar& Koklu 2022). Elle yapılan geleneksel çalışmalara göre görüntü işlemeye dayanan bilgisayarlı görü uygulamalarının avantajları vardır (Juliano,1993). Çoğu sınıflandırma yöntemin olduğu gibi tarımda da manuel yöntemlerle tahılları sınıflandırmak insan tecrübesi ile sınırlı olduğu için hem maliyetli hem de zaman almaktadır. İnsan tecrübesine dayalı sınıflandırmalar yapmak ve büyük ölçekte değerlendirmeler yapmak hem zor hem de devamlılık göstermeyecektir. Pirinç; buğday ve mısır ile beraber dünyadaki en önemli tahıl ürünlerindendir. Pirincin besleyici olması ve ekonomik anlamda ciddi bir katma değere sahip olması bütün dünyada büyük bir öneme kazanmaktadır. Bütün bu nedenlerden dolayı endüstride yaygın olarak kullanılmaktadır (Mahajan & Sardana 2015; Cinar& Koklu 2022; Juliano,1993). Ülkemizde pirinç üretimi için çeşitli kalite kriterleri mevcuttur. Bunlar fiziksel görünüm, pişirme özellikleri, aroma, tat ve koku gibi özelliklerin yanında verimlilik gibi konulardır. Nihai tüketici açısından bakıldığında, market raflarında ambalajlı olarak satılan pirinç çeşitlerinde öne çıkan kriterlerden ilk akla gelen fiziksel görünüm özelliğidir (Cinar& Koklu 2022). Üretimden sonra özellikle yüksek üretim hacmine sahip olanlar açısından pirincin kalibrasyonu, çeşitlerinin belirlenmesi ve çeşitli kalite unsurlarının ayrılmasının verimsiz ve zaman alıcı olması nedeniyle teknolojik yöntemlere olan ihtiyacın arttığı

görülmektedir (Cinar & Koklu, 2022; Juliano, 1993; Aukkapinyo et al, 2019). Bu nedenle son zamanlarda makine görme sistemleri ve görüntü işleme teknikleri kullanılarak tahıl ürünleri üzerine yapılan çalışmalara bakıldığında ürünlerin renk, doku, kalite ve boyut gibi birçok fiziksel özellik açısından incelendiği görülmektedir (Juliano, 1993; Aukkapinyo et al, 2019). Makine öğrenimi algoritmaları, büyük miktarda verinin hızlı ve güvenilir bir şekilde analiz edilmesini sağlar. Pirinç üretiminde bu tür yöntemlerin kullanılması, nihai ürünün kalitesinin artırılması ve gıda güvenliği kriterlerinin otomatik, ekonomik, verimli ve tahribatsız bir şekilde karşılanması açısından önemlidir. Literatürde görüntü işleme ve makine öğrenmesi kullanan yöntemler incelenmiştir. Uygulamada, pirinç çeşitleri veri setinden elde edilen imgeler ön işlem den geçirilmiş olup öznelik verileri elde edilmiştir. Elde edilen öznelikler farklı sınıflandırma yöntemleri kullanılarak elde edilen sonuçlar değerlendirilmiştir. Farklı özneliklerin çıkarılması ve çeşitli sınıflandırma yöntemlerinin kullanılması uygulama farklılığını ortaya çıkarmaktadır. Literatürde, pirinç çeşitleri ve pirinç hastalıklarını sınıflandırma alanında kapsamlı araştırmalar yapılmış ve çeşitli yaklaşımlar ortaya çıkarılmıştır (Cinar & Koklu, 2022; Juliano, 1993; Aukkapinyo et al, 2019).

Bu çalışmalardan bazıları sırasıyla aşağıda özetlenmiştir.

Joshi ve Jadhav, çeltik hastalıklarının tanımlanması ve sınıflandırılması için yeni bir yöntem çalışmışlardır. Çeltik yanıklığı, bakteriyel yanıklık, kahverengi yaprak lekesi ve sap çürüklüğü olmak üzere dört hastalığın tanımlanmasını ve sınıflandırılmasını yapmışlardır. Hastalıklı bölümün şekil, renk gibi farklı özelliklerini, geliştirdikleri bir algoritma ile çıkartmışlardır. Çıkarılan tüm özellikleri, hastalıklara göre gruplandırmışlardır. Hastalıkları, MDC (Minimum Distance Classifier) ve k-NN (k-Nearest Neighbor Classifier) sınıflandırıcılarını kullanarak sınıflandırmışlardır. 115 görüntü kullandıkları çalışmalarında, her hastalık için sınıflandırma doğruluğunu k-NN için %87.02 ve MDC için %89.23 elde etmişlerdir (Devi & Neelamegam, 2018; Kaymaz, 2007). Phadikar ve Sil (2008), hastalıklı çeltik görüntüleri üzerinde yaprak yanıklığı ve kahverengi yaprak lekesi hastalıklarının tespitini yapmışlardır. Görüntü işleme teknikleri ile hastalıklı ve hastalıklı olmayan bölümleri tespit etmişlerdir. Yaprığın hastalıklı kısmını, sinir ağı ile %70 doğrulukla başarılı bir şekilde sınıflandırmışlardır (Devi & Neelamegam, 2018; Kaymaz, 2007; Acar & Özerdem, 2013). Islam vd., çeltik bitki hastalıklarının tanımlanması ve sınıflandırılması için yeni bir yöntem çalışmışlardır. Çalışmalarında, hastalıklı bölümün RGB değerinin yüzdesine dayanarak, görüntü işleme teknikleri ile hastalıkları tespit etmiş ve tanımlamışlardır. Yalnızca bir özellik kullanarak üç çeltik bitkisi hastalığını başarıyla tanımlamış ve sınıflandırmışlardır. Bu yöntemin daha az zaman gerektirdiğini ve daha hızlı olduğunu bildirmişlerdir (Phadikar & Das, 2013; Joshi & Jadhav, 2016; Devi & Neelamegam, 2018). Devi ve Neelamegam, çeltik yapraklarındaki hastalıkları otomatik olarak tanımak için görüntü işleme tekniklerini kullanarak bir yaklaşım sunmuşlardır. Hastalıklı ve hastalıklı olmayan bitkilerin sınıflandırılması için çok sınıflı DVM (Multiclass DVM), Naive Bayesian, geri yayılım sinir ağı (Back Propagation Neural Network) ve KNN (K Nearest Neighbor Neural Network) kullanmışlardır. Çok sınıflı DVM'nin %98.63 doğrulukla diğer sınıflandırıcılarla karşılaştırıldığında daha iyi doğruluk sağladığını belirlemişlerdir (Joshi&Jadhav, 2016; Devi & Neelamegam, 2018). Ramesh ve Vydeki, çeltik yetiştiriciliğinin erken evresindeki yaprak yanıklığı hastalığını belirlemek için bir metod sunmuşlardır (Prajapati et al, 2017). Çeltik tarlasının görüntülerinden hastalıklı ve hastalıklı olmayan bitkileri belirlemek için sekiz özellik çıkarmışlardır. Hastalıklı ve hastalıklı olmayan bitkilerin sınıflandırılması için k-NN (K Nearest Neighbor Neural Network) ve ANN (Artificial Neural Network) kullanmışlardır. Bu iki sınıflandırma tekniğinin performansını hata matrisi ile karşılaştırmışlardır. Yaprak yanıklığı hastalığının sınıflandırma başarısını KNN için %85 ve ANN için %99 bulmuşlardır. Önerilen metodun, yaprak yanıklığı hastalığını başarılı bir şekilde tespit ettiğini ve ürün kaybını azalttığını belirtmişlerdir. Bera vd., görüntü işleme ve veri madenciliği tekniklerini kullanarak farklı çeltik hastalıklarını tanımlamışlardır. Görüntü işleme tekniklerini, görüntünün hastalıklı bölümünü ve hastalıkla ilgili özellikleri çıkarmak için uygulamışlardır. Veri madenciliği tekniklerini ise çıkarılan özelliklere dayanarak hastalık tespitinde yararlı olan gizli bilgileri çıkarmak için kullanmışlardır. Çiftçilerin, bitkileri hastalıklardan koruyabilmeleri ve kısa sürede doğru uygulamaları yapabilmeleri için bu tekniklerin faydalı olduğunu bildirmişleridir (Devi & Neelamegam, 2018 ; Bera et al, 2019). Liang vd., çeltiğin önemli hastalıklarından olan yaprak yanıklığı hastalığının tanınması için evrimsel sinir ağı (CNN) modelini kullanmışlardır. Modelin eğitimi ve testi için toplam 5808 örnekten oluşan veri kümesi oluşturmuşlardır. Önerilen modelin etkinliğinin değerlendirilmesinde kalitatif ve kantitatif

analizler için karşılaştırmalı deneyler yapmışlardır. Modelin çeltik yaprak yanıklığı hastalığını tanımasında en iyi performansı gösterdiğini ve pratik uygulamalarda potansiyel olarak kullanılabileceğini bildirmişlerdir (Devi & Neelamegam, 2018; Liang et al, 2019). Tarımda üretim ve verimliliği artırmak için hızlı ve doğru kararlar alabilme esas gerekliliklerdir. Geleneksel yöntemlerle çeltik bitkisini sınıflandırmak insan gözlemlerine dayalı olduğu için maliyetli ve sağlıksızdır. Makine öğrenme teknikleriyle bu işlemler hem daha hızlı, tutarlı ve daha maliyetle çözülebilir (Kiratiratanapruk et al, 2020).

Bu çalışmada 5 farklı pirinç türü ele alınarak sınıflandırma yapmak amaçlanmıştır. Bu farklı imgelerden öznitelik vektörü çıkarmak için HOG (Histogram of Oriented Gradients- Yönlendirilmiş Gradyanların Histogramı) algoritması kullanılmış olup, histogram eşitleme ve çok boyutlu görüntülerin filtreleme özellikleri kullanılmıştır. HOG özellikle benzer piksellere sahip görüntülerden iyi bir sınıflandırma başarımları çıkardığı için örüntü tanıma çalışmalarında yaygın olarak kullanılmaktadır. Sonuç olarak, beş farklı pirinç türü için HOG tabanlı öznitelik algoritması kullanılmış, k-NN ve DVM teknikleriyle sınıflandırma işlemi 5 farklı kategoride gerçekleştirilmiştir.


2. MATERYAL VE METOT

2.1. Veri Toplama

Bu çalışmada kullanılan pirinç bitkisi imgeleri kaggle (Kaggle, 2022) internet sayfasından elde edilmiştir. Bu çalışmada Arborio, Basmati, Ipsala, Jasmine ve Karacadağ türünde 5 sınıfa ait toplam 75000 imge kullanılmış olup her sınıfa ait 15000 tane görüntü kullanılmıştır.

2.2. Önerilen Sınıflandırma Yöntemi

Çalışmada önerilen sınıflandırmaya ait akış şeması Şekil 1’de gösterilmiştir.



Şekil 1. Kullanılan Akış Diyagramı

Yukarıdaki şekilde giriş verisi olarak Arborio, Basmati, İpsala, Jasmine ve Karacadağ isiminde 5 pirinç türüne ait görüntüler matlab ortamında işlenmiştir. Bu görüntülere HOG algoritması uygulanarak öznitelikler elde edilmiştir. Elde edilen öznitelikler k-NN ve DVM sınıflandırıcıları ile sınıflandırılmıştır.

2.3. Öznitelik Çıkarma

Çalışmanın bu aşamasında, beş pirinç türünün imgelerine ait dokulardan öznitelik vektörü çıkarmak için, benzer görüntü piksellerinden yüksek başarımlı sonuçlar elde eden HOG tabanlı algoritma kullanılmıştır. Bu algoritmanın tercih edilmesinin nedeni pirinç türlerinin benzer görünümdeki imgelere sahip olması ve benzer imge durumlarında bu algoritmanın yüksek başarımlı sonuçlar elde etmesidir.

2.4. Yönlü Gradyan Histogramı (HOG) Algoritması

Bir özellik tanımlayıcı ve öznitelik çıkarma yöntemlerinden biri olan HOG algoritması Shashua ve Dalal tarafından ilk defa kullanılmıştır (Acar & Özerdem2016; Dalal & Triggs, 2005). HOG algoritması bir görüntüyü lokal histogramların serisi olarak tanımlar. Görüntü üzerinde belirli bir alanda hesaplanan ve belirli bir yönde oluşan gradyanların dağılımı lokal histogramı oluşturmaktadır. HOG algoritması özellik hesaplamaları için bir gradyanın büyüklüğünü ve açısını kullanarak nesnenin yapısı ve şekline

odaklandığı için kenar tanımlayıcıdan daha iyidir. İmge bölgeri üzerinde gradyan büyüklüğü ve yönelimleri kullanarak histogramlar üretir. Öznitelik çıkarma işlemleri için HOG algoritması kullanılmış olup sırasıyla üç aşamadan oluşmuştur (Aukkapinyo et al, 2019).

Gradyan Hesaplama

Birinci aşamadan imge üzerindeki her bir noktanın yatay ve dikey gradyan değerleri $f_k(k,z)$ ve $f_z(k,z)$ Denklem 1 ve 2’de hesaplanmıştır.

$$f_k(k,z) = I(k+1,z) - I(k-1,z) \quad (1)$$

$$f_z(k,z) = I(k,z+1) - I(k,z-1) \quad (2)$$


Denklem 3 ve 4’te kullanılan $I(k,z)$ ifadesi (k,z) noktasındaki parlaklığı ifade etmektedir. Gradyanların büyüklüğünü hesaplama $m(k,z)$ ve gradyan yönü $\theta(x,y)$ Denklem 3 ve 4’teki eşitliklerle ifade edilmiştir.

$$m(k,z) = \sqrt{f_k(k,z)^2 + f_z(k,z)^2} \quad (3)$$

$$Q(k,z) = \arctan \frac{f_k(k,z)}{f_z(k,z)} \quad (4)$$

Histogram Hesaplama

Bu aşamadan sonra histogram hesaplaması yapılır. Histogram hesaplaması için, $\theta(k,z)$ 0 ile 180 derece veya 0 ile 360 derece arasında eşit bölgeler şeklinde ayrılma işlemi gerçekleştirilebilir. Gradyan yön bölgeleri 0 ile 180 derece arasında seçilmiş olup 20 derecelik açı farkıyla 9 bölge olarak elde edilmiştir. Şekil 2’de histogramların oluşturulması gösterilmiştir.



Şekil 2. Histogramların oluşturulması (Acar& Özerdem, 2016).


Hücre içerisindeki piksellerin sahip olduğu gradyan büyüklüğü mevcut açılara göre dağıtılıp bu dağıtım yöntemi lineer ve trilineer interpolasyon tekniği yapılır (Aukkapinyo et al, 2019; Acar & Özerdem2016; Dalal &Triggs, 2005). Çalışma lineer interpolasyon tekniği kullanılarak yapılmıştır.

Blok Normalizasyonu

Büyük bir histogramın elde edilebilmesi için herhangi bir blok içerisindeki tüm histogramların birleştirilmesi gerekir. Bu aşamadan sonra histogram normalizasyon işlemi yapılır. Blok normalizasyonunun eşitliği Denklem 5’te verilmiştir.

$$v = \frac{V_x}{\sqrt{\|V_x\|^2 + 1}} \quad (5)$$

Normalize edilmiş HOG öznitelik vektörleri v ile gösterilirken, V_x ise bir bloktan elde edilen histogramı gösterir. Histogram bölmelerinin oluşturulabilmesi için R-HOG üzerindeki işaretsiz gradyanların hesaplanması gerekir. L2-Norm yardımıyla normalizasyon işlemleri gerçekleştirilmiştir. Bir adet yerel histogram oluşturmak için, imge 3x3 dikdörtgen hücreye bölünüp her bir hücreden (540x960 piksel) şeklindeki pikseller kullanılmıştır. Yapılan bu işlemlerin sonucunda hücre başına 9 histogram bölmesi ($180^\circ/20^\circ = 9$) elde edilmiş olup hesaplanma işlemleri için 9 yerel histogram bölmesinin birleştirilmesiyle $(9 \times 9) = 81$ birim uzunluğundaki HOG öznitelik vektörü sınıflandırıcıların girişlerine verilmiştir (Dalal&Triggs, 2005; Kadota&Sugano, 2009; Ludwig et al, 2009). Hog temelli öznitelik vektörünün oluşturulması Şekil 3'te gösterilmiştir.



Şekil 3. Hog Temelli Öznitelik Vektörünün Oluşturulması (Acar & Özerdem, 2016).

Verilerin dönüşümü tamamen MATLAB uygulaması kullanılarak matrisler elde edildi. Elde edilen matris dosyası ile gerekli sınıflandırma işlemleri yapıldı. Her bir eğitim ve test veri kümesi için ayrı ayrı olarak öznitelikler oluşturuldu. Her bir veri kümesi için oluşturan hogvector kendi veri grubu adıyla kaydedilmiştir.

2.6. k-EN Yakın Komşu Algoritması

K en yakın komşu algoritması sınıflama ve regresyonda kullanılabilen çok yönlü bir algoritma olup denetimli öğrenme yöntemlerinden biridir. k-NN genelde sınıflandırma yöntemi için kullanılan bir modeldir. Uzaklık ölçümü için bilinmeyen bir sınıftaki veri eğitim setindeki diğer verilerle karşılaştırılıp bu şekilde uzaklık ölçümü yapılmaktadır. Herhangi bir sınıfa atanamamış olan veri hesaplanan uzaklığa göre en optimal sınıfa atanır. k-NN algoritmasında her yeni örnek için en yakın komşu kümesi tekrardan aranmaktadır. K en yakın komşu algoritmasında sınıfın özellikleri ve değeri önceden belirtilir. k-NN de kullanılan sınıf değeri verilerin boyut ve yapısına bağlı olarak değişmektedir. k değeri 1 den n değerine kadar değişebilmektedir. Çok büyük ve çok küçük k değerleri kullanmak düşük doğruluk değerlerinin elde edilmesine neden olacaktır (Kaymaz, 2007; Dilki & Başar, 2020).

2.7. Destek Vektör Makinesi

Sınıflandırma ve regresyon için denetimli öğrenme yöntemlerinden biri olan destek vektör makineleri klasik makine öğrenme yöntemlerinden biri olup büyük ve çok alanlı uygulamalarda sınıflandırma yapmaya yarayan bir algoritmadır. DVM algoritmasının amacı gelecek olan yeni bir veri noktasını doğru bir kategoriye koyabilmek için n boyutlu bir uzayda sınıflara ayırabilen ve en iyi karar sınırlarını hiperdüzlem denilen yöntem ile bulmaktır. İki veri noktasını ayırmak için iki sınıfın veri noktaları arasındaki en yüksek mesafeye sahip düzlemi bulmaktır. Veri noktalarının daha güvenli bir şekilde sınıflandırılabilmesi için marj mesafesini en yüksek düzeye çıkarmak gerekir. Karar sınırları yani hiper düzlemin her bir tarafına düşen veri noktaları farklı sınıflar anlamına gelmektedir. İki kategoriden birine ait olan bir dizi etiketlenilmiş eğitim örneği verildiğinde destek vektör makinesi bunları ikili lineer sınıflandırıcı durumuna getirip iki kategoriden herhangi birine yeni örnekler atayan bir model haline getirir. Destek vektör makineleri doğrusal ve doğrusal olmayan sınıflandırmaları gerçekleştirebilmektedir (Suthaharan, 2016).

3. BULGULAR VE TARTIŞMA

Öznitelik parametreleri kullanılarak, k-NN ve DVM sınıflandırıcılara ilişkin performans değerleri bu aşamada hesaplanmıştır. Çalışmada k-NN ile yapılan sınıflandırma başarı oranı %95,5 iken DVM ile yapılan sınıflandırmada başarı oranı %94,4 olarak bulunmuştur.

Tablo 1’de k-NN sınıflandırıcısının farklı komşu (k) değerleri için performans bilgileri verilmiştir. Sınıflandırıcı için en yakın komşu sayısı (k), 1 ile 10 değer aralığında alınmış olup ortalama değeri sunulmuştur.

Tablo 1’deki değerler her bir k-NN sınıflandırma için çalıştırıldı. k değerleri 1-10 aralığında ele alındı ve her bir k değeri için elde edilen sonuç yuvarlanarak Tablo 1’de verilmiştir. Bu çalışma için en yüksek başarı oranı k=1 değeri için elde edilmiştir. Tabloya bakıldığında genel olarak başarı oranlarının birbirine yakın olduğu görülmüştür. Çalışmada genel olarak yüksek bir başarı oranı elde edilmiştir.

Tablo 1. k-NN sınıflandırıcı performansı

Komşu Sayısı (k)	Ortalama Performans
1	% 94,84
2	%94,15
3	% 95,59
4	% 95,56
5	% 95,77
6	% 95,70
7	% 95,8
8	% 95,73
9	% 95,76
10	% 95,76

k-NN ve DVM ile yapılan sınıflandırma ile elde edilen sonuçlar kontrol edilip yapılan sınıflandırmanın başarı oranı bulunmuştur. Başarı yüzdesinin yüksek olması doğru veri seçimi yapıldığını ve sınıflandırma performansının yüksek olduğunu gösterir. Doğru veri seçimi yapılmadığı takdirde sınıflandırma performansının yüksek olması beklenmez. Başarı oranının düşük olması üzerinde çalışılan veri setinin iyi olmadığı veya farklı sınıflandırma metotları denenebileceğini gösterir. k-NN sınıflandırıcı model başarı ölçümü Tablo 2’de verilmiştir.

Tablo 2. k-NN Sınıflandırıcı model başarı ölçümü

Sınıf	Kesinlik	Duyarlılık	F-skör
Arborio	0.94	0.90	0.92
Basmati	0.97	0.98	0.98
Ipsala	1.00	0.99	0.99
Jasmine	0.96	0.96	0.96
Karacadağ	0.92	0.96	0.94

Tablo 2’de beş farklı pirinç türü için k-NN ile model başarı ölçümü sonucu en yüksek ve en düşük kesinlik, duyarlılık ve F-skör değerleri elde edilmiştir. k-NN ile model başarı ölçümü sonucu en yüksek kesinlik Ipsala pirinç türünde iken en düşük kesinlik ise Karacadağ’dadır. En yüksek duyarlılık Ipsala pirinç türünde en düşük duyarlılık ise Arborio pirinç türündedir. F-skör en yüksek Ipsala pirinç

türünde iken en düşük f-skor Arborio pirinç türündedir. Genel olarak tablo incelendiğinde kesinlik, duyarlılık ve f-skor da en yüksek değerler Ipsala pirinç türüne aittir.

Tablo 3'te beş farklı pirinç türü için DVM ile model başarımlar ölçümü sonucu en yüksek ve en düşük kesinlik, duyarlılık ve F-skor değerleri elde edildi. DVM ile model başarımlar ölçümü sonucu en yüksek kesinlik Ipsala pirinç türünde iken en düşük kesinlik ise Karacadağ ve Jasmine pirinç türlerinde elde edilmiştir. En yüksek duyarlılık Ipsala pirinç türünde, en düşük duyarlılık ise Arborio pirinç türünde bulunmuştur. F-skor en yüksek Ipsala pirinç türünde iken en düşük f-skor Arborio pirinç türünde elde edilmiştir. Genel olarak tablo incelendiğinde kesinlik, duyarlılık ve f-skor da en yüksek değerler Ipsala pirinç türüne bulunmuştur. Düşük metrik değerlerin ait olduğu pirinç türleri değişkenlik göstermektedir.

Tablo 3. DVM Sınıflandırıcı model başarımlar ölçümü

Sınıf	Kesinlik	Duyarlılık	F-skor
Arborio	0.93	0.89	0.91
Basmati	0.96	0.95	0.95
Ipsala	1.00	0.99	0.99
Jasmine	0.92	0.93	0.92
Karacadağ	0.92	0.96	0.94

4. SONUÇLAR VE ÖNERİLER

Pirinç en önemli gıda ürünlerinden biri olup dünyada ve ülkemizde gün geçtikçe gıdaya olan talep artmaktadır. Bu çalışmada, farklı pirinç türlerinden elde edilen öznelik vektörleri ve makine öğrenme yaklaşımı ile pirinç çeşitlerinin sınıflandırılması amaçlanmıştır. Çalışmada kullanılan veri seti 75000 görüntüden oluşmaktadır. Önerilen sınıflandırma sistemi birkaç aşamadan oluşmaktadır. İlk aşamada, HOG algoritması kullanılarak her bir pirinç türüne ait görüntülerden 81 birim öznelik vektörü çıkarılmıştır. İkinci aşamada, makine öğrenme teknikleri olarak k-NN ve DVM sınıflandırıcıları kullanılmıştır. Sonraki aşamada, elde edilen HOG öznelik vektörleri bu sınıflandırıcıların girişlerine verilmiş ve sonuç olarak ortalama %94,4-95,8 arasında doğruluk elde edilmiştir.

Bu çalışmanın devamı olarak, ilerleyen zamanlarda daha fazla imge ve yeni pirinç türleri eklenerek farklı derin öğrenme mimarileri yardımı ile yeni bir sınıflandırma sistemi hedeflenmektedir.

Kaynaklar

Koklu, M., Cinar, I., & Taspınar, Y. S. (2021). Classification of rice varieties with deep learning methods. Computers and Electronics in Agriculture, 187, 106285.

Cinar, I., & Koklu, M. (2021). Determination of Effective and Specific Physical Features of Rice Varieties by Computer Vision In Exterior Quality Inspection. Selcuk Journal of Agriculture and Food Sciences, 35(3), 229-243.

Cinar, I., & Koklu, M. (2022). Identification of Rice Varieties Using Machine Learning Algorithms. Journal of Agricultural Sciences, 9-9.

Mahajan, S., Das, A., Sardana, H.K., 2015. Image acquisition techniques for assessment of legume quality. Trends Food Sci. Technol. 42 (2), 116–133.

Juliano BO (1993). Rice in human nutrition, Int. Rice Res. Inst.

- Aukkapinyo, K., Sawangwong, S., Pooyoi, P., Kusakunniran, W., 2019. Localization and classification of rice-grain images using region proposals-based convolutional neural network. *Int. J. Autom. Comput.* 1–14
- Acar, E., & Özerdem, M. S. (2016). Tarımsal imge dokularından HOG algoritması ile öz nitelik çıkarımı ve öz nitelik tabanlı toprak neminin tahmini. *Anatolian Science-Bilgisayar Bilimleri Dergisi*, 1(1), 1-7.
- N. Dalal and B. Triggs "Histograms of oriented gradients for human detection", *Proc. IEEE Computer Soc. Conf. Comput. Vis. Pattern Recognit.*, pp.886 -893 2005.
- R. Kadota and H. Sugano "Hardware architecture for HOG feature extraction", *Proc. 5th Int. Conf. Intell. Inf. Hiding Multimedia Signal*, pp.1330 -1333 2009
- O. Ludwig, D. Delgado, V. Goncalves, and U. Nunes, 'TrainableClassifier-Fusion Schemes: An Application To Pedestrian Detection,' In: 12th International IEEE Conference On Intelligent Transportation Systems, 2009, St. Louis, 2009. V. 1. P. 432-437.
- Acar, E. and Özerdem, M.S., "Image Classification of Kiziltepe cropland by using Gabor Wavelet Transform", 20th Signal Processing and Communications Applications Conference (SIU), On page(s): 1– 4, Muğla, 2012.
- Prajapati, H. B., Shah, J. P., & Dabhi, V. K. (2017). Detection and classification of rice plant diseases. *Intelligent Decision Technologies*, 11(3), 357-373.
- Bera, T., Das, A., Sil, J. and Das, A.K. 2019. A survey on rice plant disease identification using image processing and data mining techniques. in *emerging technologies in data mining and information security*, Springer, Singapore. pp. 365-376.
- Liang, W., Zhang, H., Zhang, G. and Cao, H. 2019. Rice blast disease recognition using a deep convolutional neural network. *Scientific Reports*, 9, 2869.
- Devi, T.G. and Neelamegam, P. 2018. Image processing based rice plant leaves diseases in Thanjavur Tamilnadu. *Cluster Computing*, 22, 13415-13428.
- Joshi, A.A. and Jadhav, B.D. 2016. Monitoring and controlling rice diseases using image processing techniques. In: *International Conference on Computing, Analytics and Security Trends (CAST)*, pp. 471-476.
- Phadikar, S., Sil, J. and Das, A.K. 2013. Rice diseases classification using feature selection and rule generation techniques. *Computers and Electronics in Agriculture*, 90, 76-85.
- Kaymaz, E., "Yapay bağışıklık sistemi tabanlı k-NN sınıflandırma algoritması ile protein örüntülerinin hücredeki yerleşim yerlerinin belirlenmesi". Yüksek Lisans tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.s.45, 2007.
- Acar, E., Özerdem, M. S. (2013). Laws doku enerji ölçümü tabanlı k-NN sınıflandırıcı modeli ile iris tanıma sistemi. 21st Signal Processing and Communications Applications Conference, 24 April 2013, Haspolat, Turkey. <https://doi.org/10.1109/SIU.2013.6531397>
- Dilki, G., & Başar, Ö. D. (2020). İşletmelerin İflas Tahmininde K-en Yakın Komşu Algoritması Üzerinden Uzaklık Ölçütlerinin Karşılaştırılması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 19(38), 224-233.
- Suthaharan, S. (2016). Support vector machine. In *Machine learning models and algorithms for big data classification* (pp. 207-235). Springer, Boston, MA.
- Kiratiratanapruk, K., Temniranrat, P., Sinthupinyo, W., Prempre, P., Chaitavon, K., Porntheeraphat, S., & Prasertsak, A. (2020). Development of paddy rice seed classification process using machine learning techniques for automatic grading machine. *Journal of Sensors*, 2020.
- Kaggle (2022). <https://www.kaggle.com/datasets/muratkokludataset/rice-image-dataset>. Erişim tarihi 13 Ağustos 2022.

Türkçe Haber Başlıklarından Konu Tespiti Topic Detection from Turkish News Texts

Hülya Hark¹, Cengiz Hark², Ali Karcı³

¹8. Bölge Müdürlüğü, Karayolları Genel Müdürlüğü, Elazığ, Türkiye

²Bilgisayar Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

³Yazılım Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye
(hhark@kgm.gov.tr, cengiz.hark@inonu.edu.tr ,ali.karci@inonu.edu.tr)

Özetçe— Dijital çağda anlık veri paylaşımı yapılabilmekte ve her adımımız dijital olarak izlenmektedir. Üretilen verinin ise çok büyük bir oranı yapılandırılmamıştır ve de metin formatındadırlar. Sözü edilen büyük miktarlardaki metinlerin işlenerek anlamlı ve faydalı bilgiye dönüştürülmesi gerekmektedir. Bu ihtiyaç haber metinlerinden konu tespit edilmesi görevini oldukça önemli hale getirmektedir. Bu amaca yönelik farklı yaklaşımlar mevcuttur ancak makine öğrenmesi metotları bu çalışmaların odağındadır. Çalışma kapsamında Türkçe haber metinlerinden konu tespiti amacıyla yönelik olarak LSTM(Uzun Kısa Süreli Bellek) katmanlarından oluşan sinir ağları kullanılmıştır. Gerçekleştirilen deneysel çalışmanın başarımını çeşitli performans metrikleri ile hesaplanmıştır. Çalışmada açık erişime sahip ve çok sınıflı Turkish Headlines Dataset veri seti kullanılmıştır. İlgili tablo ve grafiklerden görüleceği üzere Türkçe Haber Başlıklarından Konu Tespiti görevinde önerilen model ile elde edilen performans başarımlarının Duyarlılık, Kesinlik ve F-Skor değerleri tüm haber kategorilerinin ortalaması alınarak %92 olarak hesaplanmıştır.

Anahtar Kelimeler : LSTM, sınıflandırma, haber sınıflandırma, derin öğrenme.

Abstract— In the digital age, instant data sharing can be made and our every step is monitored digitally. Many of the data produced are unstructured and in text format. The mentioned large amounts of texts need to be processed and transformed into meaningful and useful information. This need makes the task of identifying topics from news texts very important. There are different approaches for this purpose, but machine learning methods are the focus of these studies. Within the scope of the study, neural networks consisting of LSTM(Long Short-Term Memory) layers were used for topic detection from Turkish news texts. The performance of the experimental study was calculated with various performance metrics. The study used open access and multi-class Turkish Headlines Dataset dataset. As can be seen from the relevant tables and graphics, the Sensitivity, Precision, and F-Score values of the performance metric obtained with the proposed model in the Task Detection from Turkish News Headlines were calculated as 92% by taking the average of all news categories.

Keywords: LSTM, classification, news classification, deep learning.

1.Giriş

Günümüzdeki teknolojik gelişmeler büyük veri setlerinin oluşmasına neden olmuştur. İstenilen bilgiye daha kısa sürede erişmek bilgilerin kategorize edilmesini gerektirmektedir. İnternette çok fazla sayıda haber üreten birçok kaynak bulunması ve kullanıcıların ilgilendikleri habere hızlı ve etkili erişim için haber metinlerinin sınıflandırılması çok önemlidir. Haber metinlerinin sınıflandırılması haberlerin kategorilerini belirlemek veya kullanıcının ilgi alanlarına göre bireysel önerilerde bulunmak gibi nedenlerle kullanılabilir (G. Kaur & Bajaj, 2016).

Haber metinlerinin sınıflandırılması için makine öğrenmesi algoritmaları ya da derin öğrenme metotları kullanılabilir. Derin öğrenme metotları verilerin temsiline dayalı olarak çıkarılan özelliklerden veriyi en iyi temsil edecek algoritmalar kullanır. Derin öğrenmede tasarlanan model resim, metin, ses verilerinden sınıflandırma görevleri için eğitilir ve bunlardan çıkarım yapabilmektedir (Şeker & Diri, 2017).

LSTM uzun süreli yinelemeleri öğrenebilen özel bir Yinelemeli Sinir Ağları (RNN) türüdür. Hochreiter ve Schmidhuber tarafından 1997’de tanıtılarak sonraki çalışmalarda birçok araştırmacı tarafından ilgi gördü. Çok çeşitli problemler üzerinde çok iyi çalışmakta olduğu ve bu nedenle yaygın olarak kullanılmaktadırlar (Understanding LSTM Networks, 2015).

Yapılan bu çalışma derin öğrenme modeli olan LSTM hakkında bilgi vermeyi ve LSTM’nin sınıflandırma performansını Türkçe haber başlıklarını içeren veri setinde haber kategorilerini sınıflandırmayı amaçlamaktadır. Çalışmanın ikinci bölümünde haber metinlerinin sınıflandırılması üzerine daha önce yapılmış çalışmalara değinilmiştir, üçüncü bölümde LSTM modellerinin çalışma prensiplerinin incelenmesi, veri seti hakkında bilgi ve hazırlık süreci, veri analizlerinin gerçekleştirilmesi, 4. bölümde veri analizi sonucunda elde edilen bulgular çıkarılan sonuçlar hakkında bilgi verilmiştir. Son olarak sonuçlar bölümünde eğitilen modelden çıkarılan sonuçların doğruluk değerleri ve çalışmanın tahmini değerlere yer verilerek çalışma sonlandırılmıştır.

2. İlişkili Çalışmalar

Uslu ve Akyol, makine öğrenmesi yöntemleri kullanarak Türkçe haber metinlerinin sınıflandırması çalışmasını yapmışlardır. Çalışmalarında haber metinleri ve haber kategorilerini içeren veri seti kullanarak Destek Vektör Makineleri (SVM), Rastgele Orman (RO) ve Navie Bayes (NB) sınıflandırma yöntemlerini kullanarak karşılaştırmışlar ve en başarılı sınıflandırma yönteminin %91 performans ile NB sınıflandırma yöntemi olduğunu ortaya koymuşlardır (Uslu & Akyol, 2021).

Acı ve Çırak, yapmış oldukları çalışmada Konvolüsyonel Sinir Ağları (KSA) ve Word2Vec metotları ile TTC-3600 veri seti üzerinde Türkçe Metin sınıflandırması yapmışlar ve aynı veri setinde yapılan daha önceki çalışmalar ile sonuçlarını karşılaştırmışlardır. Çalışmalarında KSA ve Word2Vec metotlarının makine öğrenme metotlarından NB, J48 algoritması, RO, DVM gibi farklı sınıflandırma yöntemleri ile karşılaştırmışlar ve yapılan çalışmanın daha iyi başarımlar sağlamışlardır (Acı & Çırak, 2019).

Saigal ve Khanna, En Küçük Kareler Destek Vektör Makineleri, İkiz Destek Vektör Makineleri ve En Küçük Kareler İkiz Destek Vektör Makineleri Reuters ve 20 Newsgroups veri setinde kullanılarak sınıflandırıcıların davranışları gözlemlenmektedir. Veri kümesi ön işleme yapılarak özellik seti Tf_Idf matrisi olarak yapılandırılmasıyla temsili vektörler elde edilmiştir. Yapılan çalışmada En Küçük Kareler İkiz Destek Vektör Makineleri yönteminin doğruluk ve zaman karmaşıklığı bakımından diğer iki yöntemden üstün olduğunu ortaya çıkarmaktadır (Saigal & Khanna, 2020).

Devi ve ark., haber makalelerini Evrişimli Sinir Ağları (CNN) kullanarak sınıflandırma çalışması yapmıştır. Yapılan çalışmada ayrıca NB, KNN(K-En Yakın Komşu) ve SVM gibi sınıflandırma yöntemleri ile karşılaştırılması yapılmıştır. Sonuçta bu çalışmada SVM daha fazla doğruluk ve hızlı tahmin yaptığı, eğitim süresi için daha az zaman ayırmak isteniyorsa KNN’nin tercih edilmesi gerektiği, eğer daha çok veri sayısı mevcut ise CNN kullanılması gerektiği sonucunu ortaya koymuşlardır (Devi, Bai, & Reddy, 2020).

Kaur ve Khiva, derin öğrenme teknikleri kullanarak online haber metinleri üzerine sınıflandırma işlemi yapmışlardır. Haber metinlerini politika, finans, ve spor olmak üzere 4 kategoride sınıflandırarak sonuçta 99.93 doğrulukla neural network ile yapılan sınıflandırmanın geleneksel yöntemlere göre daha iyi sonuçlar verdiği gözlemlenmiştir (S. Kaur & Khiva, 2008)

Zhang, metin verilerini sınıflandırmak için yaptığı çalışmada CNN, LSTM ve MLP (Çok Katmanlı Algılayıcılar) gibi derin öğrenme yöntemlerinin birleşimi olarak ele aldığı DCLSTM-MLP modelini önermektedir. Bu modelde haber metninin sınıflandırılması problemlerini başarılı bir şekilde çözerek diğer yöntemlerle karşılaştırmış ve modelin diğer yöntemlere göre daha iyi sonuçlar elde ettiği gözlemlenmiştir (Zhang, 2021).


Rabbimov ve Kobilov, Özbekçe yazılmış haber metinleri için on kategoride makaleler seçilmiş ve bunlara yönelik bir veri seti geliştirilmişlerdir. Bu veri setinin çok sınıflı metin sınıflandırması yaparken SVM, Karar Ağacı, RO, lojistik regresyon ve Çok terimli NB (MNB) yöntemlerini kullanmışlardır. Özellik çıkarımı için TF-IDF(Terim Frekansı- Ters Belge Frekansı) algoritması ile kelime ve karakter

düzeyinde n-gram modellerini kullanmışlardır. Yapılan çalışmada çeşitli deneyler yapılmış ve SVM'nin daha iyi performans gösterdiği gözlemlenmiştir (Rabbimov & Kobilov, 2020).

3. Materyal ve Metodoloji

RNN verileri modellemek için döngüsel bağlantılar içerir. Bu onu ileri beslemeli sinir ağlarından daha güçlü yapar. RNN ağı iyi eğitildiğinde dinamik bir sistemi modelleyebilir, fakat uzun vadeli bağımlılıkların öğrenilmesinde sorunlarla karşılaşılabilir. RNN'leri eğitmek için kullanılan tüm modeller patlayan ya da kaybolan gradyan sorununa neden olmuştur. Bu sorunu çözmek için geliştirilen yöntem ise LSTM'dir (Salehinejad, Sankar, Barfett, Colak, & Valaee, 2017).

LSTM, genel amaçlı bir bilgisayar olarak kullanılmak üzere geri besleme bağlantılarından yararlanan bir RNN yöntemidir. Bu yöntem dizi, örüntü tanıma ve görüntü işleme uygulamaları için kullanılabilir. Genel olarak, LSTM modeli giriş, çıkış ve unutma kapıları olmak üzere üç merkezi birim içerir. LSTM, girdinin nörona ne zaman gireceğine karar vermeyi ve önceki zaman adımında ne hesaplandığını hatırlamayı kontrol edebilir. LSTM yönteminin en güçlü yönlerinden biri, tüm bunlara mevcut girdinin kendisine göre karar vermesidir (Mosavi et al., 2019). Şekil 1'de LSTM yönteminin mimarisi gösterilmektedir:



Şekil 1. LSTM mimarisi (Ismail, Wood, & Bravo, 2018)

Şekil 1'de σ sigmoid fonksiyonu, h_t gizli birim, i_t giriş kapısı, o_t çıkış kapısı, f_t unutma kapısı, c_t ve $\tilde{c}_t$ bellek hücrelerini ifade etmektedir (Ismail et al., 2018).

3.1. Veri Seti

Çalışmada Türkçe haber sitelerinden yararlanılarak 4200 adet Türkçe haber başlıklarından ya da haber içeriğindeki alt başlıklarda eklenmesi ile oluşturulmuş olan açık kaynak bir veri seti kullanılmıştır (UCI Machine Learning Repository: Turkish Headlines Dataset Data Set, 2021). Veri seti ekonomi, siyaset, yaşam, teknoloji, magazin, sağlık ve spor olarak 7 farklı haber türü etiketinden ve her etiket 600 adet haber başlığından oluşmaktadır.

Tablo 1. Önişleme ve hazırlık adımlarından sonra Türkçe haber başlıkları veri setine ait bazı haber başlıkları ve etiketleri

Sınıf Bilgisi	Haber Metni
Yasam	Agri'da askeri araç kaza yaptı
Ekonomi	Bankacılardan faizi indirime destek
Sağlık	Ac karnina zeytinyagi içmenin faydaları
Yasam	Universiteli gencin inanılmaz olumu
Magazin	Unlu komedyene sok! Bos koltuklara gosteri yapti!
Yasam	Yolun Karsisina Gecmek Isteyen Yasli Adama Otomobil carpti: 1 olu

Magazin	Turgut Ozakman'ın unutulmaz kitabı su cilgin Turkler dizi oluyor.
Siyaset	ABD heyeti ile yapılan vize krizi görüşmesi bitti.
Teknoloji	ZTE Quartz'in tasarımı ortaya çıktı!
Spor	Altay maci öncesi taraftarlar Karsiyaka'nin tesislerini bastı.

3.2. Sınıflama Problemlerinin Performans Metriği

Sınıflandırma problemlerinde makine öğrenimi için kullanılan bir ölçüt olan karışıklık matrisi sınıflandırmanın doğru veya yanlış olduğunu verildiği 4 farklı durumu içeren bir tablodur. Karışıklık matrisi genel olarak gerçek değerleri ve tahmin değerlerini karşılaştırmak için kullanılmaktadır. Yapılan sınıflandırma tahminleri karışıklık matrisi değerlendirmelerinden birine sahip olacaktır.

Tablo 2. Karışıklık matrisi (Caron et al., 2017)

Tahmin Değer	Gerçek Değer	
	Pozitif	Negatif
	Pozitif	Negatif
Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

Tablo 2’de bahsedilen karışıklık matrisi değerlerine göre sınıflama performans değerlendirmesi için tanımlanmış bazı önemli metrikler Tablo 3’te özetlenmektedir.

Tablo 3. Değerlendirme ölçütü (Caron et al., 2017)

Değerlendirme Ölçütü	Hesaplanan formül	Tanım
Doğruluk	$\frac{TP + TN}{FP + FN + TP + TN}$	Doğru sınıflandırmanın tüm örnekler içindeki oranıdır.
Hassasiyet	$\frac{TP}{TP + FP}$	Pozitif tahminler içindeki doğru pozitiflerin oranıdır.
Duyarlılık	$\frac{TP}{TP + FN}$	Pozitif tahminler içinde doğru pozitif tahmin oranıdır.
Özgünlük	$\frac{TN}{TN + FP}$	Negatif örnekler içinde doğru negatif tahmin oranıdır.
F-puanı	$\frac{2 * TP}{2 * TP + FP + FN}$	Hassasiyet ve duyarlılığın harmonik ortalamasıdır.

4. Bulgular


Bu çalışmada LSTM katmanlarından oluşturulan sinir ağlarının haber metinlerinden konu tespit edilmesi gibi popüler ve zorlayıcı bir görev üzerindeki başarıları incelenmiştir. Deneysel süreçlerde kullanılan veri seti %80 eğitim %20 test verisi olacak biçimde organize edilmiştir. Oluşturulan model ile gerçekleştirilen eğitim aşamalarına dair grafikler Şekil 2’de görülmektedir. Tablo 4’te LSTM ağ modelinin eğitim sürecindeki parametre ve değerleri gösterilmektedir.

Tablo 4. LSTM ağ modelinin eğitim parametreleri

Parametreler	Değerler
--------------	----------

Eğitim verisi	3360
Test verisi	840
Çıkış	7
İterasyon sayısı	30
Katman sayısı	4
Yığın (Batch) boyutu	64
Öğrenme hızı	0.0001


Eğitim sırasında 16 nöronlu bir LSTM katmanı, aşırı öğrenmenin önüne geçebilmek için bırakma işlevi olarak uzaysal bırakma 0,2 kabul edilmiştir. Modelin çıkış katmanı 7 haber kategorisine uygun olarak çıkış üretmektedir. Model, çoklu sınıflandırmaya uygun biçimde “softmax” aktivasyon fonksiyonu ve adam optimize edici ile derlenmiştir. Kayıp fonksiyonu categorical cross entropy dir.



Şekil 2. Eğitim ve test kümeleri için doğruluk ve kayıp grafikleri

Şekil 2 incelendiğinde belirli bir iterasyondan sonra kayda değer değişimlerin gerçekleşmediği görülebilmektedir.

Eğitim süreçlerinin sonrasında Şekil 3’te sunulan çakışım matrisleri elde edilmiştir.



Şekil 3. Modele ait çıkışım matrisi

Çıkışım matrisi satırları sırasıyla ekonomi, magazin, sağlık, siyaset, spor, teknoloji ve yaşam sınıfları ile temsil edilmektedir. İlgili şekil incelendiğinde keskin bir diyagonal örüntü elde edildiği görülmektedir. Bu durum modellenen uzun ömürlü kısa dönem bellek katmanlarından oluşturulan sinir ağının haber metinlerinin doğru sınıflarını tespit etme noktasındaki başarısını göstermektedir. Modellenen sistem ile %92 sınıflandırma başarımları rapor edilmektedir. Ayrıca çıkışım matrisinden elde edilen hassasiyet, duyarlılık, f-puan metriklerine Tablo 4’te yer verilmiştir.

Tablo 4. Modele ait performans sonuçları

Sınıf	Hassasiyet (%)	Duyarlılık (%)	f-puanı (%)
Ekonomi	0.97	0.88	0.92
Magazin	0.95	0.89	0.92
Sağlık	0.96	0.97	0.97
Siyaset	0.95	0.98	0.96
Spor	0.91	0.94	0.94
Teknoloji	0.74	0.89	0.81
Yaşam	0.98	0.90	0.94
Ort.	92	92	92

Sınıflandırma sonucunda herhangi bir metrik türünün daha baskın olmadığı yakın değerlerin rapor edildiği görülmektedir. Bu durumu deneysel süreçlerde kullanılan veri setinin sınıflar arasında dengeli bir biçimde dağılması ile açıklamak mümkündür.

Sonuç olarak, Uzun Ömürlü Kısa Dönem Bellek katmanlarından oluşturulan sinir ağlarının haber metinlerinden konu tespit edilmesi görevi üzerindeki başarımı ispatlanmıştır.

5. Sonuç ve Tartışma

Bu çalışmada haber başlıklarından oluşan veri setinin ekonomi, siyaset, yaşam, teknoloji, magazin, sağlık ve spor olarak 7 farklı kategori olarak sınıflandırılması için bir tahmin modeli geliştirilmesi amaçlanmıştır. Çalışmada Türkçe haber başlıklarından oluşturulmuş olan Turkish Headlines Dataset veri seti LSTM sinir ağı kullanılarak kategorize edilmiştir. Önerilen modelde veri seti %80 eğitim %20 test olarak bölünmüştür. Modele ait performans başarımları %92 genel doğruluk olarak elde edilmiştir. Modelin çok daha büyük haber metinleri üzerinde gerçekleştirilmesi ve farklı derin öğrenme mimarileri ile karşılaştırılması çalışmanın sonraki hedefleri arasında yer almaktadır.

Kaynaklar

- ACI, Ç., & ÇIRAK, A. (2019). Türkçe Haber Metinlerinin Konvolüsyonel Sinir Ağları ve Word2Vec Kullanılarak Sınıflandırılması. *Bilişim Teknolojileri Dergisi*, 219–228. <https://doi.org/10.17671/gazibtd.457917>
- Caron, S., Kim, J. S., Rolbiecki, K., de Austri, R. R., & Stienen, B. (2017). The BSM-AI project: SUSY-AI–generalizing LHC limits on supersymmetry with machine learning. *European Physical Journal C*, 77(4). <https://doi.org/10.1140/epjc/s10052-017-4814-9>
- Devi, J. S., Bai, D. M. R., & Reddy, C. (2020). Newspaper Article Classification using Machine Learning Techniques. *International Journal of Innovative Technology and Exploring Engineering*, 9(5), 872–877. <https://doi.org/10.35940/ijitee.E2753.039520>
- Ismail, A. A., Wood, T., & Bravo, H. C. (2018). *Improving Long-Horizon Forecasts with Expectation-Biased LSTM Networks*. Retrieved from <http://arxiv.org/abs/1804.06776>
- Kaur, G., & Bajaj, K. (2016). *News Classification and Its Techniques: A Review*. 18(1), 22–26. <https://doi.org/10.9790/0661-18132226>
- Kaur, S., & Khiva, N. K. (2008). Online news classification using Deep Learning Technique. *Certified Journal*, 9001. Retrieved from www.irjet.net
- Salehinejad, H., Sankar, S., Barfett, J., Colak, E., & Valaee, S. (2017). *Recent Advances in Recurrent Neural Networks*. Retrieved from <http://arxiv.org/abs/1801.01078>
- UCI Machine Learning Repository: Turkish Headlines Dataset Data Set. (2021). Retrieved July 6, 2022, from <https://archive.ics.uci.edu/ml/datasets/Turkish+Headlines+Dataset>
- Understanding LSTM Networks -- colah's blog. (2015). Retrieved July 5, 2022, from <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Uslu, O., & Akyol, S. Ö. (2021). Türkçe Haber Metinlerinin Makine Öğrenmesi Yöntemleri Kullanılarak Sınıflandırılması. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 2(1), 15–20. Retrieved from <https://dergipark.org.tr/en/pub/estudambilisim/issue/60018/852183>
- iques. *International Journal of Innovative Technology and Exploring Engineering*, 9(5), 872–877. <https://doi.org/10.35940/ijitee.E2753.039520>
- Fuks, O. (n.d.). *Classification of News Dataset*.
- Generating Your Shakespeare Text Using Sequential Models Such As Long-Short-Term-Memory (LSTMs), Gated Recurrent Units (GRUs), Recurrent Neural Network (RNNs)* - MarkTechPost. (n.d.). Retrieved July 5, 2022, from <https://www.marktechpost.com/2021/04/01/generating-your-shakespeare-text-using-sequential-models-such-as-long-short-term-memory-lstms-gated-recurrent-units-grus-recurrent-neural-network-rnns/>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/NECO.1997.9.8.1735>
- Index of /ml/machine-learning-databases/00614. (n.d.). Retrieved July 5, 2022, from <https://archive.ics.uci.edu/ml/machine-learning-databases/00614/>
- Kaur, G., & Bajaj, K. (n.d.). *News Classification and Its Techniques: A Review*. 18(1), 22–26. <https://doi.org/10.9790/0661-18132226>
- Kaur, S., & Khiva, N. K. (2008). Online news classification using Deep Learning Technique. *Certified Journal*, 9001. www.irjet.net
- Mosavi, A., Ardabili, S. F., & Várkonyi-Kóczy, A. R. (2019). *List of Deep Learning Models*. <https://doi.org/10.20944/PREPRINTS201908.0152.V1>
- Rabbimov, I. M., & Kobilov, S. S. (2020). Multi-Class Text Classification of Uzbek News Articles using Machine Learning. *Journal of Physics: Conference Series*, 1546(1). <https://doi.org/10.1088/1742-6596/1546/1/012097>
- Saigal, P., & Khanna, V. (2020). Multi-category news classification using Support Vector Machine based classifiers. *SN Applied Sciences*, 2(3), 1–12. <https://doi.org/10.1007/S42452-020-2266-6/TABLES/9>
- Salehinejad, H., Sankar, S., Barfett, J., Colak, E., & Valaee, S. (2017). *Recent Advances in Recurrent Neural Networks*. Retrieved from <http://arxiv.org/abs/1801.01078>

- Şeker, A., & Diri, B. (2017). *Emotion Recognition from the Human Voice View project A New Binary ABC Algorithm View project*. <https://www.researchgate.net/publication/322211817>
- Understanding LSTM Networks -- colah's blog*. (n.d.). Retrieved July 5, 2022, from <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Uslu, O., Akyol, S., Üniversitesi, E. O., Fakültesi, M.-M., Bölümü, M., Yüksekokulu, M., & Programı, B. P. (n.d.). *Türkçe Haber Metinlerinin Makine Öğrenmesi Yöntemleri Kullanılarak Sınıflandırılması*. <https://orcid.org/0000-0002-4377-5952>
- What Is Deep Learning? | How It Works, Techniques & Applications - MATLAB & Simulink*. (n.d.). Retrieved July 5, 2022, from <https://www.mathworks.com/discovery/deep-learning.html>
- Zhang, M. (2021). Applications of Deep Learning in News Text Classification. *Scientific Programming*, 2021. <https://doi.org/10.1155/2021/6095354>

Rastgele Alt Uzay ve Lojistik Regresyon Yöntemleri Kullanılarak Duygu Analizi

Sentiment Analysis by Using Random Subspace and Logistic Regression Methods

Ensar Arif Sağbaş^{*1} 

¹Bilişim Sistemleri Mühendisliği Bölümü, Muğla Sıtkı Koçman Üniversitesi, Muğla, Türkiye

arifsagbas@mu.edu.tr

Özetçe— Son yıllarda bilgi teknolojilerinin gelişmesine paralel olarak dijital metin kaynaklarının sayısı arttıkça duygu analizi giderek daha fazla önem kazanmaktadır. Makine öğreniminde, öznelik seçimi, verilerin boyutsallığını azaltmada ve önerilen herhangi bir çerçevenin performansını artırmada çok önemli bir yeri bulunmaktadır. Öznelik seçimi, makine öğreniminde kritik ve önemli bir görevdir. Öznelik seçimi probleminin temel amacı, performansın doğruluğunu korurken öznelik setinin boyutunu azaltmaktır. Bu çalışmada duygu sınıflandırmasında kullanılan veri kümelerinden Rastgele alt uzay yöntemi ile yeni alt kümeler elde edilmiş ve Lojistik regresyon yöntemi ile sınıflandırılmıştır. Sonrasında sınıflandırma performansları karşılaştırılmıştır. Elde edilen sonuçlar öznelik seçimi ve boyut azaltmanın sınıflandırma performansındaki önemini ortaya koymaktadır.

Anahtar Kelimeler : *duygu analizi, rastgele alt uzay, lojistik regresyon.*

Abstract— In recent years, in parallel with the development of information technologies, sentiment analysis is gaining more and more important as the number of digital text resources increases. In machine learning, feature selection has very important place in reducing the dimensionality of data and improving the performance of any proposed framework. Feature selection is a critical and important task in machine learning. The main purpose of the feature selection problem is to reduce the size of the feature set while maintaining the accuracy of performance. In this study, new subsets were obtained from the datasets used in sentiment classification with the Random subspace method and classified by the Logistic regression method. Afterward, classification performances were compared. The obtained results reveal the importance of feature selection and dimension reduction in classification performance.

Keywords : *sentiment analysis, random subspace, logistic regression.*

1.Giriş

Bilişim teknolojilerindeki hızlı gelişimin de etkisiyle dijital metin dokümanlarının sayısı arttıkça, metin madenciliği son yıllarda giderek daha kritik hale gelmektedir (Gokalp ve ark., 2020). Otomatik metin sınıflandırıcılar, spam filtreleme, duygu analizi ve haber sınıflandırma gibi birçok gerçek dünya sorununu ele almak için kullanılabilir (Pintas ve ark., 2021). Duygu analizi veya fikir madenciliği, çeşitli kaynakların metin belgelerinden faydalı bilgilerin çıkarılması için doğal dil işlemenin anahtarıdır. Birkaç farklı teknik, yani basit kural tabanlı, sözlük tabanlı ve daha karmaşık makine öğrenme algoritmaları, duygunun olgusal analizini elde etmek için farklı sınıflandırıcılarla yaygın olarak kullanılmıştır (Rasool ve ark., 2020). Bu çalışmalarda metinler genellikle yüksek boyutlu ve seyrek bir belge terim matrisi ile kelime sıklık sayılarını içeren kelime dağarcığının boyutuna sahip bir boşlukta temsil edilir. Yüksek boyutluluk, boyutluluk laneti ve modelin aşırı yüklenmesi gibi bazı sorunlara neden olabilir (Pintas ve ark., 2021).

Bir veri kümesi çok sayıda öznelik içermektedir. Bazı öznelikler alakasız veya gereksiz olabilmekte ve bu da modelin performansını düşürmektedir. Bu nedenle, performansın doğruluğunu korurken orijinal veri kümelerinin boyutunu küçültmek, öznelik azaltma probleminin ana amacıdır.

Öznitelik seçimi problemi, makine öğrenimindeki en zorlu görevlerden biridir. Bir küme n sayıda öznitelik içeriyorsa, en iyi alt kümenin seçilmesi için gereken toplam 2^n adet alt küme mümkündür. Modelin performansını her bir alt kümede değerlendirmek mümkün olmayacağından durumu ele almak için çeşitli metodolojiler önerilmiştir (Agrawal ve ark., 2021).

Topluluk öğrenme yöntemleri ve bu yöntemlerden birisi olan Rastgele alt uzay yaklaşımı çeşitli duygu analizi çalışmalarında yer almıştır. Wang ve Ma (2011) kurumsal kredi riski tahmini için Boosting ve Rastgele alt uzaya dayanan, RS-Boosting adı verilen entegre bir topluluk yaklaşımı önermişlerdir. Wang ve ark. (2014) beş temel öğreniciye dayalı üç popüler topluluk yönteminin (Bagging, Boosting, Rastgele alt uzay) performansının karşılaştırmalı bir değerlendirmesini yapmışlardır. Wang ve ark. (2015) konuşmanın bir bölümünün analizine dayalı duygu sınıflandırması için geliştirilmiş bir Rastgele alt uzay yöntemi olan POS-RS önermişlerdir. Bu çalışmada ise duygu sınıflandırmada kullanılan açık 3 veri kümesi üzerinden Rastgele alt uzay ve Lojistik regresyon sınıflandırıcının birlikte kullanılması ile elde edilen sonuçların performansları değerlendirilmiştir. Elde edilen sonuçlar öznitelik seçimi konusunun önemini ortaya koymaktadır.

2. Materyal ve Yöntem

2.1. Veri kümesi

Bu çalışmada, ele alınan öznitelik seçimi algoritmalarının performanslarını değerlendirmek için Whitehead ve Yaeger (2009), Wang ve ark. (2014)'dan sağlanan 3 veri kümesi kullanılmıştır. Bu veri kümelerinin adları camp, music ve cameradır. İçerikleri yaklaşık %50 olumlu ve %50 olumsuz incelemelerden oluşmaktadır. Veri kümelerinin özellikleri Tablo 1'de listelenmiştir. Fikir madenciliği/duygu madenciliği veri kümelerinin kısa açıklamaları Tablo 2'de gösterilmiştir.

Tablo 1. Kullanılan duygu sınıflandırması veri kümelerinin özellikleri

Veri kümesi	Öznitelik sayısı	Gözlem sayısı
Camp	1810	804
Music	1441	582
Camera	1457	498

Tablo 2. Kullanılan duygu sınıflandırması veri kümelerinin açıklamaları

Veri kümesi	Açıklama
Camp	CampRatingz.com'dan yaz kampı incelemeleri
Music	Amazon.com'dan müzik CD'si incelemeleri
Camera	Amazon.com'dan dijital kamera incelemeleri

2.2. Rastgele Alt Uzay

Rastgele alt uzay yöntemi, Ho (1998) tarafından önerilen bir topluluk oluşturma tekniğidir. Rastgele alt uzayda, eğitim veri seti de Bagging yönteminde olduğu gibi değiştirilir. Ancak, bu değişiklik öznitelik alanında (gözlem alanı yerine) gerçekleştirilir. Veri kümesi birçok fazlalıklı veya alakasız öznitelige sahip olduğunda, Rastgele alt uzaylarda orijinal öznitelik uzayından daha iyi temel sınıflandırıcılar elde edilebilir (Ho, 1998). Bu tür temel sınıflandırıcıların birleşik kararı, tam öznitelik uzayında orijinal eğitim veri kümesi üzerinde oluşturulan tek bir sınıflandırıcıdan daha üstün olabilir (Wang ve Ma, 2011).

2.3. Lojistik Regresyon

Lojistik regresyon, bir lojistik fonksiyon kullanarak olasılıkları tahmin ederek sınıf değişkeni ile diğer ilgili tahmin değişkenleri arasındaki ilişkiler hakkındaki varsayımları tanımlamak ve test etmek

için kullanılır (Ballı ve Sağbaş, 2017). Çok terimli lojistik regresyon modeli, ikiden fazla ayrık sonuca izin vererek lojistik regresyonu genelleştiren bir modeldir. Yani, kategorik olarak dağılmış bir bağımlı değişkenin, bir dizi bağımsız değişken verildiğinde, farklı olası sonuçlarının olasılıklarını tahmin etmek için kullanılan bir modeldir (Feng ve ark., 2010).

3. DeneySEL Bulgular

Veri kümelerinin %70'i eğitim, geri kalan %30'u ise test için ayrılmıştır. Sınıflandırma performansları doğruluk oranı, Precision, Recall, F-Measure ve AUC (Area Under Curve) ile değerlendirilmiştir. Çalışmada kullanılan açık 3 veri kümesinin herhangi bir önışlem ya da öznelik seçimi uygulanmadan elde edilen sonuçlar Tablo 3'te sunulmaktadır.

Tablo 3. Veri kümelerinden elde edilen sonuçlar

	Doğruluk (%)	Precision	Recall	F-Measure	AUC
Camp	81.74	0.855	0.787	0.820	0.920
Music	66.86	0.684	0.713	0.698	0.705
Camera	71.14	0.700	0.690	0.695	0.810

Özneliklerin tamamı kullanıldığında camp veri kümesi için %81.74, music veri kümesi için %66.86 ve camera veri kümesi için ise %71.14 sınıflandırma doğruluğu elde edilmiştir. Precision, Recall, F-Measure ve AUC değerleri de sınıflandırma doğruluğuna paralel sonuçlar vermiştir. Rastgele alt uzay yöntemi deneyleri alt uzay boyutu 0.1'den 0.9'a kadar 0.1 artacak şekilde toplamda 9 farklı alt uzay boyutunda gerçekleştirilmiştir. Alt uzayların seçiminde rastgelelik durumu söz konusu olduğundan her bir test 10 kere çalıştırılmıştır ve not alınmıştır. Camp veri kümesinden alt uzay boyutlarına göre elde edilen en iyi, en kötü, ortalama doğruluk oranları ve standart sapma değerleri Tablo 4'te gösterilmektedir.

Tablo 4. Camp veri kümesinden elde edilen sonuçlar

Alt uzay boyutu	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
En büyük	87.55	89.63	90.46	89.21	88.38	88.38	89.21	86.72	85.89
En küçük	80.08	83.82	85.48	84.65	85.89	84.23	85.06	83.4	82.57
Ortalama	84.23	86.06	87.39	87.43	87.68	87.01	86.68	85.31	84.15
Standart sapma	2.250	1.957	1.328	1.680	0.789	1.146	1.369	0.986	1.214

Rastgele alt uzay yöntemi alt uzay boyutlarının tamamında ortalama doğruluğu artırmıştır. En yüksek sınıflandırma başarısı 0.3 alt uzay boyutunda %90.46 ile sağlanmıştır. Music veri kümesinden alt uzay boyutlarına göre elde edilen en iyi, en kötü, ortalama doğruluk oranları ve standart sapma değerleri Tablo 5'te gösterilmektedir.

Tablo 5. Music veri kümesinden elde edilen sonuçlar

Alt uzay boyutu	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
En büyük	77.14	74.86	77.14	78.29	77.71	76.57	76	74.29	72
En küçük	64.57	68	68	66.86	68	67.43	68	67.43	65.71
Ortalama	71.09	71.37	71.71	71.54	72.34	71.94	71.60	71.26	69.14
Standart sapma	2.960	2.336	3.153	3.221	2.915	2.482	2.518	1.930	2.123

Music veri kümesi için en yüksek ortalama doğruluk oranı 0.5 alt uzay boyutunda sağlanırken, bireysel en başarılı sonuç ise %78.29 ile 0.4 alt uzay boyutunda elde edilmiştir. Camera veri kümesinden alt uzay boyutlarına göre elde edilen en iyi, en kötü, ortalama doğruluk oranları ve standart sapma değerleri Tablo 6’da gösterilmektedir.

Tablo 6. Camera veri kümesinden elde edilen sonuçlar

Alt uzay boyutu	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
En büyük	79.19	83.22	81.88	82.55	81.21	82.55	81.88	81.21	79.87
En küçük	73.83	75.84	71.81	75.84	75.17	76.51	76.51	76.51	74.5
Ortalama	75.901	78.52	77.38	79.20	78.05	78.59	78.59	78.39	77.32
Standart sapma	1.420	2.205	2.736	2.144	1.777	1.657	1.486	1.434	1.894

Camera veri kümesinde en başarılı sınıflandırma 0.2 alt uzay boyutunda %83.22 ile gerçekleşmiştir. Ortalama sınıflandırma başarısı incelendiğinde ise en iyi sonuç %79.2 ile 0.4 alt uzay boyutunda görülmektedir. Gerçekleştirilen deneyler sonucunda elde edilen en başarılı sınıflandırmalara ait sonuçlar Tablo 7’de sunulmaktadır.

Tablo 7. En iyi sınıflandırmalara ait sonuçlar

	Doğruluk (%)	Precision	Recall	F-Measure	AUC	Alt uzay boyutu
Camp	90.46	0.933	0.882	0.907	0.970	0.3
Music	78.29	0.804	0.787	0.796	0.818	0.4
Camera	83.22	0.795	0.873	0.832	0.893	0.2

Bireysel sınıflandırmaları göz önüne aldığımızda camp veri kümesinin sınıflandırma başarısı Rastgele alt uzay ile %81.74’ten %90.46’ya, music veri kümesinin %66.86’dan %78.29’a, camera veri kümesinin ise %71.14’ten %83.22’ye çıktığı görülmektedir.

4. Sonuç

Bu çalışmada duygu sınıflandırması için kullanılan 3 veri kümesinin sınıflandırma performansları Lojistik regresyon yöntemi ve Rastgele alt uzay tabanlı yaklaşım ile değerlendirilmiştir. Elde edilen sonuçlara göre daha az sayıda öznelilik ile daha başarılı sınıflandırmaların gerçekleştirildiği görülmektedir. Gerçekleştirilen deneylere göre mevcut özneliliklerin yarısından daha az sayıda özneliliğe sahip alt kümeler ile daha yüksek sınıflandırma başarısı yakalanmıştır. Rastgele alt uzay tabanlı yaklaşım performans ölçümünde kullanılan bütün metriklerde olumlu yönde artış sağlamıştır.

Kaynaklar

- Agrawal, P., Abutarboush, H. F., Ganesh, T., & Mohamed, A. W. (2021). Metaheuristic algorithms on feature selection: A survey of one decade of research (2009-2019). *IEEE Access*, 9, 26766-26791.
- Balli, S., Sağbas, E.A. (2017) The usage of statistical learning methods on wearable devices and a case study: activity recognition on smartwatches, in Hokimoto, T. (Ed.): *Advances in statistical methodologies and their application to real problems*. 259-277.
- Feng, T., Timmermans, H.J.P. (2010) Comparative evaluation of algorithms for GPS data imputation. *Proc. of the 13th World Conf. Transportation Research (WCTR)*, Rio de Janeiro, Brazil, pp. 1–11.
- Gokalp, O., Tasci, E., & Ugur, A. (2020). A novel wrapper feature selection algorithm based on iterated greedy metaheuristic for sentiment classification. *Expert Systems with Applications*, 146, 113176.

- Ho, T. K. (1998). The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(8), 832–844.
- Pintas, J. T., Fernandes, L. A., & Garcia, A. C. B. (2021). Feature selection methods for text classification: a systematic literature review. *Artificial Intelligence Review*, 54(8), 6149-6200.
- Rasool, A., Tao, R., Kamyab, M., & Hayat, S. (2020). GAWA—a feature selection method for hybrid sentiment classification. *IEEE Access*, 8, 191850-191861.
- Wang, G., & Ma, J. (2011). Study of corporate credit risk prediction based on integrating boosting and random subspace. *Expert Systems with Applications*, 38(11), 13871-13878.
- Wang, G., Sun, J., Ma, J., Xu, K., & Gu, J. (2014). Sentiment classification: The contribution of ensemble learning. *Decision support systems*, 57, 77-93.
- Wang, G., Zhang, Z., Sun, J., Yang, S., & Larson, C. A. (2015). POS-RS: A Random Subspace method for sentiment classification based on part-of-speech analysis. *Information Processing & Management*, 51(4), 458-479.
- Whitehead, M., & Yaeger, L. (2009, March). Building a general purpose cross-domain sentiment mining model. In 2009 WRI world congress on computer science and information engineering (Vol. 4, pp. 472-476). IEEE.

Turkish news category classification using deep learning approaches: An evaluation of vocabulary size and text length

Ömer Faruk Söylemez^{*1} 

¹Department of Computer Engineering, Dicle University, Diyarbakir, Turkey
(omer_soylez@hotmail.com)

Abstract—Automatic classification of news text aims to classify news according to their contexts. It has some useful use cases such as personalized news recommendation and search engine optimization. In this study, we employed deep learning approaches for classification of Turkish news text. An LSTM and a Dense network, along with varying vocabulary size and text length are utilized. Using an LSTM network with 20k vocab size 500 text length, an F1-score of 0.8901 is achieved. Besides, we have obtained important findings on the selection of proper vocabulary size and text length.

Keywords : *news classification, turkish news, lstm, vocabulary size, text length*

I. Introduction

Today, approximately 5 billion people, constituting 63% of the world's population, use the internet (Kepios, 2021). Internet usage is growing every year and 2021 is located in a very different place due to the coronavirus pandemic. During the pandemic, people have been forced to stay at home and spend more time on digital technologies. Users use the internet for different purposes such as social media, news, shopping, listening to music, watching videos, managing finance.

Personalized news recommendation is a technique that presents news on topics of interest to users (Wu et al., 2022). In this way, users can skip news that are not in their interests and have a better news experience. One of the most important elements of personalized news systems is the correct labeling of news. In this way, healthy filtering can be performed for areas of interest from very large data stacks. There can be many different reasons for not tagging the news correctly. Careless labeling, irrelevancy of news title and news body, and clickbait news are examples of mislabeling. For this reason, robust methods are needed to accurately label the news.

Natural Language Processing, is arguably one of the most favorite and exciting machine learning fields today. It has many use cases such as information retrieval, text and document classification, machine translation, text summarization, and question answering. With major achievements such as BERT, GPT-3 and transformers, the field of NLP has achieved very high achievements.

In this study, deep learning approaches were used to classify Turkish news texts. Within the scope of the study, a total of 12 trainings were carried out with the combination of three different parameters. The study can be summarized as follows:

- A text pre-processing has been performed to remove irrelevant features such as stop words, punctuations and digits.
- Three different vocabulary-sizes, 20000, 10000 and 2000, are used to create the tokenizer.
- Two different values of 200 and 500 are selected for creating word sequences.
- Two different structures, MLP and LSTM, are used for feature extraction.

A considerable amount of literature has been published on NLP. In this section, we focused studies on Turkish news categorization. Buluz et al., (2019) used a voting-based approach for Turkish news classification. They obtained a 2000-dimensional feature vector using TF-IDF for each word 1-3-ngrams and character 2-6-ngrams, and obtained another 300-dimensional feature vector using FastText. They combined these two vectors to form up the 2300 dimensional feature vector. Classification was performed using SVM, KNN, Random Forest, Logistic regression and XGBoost methods. The outputs of the related methods are weighted with the help of average voting. 93.72% success was achieved on the 7-category data set containing 21000 data. Nergiz et al., (2019) proposed an LSTM-based model for the classification of Turkish news content. FastText, Word2vec and Doc2vec word embeddings are used as feature vectors. As a result of the classification process performed with 2.5 million data on 7 categories, a performance of 0.9618 was achieved by using FastText word embeddings and LSTM. Gurcan (2018) used a set of classifiers to categorize Turkish news texts. Author states that features were acquired by TF-IDF on 5 classes with total of 5000 texts. Multinomial NB, Bernoulli NB, SVM, J48 and KNN are used for classification task. Cross validation is performed with k=5, and a classification rate of 90% is achieved.

II. Material and Method

A. Glove Embeddings

Word embeddings are a real-valued word representation in a predefined vector space that ensures that words with the same meaning have close values. Word embeddings are one of the most used representations in NLP tasks.

GloVe is an unsupervised learning algorithm for obtaining word embeddings. Proposed by Pennington et al., (2014), GloVe creates a word co-occurrence matrix by deriving statistics from a given corpus.

B. LSTM

Recurrent Neural Networks are a type of artificial neural networks that excels at gaining information from sequential problems such as time series or machine translation (Lindemann et al., 2021; M.Tarwani & Edem, 2017). RNNs include feedback loops letting them maintain information over time. However, they lack in solving problems that have temporal dependencies for long-terms.

Proposed by Hochreiter & Unger Schmidhuber (1997), LSTM's employ a gradient-based method, named as cell-states, to address memory shortcomings of RNNs. Cell-states helps to memorize long-term dependencies.

C. Dataset

Interpress Turkish News Category Dataset (270K - Lite Version) was used in the study. (Kömeçoğlu, 2021). The dataset, consisting of 273601 news in 17 categories in total, was compiled by the Interpress media monitoring company from printed publications and news websites between 2010-2017. The "Lite" version was created by reorganizing the dataset into 10 categories, which can be easily decomposed and has fewer classes. The classes belonging to the data set and the number of samples for each class are given in Table 1.

Table 1. Information on Classes of Interpress Turkish News Category Dataset

Classes	Train size	Test size	Total	Percentage (%)
Culture & Art	70962	17491	88453	32,3
Economy	36671	9086	45757	16,7
Politics	9645	2448	12093	4,4
Education	10438	2597	13035	4,8
World	6980	1816	8796	3,2
Sports	23430	5975	29405	10,7
Tech	31652	7928	39580	14,5
Magazine	5705	1461	7166	2,6
Health	18813	4766	23579	8,6
Agenda	4854	1153	6007	2,2
Total	219150	54721	273871	100

III. Experiments

A. Preprocessing

The news texts undergo a series of preprocessing to make them more robustly transformed into feature vectors. These pre-processes can be listed as follows: (i) converting all text to lowercase, (ii) deleting e-mail addresses, (iii) deleting URL links, (iv) removing punctuation, (v) removing numbers, (vi) removing stop words, and (vii) removing of postfixes.

B. Forming embeddings

We have used Turkish-GloVe (2020) repository for embeddings. This repository has been created with official GloVe repository (Stanfordnlp, 2018) and has 2 pre-trained word embeddings, (a) 570k vocabulary, cased with 300 dimensional vectors (1.6 GB size), and (b) 253k vocabulary with 300 dimensional vectors (720 MB size). The corpus is collected from January-December 2018 with Common Crawl. It has 2,736 billion tokens with 21 GB size. We've used the 253k vocab in this study.

For tokenization, we have used three different vocabulary size as 20k, 10k and 2k. Tokenization is performed on the training set. After tokenization phase, we have created sequences to represent texts as vectors. We created two sequences for each text, (a) 500 words for each text with pre-padding for shorter texts, and (b) 300 words for each text with pre-padding for shorter texts.

C. Forming Networks

We have utilized two different networks for classification task, namely Dense networks and LSTM network. The Dense network uses a global average pooling layer after embedding layer to reduce dimensions. Later it connects to a dense layer with 512 neurons with ReLu activations for mass feature extraction. Finally, classification is performed with a 10-class Softmax function. The LSTM network uses an LSTM layer with 32 units after embedding layer. Followingly, it connects to a dense layer with 512 neurons with ReLu activations. Classification is performed with 10-class Softmax function. Architectural design for each network along with other parameters are given in Table 2 and Table 3.

Table 2. Architectural design and parameters for Dense network

Layer	Output Shape - 200 / 500 words	Param # - 2k / 10k / 20k vocab
Input	(200) / (500)	0
Embedding	(200,300) / (500,300)	600k / 3m / 6m
Global Average Pooling	(300)	0
Dense	(512)	154112
Softmax	(10)	5130

Table 3. Architectural design and parameters for LSTM network

Layer	Output Shape - 200 / 500 words	Param # - 2k / 10k / 20k vocab
Input	(200) / (500)	0
Embedding	(200,300) / (500,300)	600k / 3m / 6m
LSTM	(32)	42624
Dense_1	(512)	16896
Softmax	(10)	5130

D. Training Networks

Training is performed with 20 epochs, though networks greatly converged before the 10th epoch. A batch size of 128 was selected for training and validation. Though the compute infrastructure was capable for larger batch sizes such as 4096, we omitted it for better generalization. Adam is used for optimization with its defaults parameters and categorical cross entropy is utilized as a loss function. Parameters for training networks is given in Table 4.

Table 4. Parameters used for network training

Epoch	Batch size	Loss	Optimizer			
20	128	Softmax	Adam			
			Lr	Beta_1	Beta_2	Epsilon
			0.0001	0.9	0.999	10^{-7}

IV. Results and Discussion

Consisting of a combination of 3 different vocabs, 2 different text sizes and 2 different networks, a total of 12 configurations are trained in this study. The metrics obtained after the evaluation of each model are summarized in Table 5 for LSTM network and in Table 6 for Dense network.

Table 5. Performance metrics for LSTM network

		Precision		Recall		F1-Score	
		200 w	500 w	200 w	500 w	200 w	500 w
Vocab size	20k	0.8944	0.9004	0.8678	0.8800	0.8809	0.8901
	10k	0.8921	0.9007	0.8705	0.8778	0.8812	0.8891
	2k	0.8851	0.8903	0.8593	0.8516	0.8720	0.8705

Table 6. Performance metrics for Dense network

		Precision		Recall		F1-Score	
		200 w	500 w	200 w	500 w	200 w	500 w
Vocab size	20k	0.8940	0.8987	0.8642	0.8631	0.8788	0.8805
	10k	0.8944	0.8990	0.8651	0.8711	0.8795	0.8848
	2k	0.8875	0.8907	0.8564	0.8464	0.8716	0.8680

Results of the study can be summarized as follows:

- *LSTM better than Dense network:* Since news text bodies highly correlate within, it is expected for LSTM to achieve better than Dense networks. LSTMs take spatiotemporal relationship of text data into account, which makes them better predictors for text based classification task.
- *Bigger vocab yields better metrics:* Both networks yielded better scores on larger vocab size. This result complies with other studies on effective vocab size selection (Chen et al., 2019; Gowda & May, 2020) A larger vocab increases the probability of finding better tokens that can represent the text effectively. However, larger vocab size may limit applicability on memory – computation constrained tasks (Faruqui et al., 2015). Therefore, a careful tradeoff should be conducted on vocab size selection.
- *Longer texts are better:* Texts with 500 word size performed better than texts with 200 word size. Similar to vocab size selection, text size selection is correlated with better representation of textual data. A larger text may induce better features that can relate it with the correct class. However, selection of text size in an empirical process. For distinguishing a medical news text from a sports news text, 50 words could be adequate, though finding a distinction between agenda news and world news may require more than that. Another solution could be using statistics, such as mean text length, median text length and standard deviation of text length for anticipation of accurate text length.

Selected corpus is a restriction for this study. For NLP tasks, embeddings are generally created from highly associated corpora. A specific corpus associated with the given task, has higher chance of providing better features. However, in this study, a general corpus from Common Crawl is used. Performance metrics may seem low compared to other studies in the introduction part, though experiments highly demonstrate the discriminative capabilities of the models. An exceptional representation of words may leverage model capabilities, thus diminish the effects of models, vocab sizes and text sizes.

V. Conclusion

In this study, Turkish news category classification is performed using deep learning approaches. GloVe embeddings are used as features and capabilities of two different deep models are evaluated with respect to vocab size and text size parameters. A total of 12 configuration are held. It is found that increase in vocabulary size improves classification metrics, though a trade-off should be considered with respect to memory-computation when choosing larger vocabs. LSTMs are capable of achieving better than simple Dense networks. We believe this is due to their capabilities of taking spatiotemporal relationships into account. Longer text size improves classification, as like bigger vocabulary, due to its containment of better feature vectors that can separate classes from each other. The worst performing configuration was Dense – 2k vocab – 500 w configuration with F1-Score of 0.8680. On the other hand, LSTM – 20k vocab – 500 word configuration achieved an F1-score of 0.8901, as the best performing configuration.

References

- Buluz, B., Komecoglu, Y., & Kizrak, M. A. (2019). Voting-Based Multiple Classification Approach for Turkish News Texts. *Proceedings - 2019 Innovations in Intelligent Systems and Applications Conference, ASYU 2019*. <https://doi.org/10.1109/ASYU48272.2019.8946333>
- Chen, W., Su, Y., Shen, Y., Chen, Z., Yan, X., & Wang, W. (2019). How large a vocabulary does text classification need? A variational approach to vocabulary selection. *NAACL HLT 2019 - 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Proceedings of the Conference, 1*, 3487–3497. <https://doi.org/10.18653/v1/n19-1352>
- Faruqui, M., Tsvetkov, Y., Yogatama, D., Dyer, C., & Smith, N. A. (2015). Sparse overcomplete word vector representations. *ACL-IJCNLP 2015 - 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing of the Asian Federation of Natural Language Processing, Proceedings of the Conference, 1*, 1491–1500. <https://doi.org/10.3115/v1/p15-1144>
- Gowda, T., & May, J. (2020). Finding the optimal vocabulary size for neural machine translation. *Findings of the*

- Association for Computational Linguistics Findings of ACL: EMNLP 2020*, 3955–3964. <https://doi.org/10.18653/v1/2020.findings-emnlp.352>
- Gurcan, F. (2018). Multi-Class Classification of Turkish Texts with Machine Learning Algorithms. *ISMSIT 2018 - 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies, Proceedings*. <https://doi.org/10.1109/ISMSIT.2018.8567307>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Kepios. (2021). *Digital Around the World — DataReportal – Global Digital Insights*. DATAREPORTAL. <https://datareportal.com/global-digital-overview>
- Kömeçoğlu, Y. (2021). *interpress_news_category_tr_lite*. https://huggingface.co/datasets/interpress_news_category_tr_lite
- Lindemann, B., Müller, T., Vietz, H., Jazdi, N., & Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. *Procedia CIRP*, 99, 650–655. <https://doi.org/10.1016/j.procir.2021.03.088>
- M.Tarwani, K., & Edem, S. (2017). Survey on Recurrent Neural Network in Natural Language Processing. *International Journal of Engineering Trends and Technology*, 48(6), 301–304. <https://doi.org/10.14445/22315381/IJETT-V48P253>
- Nergiz, G., Safali, Y., Avaroglu, E., & Erdogan, S. (2019). Classification of Turkish News Content by Deep Learning Based LSTM Using Fasttext Model. *2019 International Conference on Artificial Intelligence and Data Processing Symposium, IDAP 2019*. <https://doi.org/10.1109/IDAP.2019.8875949>
- Pennington, J., Socher, R., & Manning, C. D. (2014). GloVe: Global vectors for word representation. *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, 1532–1543. <https://doi.org/10.3115/v1/d14-1162>
- Stanfordnlp. (2018). *stanfordnlp/GloVe: GloVe model for distributed word representation*. <https://github.com/stanfordnlp/GloVe>
- Turkish-GloVe. (2020). *Repository for Turkish GloVe Word Embeddings*. <https://github.com/inzva/Turkish-GloVe>
- Wu, C., Wu, F., Huang, Y., & Xie, X. (2022). Personalized News Recommendation: Methods and Challenges. *ACM Transactions on Information Systems*. <https://doi.org/10.1145/3530257>

A Simulation Study on Vehicle-to-Grid Implementation and Environmental Impacts

Bünyamin KUZU*¹, Ozan AKDAĞ², Mustafa NURMUHAMMED³, Teoman KARADAĞ⁴

¹Department of Information Technology, İnönü University, Malatya, Turkey

²Turkey Electricity Transmission Inc., Malatya Regional Directorate, Malatya, Turkey

³Malatya OIZ Vocational School, İnönü University, Malatya, Turkey

⁴Department of Electric-Electronic Engineering, İnönü University, Malatya, Turkey

(bunyamin.kuzu@inonu.edu.tr, ozanakdag@live.com, mustafa.nurmuhammed@inonu.edu.tr, teoman.karadag@inonu.edu.tr)

Abstract— In recent years, electric vehicle (EV) production has become widespread. Since EVs have the ability to store energy due to their structure, ideas have emerged that they can perform tasks such as backup power supply and auxiliary services on the electrical network. One of these ideas is energy transfer from the vehicle to the grid (V2G). In this study, a simulation study of electrical energy transfer to the grid was carried out by ensuring optimum integration of EVs into the grid. Within the scope of the simulation study, the IEEE 5-bus test system was modeled in Matlab environment. Afterwards, EV charging station integration was provided to this power system and related buses. In this model, V2G concept analysis was investigated by simulating the charge/discharge states of EVs. Thus, with this model, both the effects of EVs on the existing grid and their environmental effects are shown in detail. Moreover, 950 EVs were integrated to the sample distribution system and 2572 kWh of electrical energy was transferred to the grid on a per-hour basis, while reducing 8448 kg of CO₂ emissions.

Keywords : *Electric Vehicle, Load Flow, Simulation, V2G*

1. Introduction

Electric vehicles (EVs) were manufactured earlier than vehicles with internal combustion engines (ICE). The first electric vehicle in the history was developed by Prof. Stratingh in Netherlands in 1835. Later, in 1838, an electric locomotive that could reach a speed of 6.4 km / h was produced by Robert Davidson, and in 1882 the electric trolleybus called Elektromote was produced by Siemens. The vehicle named Elektromote has achieved speed of 12 km/h with 2.2 kW power. (Kerem, 2014; Singh, 2013; Ünlü et al., 2003).

Today, automobile manufacturers have started to develop EVs along with ICE vehicles. The popularity of EVs has increased due to greenhouse gases and air pollution caused by ICE (Özbay et al., 2020). The fact that EVs can be charged from anywhere with an electrical outlet and the incentives given by the countries are other reasons for this popularity (Li et al., 2020; Şen, 2012). Especially the incentives provided by China, Norway, England, France and Germany increased the interest in these vehicles. In 2018, more than a million EVs were sold in China, which corresponds to approximately 60% increase compared to the previous year (Li et al., 2020). In addition to individual uses, EVs are increasingly used in public transportation (Dikmen et al., 2021). Since the spread of the number of EVs will increase the energy need, it is predicted that the electricity distribution network will be affected by this situation. There are many studies in the literature examining the effects of EVs on the distribution system. For example, Heydt (1983) predicted that EV owners would charge their vehicles at similar times and there is a high probability that this time period would fall in the peak times, and concluded

that electric load management application is necessary (Heydt, 1983). Güven et al. stated that there may be demands that cannot be met in the network because fast charging stations transmit power with high current and voltage (Güven & AKBAŞAK, 2021). Although EVs can affect the grid with certain problems such as causing harmonics, power quality problems, unmet demands, phase imbalance, they pose less impact on living things and the environment by providing zero emissions. This particular feature of EVs is vital for the global warming problem and the future of our world.

Since EVs have zero emissions thanks to their technological infrastructure, they do not directly emit harmful gases to the environment. Vehicles with ICE using fossil fuels, on the other hand, release nitrogen oxides (NO_x), sulfur oxides (SO_x), carbon monoxide (CO), carbon dioxide (CO₂) and some harmful particles into the nature. Today, the CO₂ emission of vehicles with ICE has been reduced to the level of 100-120 g/km (Volkswagen Türkiye, 2022). As a result of using a vehicle with an ICE for 1000 km, approximately 100-120kg of CO₂, 250g of CO, 30g of NO_x will be released to the environment (Emissions Finder, 2022). Therefore, the spread of EVs will significantly reduce the harmful gases produced by vehicles with ICE. The reduction of harmful gases leads to the regression of the effects of global warming and the reduction of environmental pollution results in healthy societies. Charging EVs using renewable energy resources can contribute to the prevention of environmental pollution and the reduction of greenhouse gases.

The technology used in EVs enables the energy stored in the batteries to feed different sources in line with the needs, just like an energy source. The concept of Vehicle-to-Grid (V2G) energy transfer from the vehicle to the grid has emerged regarding the use of the energy stored in EVs on the distribution network (Kempton & Letendre, 1997).

In this study, the optimum integration of EVs into the grid was performed, the charge/discharge states of EVs were simulated and the amount of electricity transferred to the grid was determined. Next, in this simulation model, the amount of CO₂, NO_x, SO_x emissions that are reduced by using EVs were calculated. In summary, it is anticipated that this study will contribute to the literature in 3 branches. These contributions are:

- 1- Ensuring optimum integration of EVs into the existing distribution network,
- 2- Detailed analysis of charging and discharging processes of EVs into the existing distribution network,
- 3- The effects of EVs on the environment are shown in the form of numerical data.

2. Theoretical Background

In this section, the general structure of EVs, their effects on the grid, charge-discharge operations and the program used for simulation study are explained.

2.1 General Specifications of EVs

There are two types of EVs: A battery electric vehicles (BEV) and hybrid electric vehicles (HEAs). BEVs do not have an ICE and exhaust system like conventional vehicles. Thanks to these features, they do not need fossil fuels and do not emit harmful gases. HEAs, on the other hand, have an ICE as well as a battery and an electric motor (Özbay et al., 2020).




Figure 7. Structure of Hybrid vehicle (Kumar, 2016)

BEVs can be charged over the existing electricity grid in places such as homes, offices, shopping malls. HEAs, on the other hand, has a battery in the structure which leads to lower fuel consumption and emit less harmful gases. (Özbay et al., 2020; Ünlü et al., 2003). All vehicles with batteries has a battery management system (BMS) which facilitates charging and discharging. (Karadağ & Dikmen, 2022; Menak et al., 2021)

2.2. Impact of EVs on Grid

The shorter range of EVs compared to conventional vehicles may cause frequent charging needs and remain charged for a long time in the existing network. With the spread of EVs, this situation may cause additional loads on the network (Kuşdoğan, 2017). When we look at people's driving habits, charging during peak hours indicate that planned charging is required (Heydt, 1983; Yıldız et al., 2018). Fast charging processes, on the other hand, can directly cause problems on the grid components, as they require very high power.

Since charging operations at peak hours will cause very high demand load, they have the potential to damage energy transformers and transmission elements. A transformers life span is estimated to be 40-50 years in the production phase, but in practice it is about 17 years on average. This average life span may decrease if EV adoption level is significantly increased. If different number of vehicles draw power from different phases at the same time, it may cause phase imbalances. During the charging process of EVs, AC voltage is converted to DC. Then the DC voltage is used to charge the battery with the help of DC/DC converters. Since harmonic components can be produced at each step of these stages, power quality problems may arise (Şen et al., 2011; Zoroğlu, 2020).

2.3. Charging Process of EVs

EVs store the electrical energy received from the electrical grid chemically in their batteries. They convert this stored energy back into electrical energy to move the vehicle. The speed of the electrical energy stored during the charging process is very important. The charging speed depends on the power

allowed by the grid, the charging capacity of the EV batteries, and the electronic circuits on the EV that control the charge. Charge levels can be examined in three categories (Kuşdoğan, 2017; Şen et al., 2011).

2.3.1 Level 1

It is the slowest charging process. It is implemented with single-phase electricity supply in houses, parking lots and workplaces.

2.3.2 Level 2

It is medium fast charging. It can be implemented with single-phase or three-phase electricity supply in private and public facilities. It requires higher current than Level 1.

2.3.3 Level 3

It is high speed charging. They are found outside of cities, at gas stations or recreational facilities. They need a very strong infrastructure. Therefore, Level 3 charging stations need to be positioned appropriately to reduce their impact on the energy grid. (Ekici et al., 2021a; Nurmammed, 2021)

Charge levels showing above types are shown in Table 1.

Table 1. Charge levels(SAE, 2017; Shareef et al., 2016)

	Level -1	Level -2	Level -3
Voltage (V)	AC 120	AC 208-240	DC 50-1000
Current (A)	15 - 20	40 - 80	80-400
Power (kW)	1,4 – 1,9	7 – 25	400
Charging time	~8-36 hours	~1-5 hours	%80 10-40 min.

2.4 Vehicle-to-Grid (V2G)

V2G is the use of electric vehicles in the city grid as an energy source. It was first introduced in 1997 by a study by Willett Kempton and Steven Letendre (Kempton & Letendre, 1997). V2G idea; It has emerged with the aim of increasing the need for energy, increasing the emission of greenhouse gases, spreading EVs and solving the energy demand problem especially at peak hours.

Although the V2G concept is likely to be an effective solution to meet peak demand with improvements, it faces technical, economic and social problems. Lack of smart grids, official regulations and high battery costs are some of these problems (Kuşdoğan, 2017). Battery degradation might vary depending on the chemistry used in the batteries.(Ekici et al., 2021b; Özcan et al., 2021)

Contracts to be prepared for the implementation of the V2G concept can be created through joint work by the government, participants and distribution companies. At the end of these studies, it can be ensured that the environment, energy management and user profitability are maximized. The V2G participation procedure is presented in Figure 2.




Figure 8. Flowchart of V2G participation

3.Simulation Study

For the implementation of the V2G concept, a simulation study was prepared using Matlab software in order to examine in detail the environmental consequences of the energy that can be supplied to the grid. In this simulation study, the IEEE 5-bus test system was modeled in Matlab environment. Next, the EV charging stations (EVCSs) were integrated into the buses in this power system according to the power system constraints. Then, charge/discharge states of EVs in this power system are simulated with the codes written in Matlab, and Newton Raphson based load flow integration is performed. The single line diagram of the IEEE 5-bus test system is given in Figure 3. In addition, the load and bus/line data of this power system are given in Tables 2 and 3, respectively. EVCSs are integrated into the buses in IEEE 5-bus test system based on bus limits and the loading rates of the lines. Consequently, 20 MW, 25 MW, 40 MW, 30 MW EVCSs are placed into the buses 2, 3, 4, and 5, respectively. In this study battery capacity of an EV is assumed to be 100 kWh. Accordingly, a total of 950 EV has been integrated into the system.




Figure 9. Single line diagram of IEEE 5-bus test system(Mohan & Vidya, 2020)

Table 2. Load data of the power system(Mohan & Vidya, 2020)

Bus No	Bus Voltage	Generation		Load	
		MW	MVar	MW	MVar
1	$1.06+j0.0$	0	0	0	0
2	$1.0+j0.0$	40	30	20	10
3	$1.0+j0.0$	0	0	45	15
4	$1.0+j0.0$	0	0	40	5
5	$1.0+j0.0$	0	0	60	10

Table 3. Bus/Line data of the power system(Mohan & Vidya, 2020)

Line	Line Impedance		Line Charging
	R per unit	X per unit	
1-2	0.02	0.06	$0.0+j0.03$
1-3	0.08	0.24	$0.0+j0.025$
2-3	0.06	0.25	$0.0+j0.02$
2-4	0.06	0.18	$0.0+j0.02$
2-5	0.04	0.12	$0.0+j0.015$
3-4	0.01	0.03	$0.0+j0.01$
4-5	0.08	0.24	$0.0+j0.025$

Load flow analysis was performed according to whether EVs are active or not in the 5 bus sample power system. Results of load flow analysis are shown in Table 4. According to the table, bus voltages are within normal limits before and after the EVs were integrated into the distribution system. The most challenging scenario after EV integration which is simultaneous charging of all EVs is considered. In this scenario, it is desired that the bus voltages of the power system fall between 0.9 -1 pu (Akdağ & Yeroğlu, 2020). The battery capacity of an EV is assumed to be 100 kWh.

Table 4. Load flow analysis results

EV integration after				EV integration before			
P_{g1}	194.7 MW	V_4	0.95 pu	P_{g1}	89 MW	V_4	0.97 pu
Q_{g1}	11.7 MVAR	V_5	0.91 pu	Q_{g1}	18 MVAR	V_5	0.96 pu
P_{g2}	40 MW	P_{loss}	14.7 MW	P_{g2}	40 MW	P_{loss}	4 MW
Q_{g2}	30 MVAR	Q_{loss}	0.12 MVAR	Q_{g2}	30 MVAR	Q_{loss}	0.03 MVAR
V_1	1 pu	P_D	260 MW	V_1	1 pu	P_D	165 MW
V_2	0.95 pu	Q_D	48 MVAR	V_2	0.98 pu	Q_D	48 MVAR
V_3	0.93 pu			V_3	0.97 pu		

It is assumed that all EVs in this simulation study have a battery capacity of 100 kWh and that the vehicles will participate in V2G once a day. At the beginning of the simulation run, the system requests the number of vehicles to be entered. By taking the number of vehicles, each vehicle is randomly assigned an instantaneous charge level between 30% and 99%. EVs with a battery charge level below 40% are not included in the V2G system. Until the state of charge of the remaining EVs was lower than 40%, 6 kWh of energy is transferred to the grid every hour. At the end of a total of 10 hours, the energy transferred to the grid was calculated and the contribution of EVs on the environment via V2G system was analyzed in detail. When the simulation was repeated 3 times with 950 EVs, the status of participation in V2G is shown in Table 5. In addition, the load flow data obtained after simulating the charge/discharge states of the EVs in this study are given in Table 4. According to the results seen in Table 6, 25872 kWh has been added to the power system. As a result of this power transfer, 1056 kg/h CO₂, 4,48 kg/h SO_x, 0,012 kg/h NO_x emissions have been reduced.

Table 5. Simulation study V2G participation data

Total Number of Vehicles to Participate in Simulation	950	950	950
Number of Vehicles Not Participating in V2G	146	130	136
Number of Vehicles Participating in V2G	804	820	814

The simulation study calculates the energy flow to the grid after decoupling the EVs that will participate the V2G. The V2G energy flow process performed in the simulation study is presented in Figure 4.


**Figure 10.** Simulation study

Table 6 shows the amount of energy transferred to the grid with the V2G concept and the number of households whose energy needs are met assuming the average hourly energy need of a house is 8 kWh.

Table 6. Energy transfer to the grid in the simulation study

	Hourly Energy Transfer	Number of houses
Energy transfer for the 1st hour	4824 kWh	603
Energy transfer for the 2nd hour	4296 kWh	537
Energy transfer for the 3rd hour	3816 kWh	477
Energy transfer for the 4th hour	3366 kWh	421
Energy transfer for the 5th hour	2850 kWh	356
Energy transfer for the 6th hour	2364 kWh	296
Energy transfer for the 7th hour	1836 kWh	230
Energy transfer for the 8th hour	1320 kWh	165
Energy transfer for the 9th hour	792 kWh	99
Energy transfer for the 10th hour	408 kWh	51
Total energy transfer	25872 kWh	3235

For every 1000 kWh of electricity produced using coal, an average of 800-1000 kg of CO₂ is emitted. For natural gas, this rate is between 600-800 kg (Akdağ & Yeroglu, 2020). In Turkey, the share of coal in electricity production is 20% and the share of natural gas is 24% (Tur. Elec. Trans. Corp. 2022). According to the simulation result, the CO₂ emitted by the use of coal to meet the energy supplied to the grid by V2G has decreased by 4310 kg, and the CO₂ due to the use of natural gas has decreased by 4138 kg. A grown beech tree eliminates an average of 2.35 kg of CO₂ per hour (Gen. Dir. For., 2022). Amount of prevented CO₂ emissions by 10-hour energy transfer with 950 EV in the simulation study, corresponds to cleaning ability of approximately 450 grown beech trees.

4. Conclusion

In this paper, a simulation study was carried out to show the effects of the V2G concept on the environment and the existing network by ensuring the optimum integration of EVs into the distribution network. IEEE 5-bus test system was used to transfer the energy stored by the EVs to the grid. This test system and the EV charging stations are modeled in the MATLAB environment. In this model, simulation of EVs providing energy flow in peak hours is performed. Considering that the effect of 950 EVs on the grid lasts for 10 hours, a simulation study has been carried out accordingly. In this time period, a total of 25872 kWh energy flowed into the grid and the 10-hour electricity needs of approximately 323 households were met. Thus, approximately 8448 kg of CO₂ emission has been prevented. Hence, in this study, both the effects of EVs on the existing network and the environmental effects on the relevant location were analyzed in detail according to the V2G concept.

5. References

- Akdağ, O., & Yeroglu, C. (2020). An evaluation of an offshore energy installation for the Black Sea region of Turkey and the effects on a regional decrease in greenhouse gas emissions. *Greenhouse Gases: Science and Technology*, 10(3), 531–544. <https://doi.org/10.1002/ghg.1963>
- Dikmen, İ. C., Ekici, Y. E., Karadağ, T., Abbasov, T., & Hamamcı, S. E. (2021). Electrification in Urban Transport: A Case Study with Real-time Data. *Balkan Journal of Electrical and Computer Engineering*, 9(1), 69–77. <https://doi.org/10.17694/bajece.837248>
- Ekici, Y. E., Dikmen, İ. C., Nurmhammed, M., & Karadağ, T. (2021a). A Review on Electric Vehicle Charging Systems and Current Status in Turkey. *International Journal of Automotive Science And Technology*, 5, 316–330. <https://doi.org/10.30939/ijastech..958368>
- Ekici, Y. E., Dikmen, İ. C., Nurmhammed, M., & Karadağ, T. (2021b). Efficiency Analysis of Various

- Batteries with Real-time Data on a Hybrid Electric Vehicle. *International Journal of Automotive Science And Technology*, 5(11), 214–223. <https://doi.org/10.30939/ijastech..946047>
- Emissions Finder. (2022). *Find Emission for Vehicle*.
- General directorate of forestry. (2022). General Directorate of Forestry. <https://www.ogm.gov.tr/tr/bunlari-biliyor-muydunuz>
- Güven, A. F., & AKBAŞAK, S. B. (2021). Elektrikli Araçlarda DA Hızlı Şarj Ünitelerinin Şebeke Altyapısına Etkilerinin İncelenmesi. *Sinop Üniversitesi Fen Bilimleri Dergisi*, 6(1), 42–54.
- Heydt, G. T. (1983). The impact of electric vehicle deployment on load management strategies. *IEEE Transactions on Power Apparatus and Systems*, PAS-102(5), 1253–1259. <https://doi.org/10.1109/TPAS.1983.318071>
- Karadağ, T., & Dikmen, İ. C. (2022). Yeni Nesil, Modüler ve Akıllı Batarya Yönetim Sistemi. *European Journal of Science and Technology*, 32, 1103–1112. <https://doi.org/10.31590/ejosat.1045564>
- Kempton, W., & Letendre, S. E. (1997). Electric vehicles as a new power source for electric utilities. *Transportation Research Part D: Transport and Environment*, 2(3), 157–175. [https://doi.org/10.1016/S1361-9209\(97\)00001-1](https://doi.org/10.1016/S1361-9209(97)00001-1)
- Kerem, A. (2014). Elektrikli Araç Teknolojisinin Gelişimi ve Gelecek Beklentileri. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 5(1), 1–13.
- Kumar, A. R. (2016). *Focus on Expansion of Hydrogen and Electric Fleets for Passenger and Freight Transport in United Kingdom* (Issue August). University of Aberdeen.
- Kuşdoğan, Ş. (2017). Akıllı Şebekelere Elektrikli Araçların Entegrasyonu ve Taşıttan Şebekeye V2G Uygulamaları. III. Güç ve Enerji Sistemleri Sempozyumu, İzmir, 2017.
- Li, X., Tan, Y., Liu, X., Liao, Q., Sun, B., Cao, G., Li, C., Yang, X., & Wang, Z. (2020). A cost-benefit analysis of V2G electric vehicles supporting peak shaving in Shanghai. *Electric Power Systems Research*, 179(106058). [10.1016/j.epsr.2019.106058](https://doi.org/10.1016/j.epsr.2019.106058)
- Menak, R., Karadağ, T., Altuğ, M., & Tan, N. (2021). Elektrikli Araçlarda Batarya Yönetim Sistemleri Üzerine Bir Derleme Çalışması A Review Study On Battery Management Systems In Electric Vehicles. *Gazi University Journal of Science Part A: Engineering and Innovation*, 8(2), 234–275. <https://dergipark.org.tr/tr/pub/gujisa/issue/63143/886738>
- Mohan, A., & Vidya, M. S. (2020). Artificial neural network model of an IEEE 5 bus system under transient conditions. *Proceedings of the 3rd International Conference on Smart Systems and Inventive Technology, ICSSIT 2020, Iccsit*, 234–241. <https://doi.org/10.1109/ICSSIT48917.2020.9214298>
- Nurmuhammed, M. (2021). Elektrikli Araç Şarj İstasyonlarının Konumlandırılması ve Enerji Şebekesi Üzerine Etkisi Konulu Derleme Çalışması A Review on Locating the Electric Vehicle Charging Stations and Their Effect on the Energy Network. 8(2), 218–233.
- Özbay, H., Közkurt, C., Dalcı, A., & Tektaş, M. (2020). Geleceğin ulaşım tercihi : Elektrikli araçlar. *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 3(1), 34–50.
- Özcan, Ö. F., Karadağ, T., Altuğ, M., & Özgüven, Ö. F. (2021). A Review Study on the Characteristics and Advantages of Battery Chemicals Used in Electric Vehicles. *Gazi University Journal of Science*, 8(2), 276–298.
- SAE, I. (2017). *Electric Vehicle and Plug in Hybrid Electric Vehicle Conductive Charge Coupler. Standard J1772_201710*. https://www.sae.org/standards/content/j1772_201710/
- Şen, G. (2012). *Şarj Edilebilen Elektrikli Araçların Kesintisiz Güç Kaynağı Olarak Kullanılmasını Sağlayan Bir Güç Ünitesinin Tasarımı Ve Uygulaması*. Yıldız Teknik Üniversitesi.
- Şen, G., Boynuegri, A. R., & Uzunoglu, M. (2011). Elektrikli Araçların Şarj Yöntemleri Ve Araçların Şebekeyle Bağlantısında Karşılaşılan Problemlere Yönelik Çözüm Önerileri. *Elektrik-Elektronik ve Bilgisayar Sempozyumu, Elazığ*, 2011, 357–362. <https://doi.org/10.13140/2.1.1956.8648>
- Shareef, H., Islam, M. M., & Mohamed, A. (2016). A review of the stage-of-the-art charging technologies, placement methodologies, and impacts of electric vehicles. *Renewable and Sustainable Energy Reviews*, 64, 403–420. <https://doi.org/10.1016/j.rser.2016.06.033>
- Singh, M. (2013). Green Energy for Metropolitan Transport. *International Journal on Power Engineering and Energy*, 4(1), 338–342. <https://doi.org/10.12986/ijpee.2013.002>
- Teias. (2022). *June 2022 Installed Power Report*. <https://www.teias.gov.tr/kurulu-guc-raporlari>. Accessed 14 July 2022
- Ünlü, N., Karahan, Ş., Tür, O., Uçarol, H., Özsu, E., Yazar, A., Akgün, F., Tırıs, M., & Turhan, L.

- (2003). Elektrikli Araçlar. In *Türkiye Bilimsel ve Teknik Araştırma Kurumu Marmara Araştırma Merkezi*.
- Volkswagen Türkiye. (2022). *volkswagen golf brochure*. <https://ebrosur.vw.com.tr/araclar/golf-8/golf-8.html> Accessed: 12 July 2022
- Yıldız, B., Çiftçi, H., Ayan, O., & Türkay, B. E. (2018). Elektrikli Araçların Dağıtım Şebekesine Etkisinin Maliyet Analizi ve Genetik Algoritma ile Optimizasyonu Cost Analysis of the Effect of Electric Vehicles on Distribution Network and Optimization with Genetic Algorithm. *Güç Sistemleri Konferansı*, 7–12. <https://doi.org/10.5281/zenodo.1482364>
- Zoroğlu, B. (2020). Elektrikli Araç Şarj İstasyonlarının Standartları Ve Türkiye ' Deki Elektrikli Araç Durumu. *International Marmara Sciences Congress*, 301–310.

Radyal Elektrik Dağıtım Sistemlerinde Gerilim Profillerinin İyileştirilmesi ve İletim Kayıplarının Azaltılması için Sistem Yapılandırmasına Bağlı Optimal Kapasitör Yerleşimi

Optimal Capacitor Placement Based on System Configuration for Improving Voltage Profiles and Reducing Transmission Losses in Radial Electric Distribution Systems

Serkan KOCA^{*1} , Mustafa ŞEKER² , Hülya DOĞAN³ 

¹Çamlıbel Elektrik Dağıtım A.Ş., Sivas, Türkiye

²Hafik Kamer Örnek Meslek Yüksekokulu, Ulaştırma Hizmetleri Bölümü, Raylı Sistemler İşletmeciliği Programı, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye

³Elektrik- Elektronik Mühendisliği Bölümü, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye

(serkan.koca@cedas.com.tr, mustafaseker@cumhuriyet.edu.tr, hdogan@cumhuriyet.edu.tr)

Özetçe— Bu çalışma, radyal dağıtım sistemlerinde Binary Parçacık Sürü Optimizasyon Algoritması (Binary Particle Swarm Optimization-BPSO) kullanılarak kapasitörlerin optimal konumlarını ve boyutlarını belirlemek için sistem yapılandırmasına bağlı bir yaklaşım sunmaktadır. Analizde, 33 baralı test sistemin kullanılarak, elektriksel sisteme ilişkin kısıtlamalar, yük duyarlılık indeksi ve geri/ileri süpürme (Backward/Forward Sweep) algoritması yardımıyla sabit ve anahtarlamalı kapasitörler için optimum kapasitör lokasyonları ve büyüklüklerinin belirlenmesi hedeflenmiştir. Sonuçlar, şebeke yapılandırılması kullanarak optimal kapasitör yerleşimi yapılması ile elektriksel sistemlerdeki kayıplar, gerilim profilleri ve maliyet yönünden daha verimli şekilde işletilebileceğini göstermektedir. Radyal sistemlerin planlanmasında ve yapılacak yatırımlarda sistem yapılandırmasına bağlı optimal kapasitör yerleşimi önerilmektedir.

Anahtar Kelimeler : Optimal Kapasitör Yerleşimi, Radial dağıtım şebekeleri, Güç Kayıpları, Gerilim Profili İyileştirme.

Abstract— This study presents a system configuration-dependent approach to determine the optimal positions and sizes of capacitors using Binary Particle Swarm Optimization (BPSO) in radial distribution systems. The analysis, is aimed to determine the optimum capacitor locations and sizes for fixed and switched capacitors with the help of electrical system constraints, load sensitivity index, and back/forward sweep algorithm using a 33 busbar test system. The results show that with optimal capacitor placement using grid configuration, electrical systems can be operated more efficiently in terms of losses, voltage profiles, and cost. Optimal capacitor placement is recommended depending on the system configuration in the planning of radial systems and investments to be made.

Keywords: Optimal Cpacitor Placement, Radial Disturbution Networks, Power Losses, Voltage Profile Improvement.

1.Giriş

Elektrik enerjisinin üretildiği noktadan son tüketiciye kadar aktarılırken; iletilen gücün sürekliliğinin yanı sıra beslenen gerilimin belli bir frekans değerinde ve arzu edilen dalgalanma sınırları içerisinde olması istenir. Elektrik iletim ve dağıtım sistemleri, sistemin herhangi bir noktasında arıza olması

durumunda minimum tüketicinin enerjisiz kalması ve enerji sürekliliğinin sağlanması için her ne kadar ring yapıda tasarlanmış olsalar da radyal yapıda çalışacak şekilde işletilirler. Dağıtım sistemlerindeki yükler hızlı bir yayılıma sahiptir ve bu yükler enterkonnekte sisteme aktarılır. Hızlı yayılıma sahip yükler dağıtım sistemlerinde radyal yapının uzun olması, iletim hatlarının yüksek R/X oranına sahip olması, güç kayıpları ve gerilim düşmeleri ve güç faktörü gibi birçok durumu göz önüne alarak sistemin kararlılığının ve güvenilirliğin sağlanması gereklidir. Böylelikle, iletim hattının uygun gerilim seviyelerinde, en az kayıpla ve kesintisiz olarak tüketiciye ulaştırılması sağlanır. Bu işlemi gerçekleştirmek için elektriksel sistemin radyal yapıyı koruyacak şekilde en uygun anahtarlama pozisyonunun belirlenerek çalıştırılması gereklidir. Ayrıca maliyeti azaltmak, sistemin güvenilirliğini ve güç kalitesini arttırmak için radyal fiderlere şönt kapasitörler de kurulur. Bu durumda radyal sistemleri planlamada en önemli problem hangi anahtarlama pozisyonuna sahip olarak sistemin çalıştırılması gerektiği ve kapasitörlerin optimal konumları ve boyutlarının belirlenmesidir. Bu problem bir optimizasyon problemi olarak tanımlanabilir.

Elektrik dağıtım sistemlerinde optimizasyon ile ilgili ilk çalışma 1975 yılında Merlin & Back tarafından gerçekleştirilmiştir(Merlin A., Back 1975) ve uygulamış oldukları yöntem ile dağıtım hatlarında kaybin azaltılabileceğini göstermişlerdir. Fakat sunulan bu yöntemin en büyük dezavantajı yakınsama probleme sahip olmasıydı. Bu nedenle problemin çözümünde daha karalı bir yapıyı sağlayacak algoritmalara ihtiyaç duyulmuştur. Bunun üzerine Baran & Wu çalışmalarında şebeke topolojilerinde uygun anahtarlama durumlarını belirleyerek ve değiştirerek kayıpların azaltılarak şebekedeki yük dengesinin sağlanabileceğini ileri sürmüşlerdir (Baran and Wu 1989). Ayrıca problemin çözümünde kararlılığın sağlanması için tekil amaç fonksiyonları yerine çoklu fonksiyonların kullanılmasının daha faydalı olacağını belirlemişlerdir. Yine benzer şekilde Cheng(Wang and Cheng 2008) çalışmalarında çoklu amaç fonksiyonu üzerinde durmuş ve buna ek olarak elektriksel şebekelerde gerilim ve güç kayıplarına ilişkin tanımlamalar yapmıştır.

Elektriksel sistemlerinin kayıplar ve gerilim profillerinin iyileştirilmesi için yeniden yapılandırılması farklı optimizasyon algoritmaları kullanılarak birçok araştırmacı tarafından incelenmiştir. Chiang (Wang and Cheng 2008), Bitki Büyüme Simülasyon Algoritması (Plant Growth Simulated Algorithm) kullanarak dağıtım şebekelerinde yeniden yapılandırmasını değerlendirmiştir. Rao (Srinivasa Rao et al. 2011) ise gerçekleştirmiş olduğu çalışmada, radyal sisteminin yapılandırmasını harmony search algoritması kullanarak gerçekleştirmiştir. Niknam (Niknam and Sadeghi 2011), Parçacık Sürü Optimizasyonu (PSO) ve Bal Arısı Çiftleşme Optimizasyonu (Honey Bee Mating Optimization-HBMO) algoritmalarını temel alan Hibrit Evrimsel algoritmasını kullanarak 33 ve 69 baralı sistemler için elektriksel şebekenin yapılandırmasını değerlendirmiştir. Hoosmand ve ark. (Saffar, Hoosmand, and Khodabakhshian 2011) ise şebeke yeniden yapılandırmasını tanımlamada bulanık mantık tabanlı optimal güç akışını kullanmıştır. Bu algoritmada yük akışı, şebekedeki minimum güç kaybı, yük dengesi, branşların akım kapasite sınırlamaları ve fiderlerin maksimum ve minimum limitlerini dikkate alarak gerçekleştirmiştir. Bu çalışmaların haricinde sunulan farklı Meta-Heuristik yaklaşımlarda dağıtım şebekelerinin yapılandırması (reconfigürasyonu) gerçekleştirmek için kullanılmıştır(Mohamed Imran and Kowsalya 2014; Teimourzadeh and Zare 2014; Niknam and Sadeghi 2011; De Oliveira et al. 2014; Cikan and Kekezoglu 2022). Gerçekleştirilen çalışmalar değerlendirildiğinde arama algoritmalarının genel olarak, dağıtım hatlarındaki kayıp miktarının minimuma düşürülmesi, gerilimin düşümlerinin nominal değerler aralığında iyileştirilmesinin sağlanması amaçlanmaktadır.

Elektriksel sistemlerde kayıp ve gerilim profillerinin iyileştirilmesi için en etkili yöntemlerden birisi de reaktif güç kompanzasyonudur. Elektriksel sistemlerde optimal kapasitör yerleşiminin ve kapasitör büyüklüğünün belirlenmesi de birçok araştırmacı tarafından incelenmiştir. Etemadi ve Fotuhi-Firuzabad (A.H. Etemadi 2008), farklı amaç fonksiyonları ile optimal kapasitör yerleşimini bulmak için PSO algoritmasını kullanmışlardır. Prakash ve Sydulu (K. Prakash; M. Sydulu 2007), sırasıyla kapasitörlerin optimal konumlarını ve boyutlarını bulmak için yük duyarlılık faktörü (LSF) ve PSO algoritmasını kullanmışlardır. Reddy ve Sydulu (V. Reddy 2014), kapasitör yerleştirme problemi için güç kaybı indeksi (PLI) tabanlı konum ve indeks ve genetik algoritma (GA) tabanlı boyutlandırma sunmuştur. Raju ve ark. (Ramalinga Raju, Ramachandra Murthy, and Ravindra 2012), aktif güç kaybını en aza indirmek için sabit ve anahtarlama kapasitörlerin optimal konumlarını ve boyutlarını bulmak için doğrudan arama algoritmasını sunmuştur. Tabatabaei ve Vahidi (Tabatabaei and Vahidi 2011), bulanık

karar verme ve bakteri arama algoritmasını (BFA) kullanarak kapasitörlerin optimal konumlarını ve boyutlarının belirlenebileceğini ortaya koydu. Nojavan ve ark.(Nojavan, Jalali, and Zare 2014) radyal/ağ dağıtım sistemlerinde kapasitör yerleşimi için karışık tamsayı doğrusal olmayan bir programlama yaklaşımı sunmuştur. Xu et al. (Yan Xu; Zhao Yang Dong; Kit Po Wong; Evan Liu; Benjamin Yue 2013), kapasitör banklarının optimal yerleşimini bulmak ve kapasitör kurulum projesinin maliyet faydasını değerlendirmek için karma bir programlamayı ve net bugünkü değer kriterine göre kullanmıştır.

Bu çalışmada, Binary Parçacık Sürü Optimizasyon Algoritması (Binary Particle Swarm Optimization-BPSO) kullanılarak 33 baralı radyal dağıtım sisteminin optimal kapasitör lokasyonunun ve büyüklüğünün belirlenmesi şebeke yapılandırmasına bağlı olarak değerlendirilmiştir. Optimizasyon analizinde çoklu amaç fonksiyonu kullanarak şebeke kayıplarının en aza indirilmesi, gerilim profillerinin iyileştirilmesi ve optimal kapasitör yerleşimine bağlı olarak toplam enerji maliyetlerinin azaltılması amaçlanmıştır.

Çalışmanın ikinci bölümünde sunulan probleme ilişkin tanımlamalara ve optimizasyonda kullanılan kısıtlamalara yer verilmiştir. Analizde kullanılan kayıp indeksi ve yük akışı için kullanılan ileri/geri süpürme algoritması (Backward-Forward Sweep (BFS)) sırası ile çalışmanın üç ve dördüncü bölümünde açıklanmıştır. Çalışmanın beşinci bölümünde PSO algoritması açıklanmıştır. Altıncı bölümde ise sunulan yaklaşım ile elde edilen sonuçlar açıklanmıştır. Son bölüm ise elde edilen sonuçların genel bir özetini sunmaktadır.

2. Problemin Tanımlanması

Radyal dağıtım sisteminde, sistemin radyal yapıda kalması sağlandıktan sonra, optimal kapasitör yerleşimi için toplam enerji maliyetinin en aza indirgenmesi amaçlanır. Bu durum aşağıda sunulan matematiksel eşitlik ile ifade edilir(Abou El-Ela et al. 2016);

$$S_{min} = K_p P_{tk} + K_c Q_{ct} = K_p \sum_{i=1}^{N_b-1} P_{k,i} + K_c \sum_{i=1}^{N_c} Q_{c,j} \quad (1)$$

Bu denklemde, S yıllık toplam maliyet, K_p birim güç kaybı başına yıllık maliyet ve K_c ise toplam kapasitör kurulum maliyetidir. $P_{k,i}$ ve $Q_{c,j}$ ise i ve j. konumuna göre sırası ile hattın güç kaybı ve sisteme enjekte edilen reaktif gücü ifade etmektedir. N_b ise sistemdeki toplam bara sayısını ifade etmektedir. N_c ise sistemdeki toplam kapasitör sayısıdır. Bu değerler dikkate alınarak kapasitörlerin yıllık toplam maliyetleri (2) denklemi ile ifade edilebilir;

$$Toplam\ Kapasitör\ Maliyeti = \frac{K_c \cdot Q_{ct}}{Ekonomik\ ömür} / (yıl) \quad (2)$$

- (1) Denklemde sunulan amaç fonksiyonunun optimizasyon probleminde minimize edilmesinde aşağıda sunulan operasyonel ve sınırlamalar dikkate alınır;

a) Operasyonel Sınırlamalar

- **Dağıtım şebekesinin radyal topolojik yapısının korunması ve Radyal Test**

Dağıtım şebekeleri genellikle radyal olarak işletilir. Herhangi bir arıza veya ihtiyaç duyulan bir manevra yapılması durumunda sistemdeki anahtarlama pozisyonları değiştikten sonra da, radyal yapının korunması amaçlanır. Denklem (3), radyal yapının sağlanması için açılması gereken anahtar sayısını ifade eder.

$$\Lambda = B - N + S \quad (3)$$

Bu ifadede, Λ - açılması gereken anahtar sayısını (dağıtım hattında bulunan göz sayısını), B- hattın toplam dal sayısını, N- Radyal hattın bara sayısını ve S- toplam fider sayısını ifade etmektedir.

Radyal dağıtım hattı bağlantı değiştiriciler (tie-switch -T.S) ve bu hatta bağlı olan bölümleyici anahtarlardan (sectionalising switch- S.S) oluşur(Cikan and Kekezoglu 2022). Sistemin radyal yapıda olması için aşağıdaki koşulları da sağlaması gereklidir.

- ✓ Sistemde bulunan tüm yüklerin aynı fider tarafından besleniyor olması
- ✓ Hatta hiçbir göz tipi (kapalı bir çevrim) yapının bulunmaması

Bu durumda dağıtım hattında bulunacak SS' lerin sayısı ise (4) ifadesi ile belirlenir.

$$N_{S.S.} = N_{Bara} - 1 \quad (4)$$

Anahtarlar pozisyonları değiştirilerek sistemin yapılandırılmasından sonra radyallığın korunması için gerekli şartlar eşitlik (3) ve (4) gösterilmiştir. Radyallığın sağlanabilmesi için Bara sıklık matrisinden faydalanılır (Mekhamer et al. 2008; Mohammadi-Ivatloo B. 2020). Bu matris oluşturulurken (5) denkleminde belirtilen koşullar dikkate alınır.

$$\hat{A} = \begin{cases} a_{ij} = 0 & \text{Eğer branş } i, j' \text{ ye bağlı değilse} \\ a_{ij} = -1 & \text{Eğer branş } i, \text{ düğümüne doğru yönelmişse} \\ a_{ij} = 1 & \text{Eğer branş } i, \text{ uzaktaki } j \text{ düğümüne yönelmişse} \end{cases} \quad (5)$$

Bu kabule göre sistem bir matris olarak oluşturularak, matrisin determinant değeri incelenerek sistemin radyal olup olmadığına karar verilir (Denklem (6)).

$$\det(\hat{A}) = \begin{cases} -1 \text{ or } 1 & \text{Radyal} \\ 0 & \text{Radyal değil} \end{cases} \quad (6)$$

Eğer $|\det(A)| = 1$ sistem radyaldır ve baralara bağlı tüm yükler tek kaynak tarafından besleniyordur.

- **Bara Gerilim Limitleri (Bus Voltage Limitation)**

Dağıtım şebekelerinde bara gerilim seviyelerini belirli sınırlar arasında olmalıdır.

$$V_{\min}^i \leq V_{\text{bara}}^i \leq V_{\max}^i \quad (7)$$

Bara gerilim sınır değeri $0.9.V_{\text{bara}}^i \leq V_{\text{bara}}^i \leq 1.1.V_{\text{bara}}^i$ p.u. Besleme noktaları için müsaade edilen gerilim aralığı $0.95.V_{\text{fider}}^i \leq V_{\text{fider}}^i \leq 1.05.V_{\text{fider}}^i$ p.u. olarak kabul edilir.

- **Hattın akım taşıma kapasitesi (Branches Current Limitation)**

Akımın maksimum değeri, hattın akım taşıma kapasitesini aşmamalıdır.

$$I_{\text{Bara}}^i \leq I_{\text{maksimum}}^i \quad (8)$$

- **Güç akış sınırlaması**

Her hattaki güç akışı maksimum güç akış sınırından daha az olmalıdır.

$$|PF_k| < PF_k^{\max} \quad (9)$$

- **Güç faktörü sınırlaması**

Sistemin güç faktörü minimum güç faktöründen büyük veya eşit olmalıdır.

$$|pf_{\text{sistem}}| \geq pf_{\text{sistem}}^{\min} \quad (10)$$

b) Kapasitör Sınırlamaları

- **Kapasitör Sayısı**

Bu sınırlama ile yerleştirilecek kapasitör sayısının azaltılması amaçlanır. N_c optimal kapasitör sayısı olmak üzere; sisteme enjekte edilecek kapasitör sayısı mümkün olan kapasitör yerleşim noktalarının sayısına ($N_{c,\max}$) eşit veya daha az olmalıdır.

$$N_c \leq N_{c,\max} \quad (11)$$

- **Kapasitör büyüklüğü**

Reaktif güç enjeksiyonu, mümkün olan minimum ve maksimum limitler dahilinde olmalıdır.

$$Q_{Cj}^{\min} \leq Q_{Cj} \leq Q_{Cj}^{\max} \quad (12)$$

Bu ifadede, Q_{Cj} , j noktasında sisteme enjekte edilen reaktif gücü ifade etmektedir.


- **Toplam Reaktif Güç**

Sisteme enjekte edilen toplam reaktif güç miktarı, yüklerin reaktif güç toplamına eşit veya daha az olmalıdır.

$$Q_C^{Toplam} \leq Q_L^{Toplam} \quad (13)$$

3. Kayıp Duyarlılık İndeksi

Şekil 1'de gösterilen bir radyal dağıtım sisteminde bir dal ile birbirine bağlı 2 düğümü ayrı olarak düşünüldüğünde, p ve q veri yolları sırasıyla gönderen ve alan uç veri yollarıdır.



Şekil 6. Bir dağıtım sisteminde iki düğüm olarak gösterimi.

Şekil 1'de, V_p ve V_q sırası ile p ve q düğümlerindeki gerilim değerleridir. δ_p ve δ_q ise sırası ile p ve q düğümlerinin gerilim açılarıdır. R_k ve X_k ise sırası ile sunulan dalın direnci ve reaktansını ifade etmektedir.

Her bir dal için akım ve gerilim yasaları uygulanarak, gerekli düzenlemeler yapıldığında; k branşı için aktif ve reaktif güç değerleri denklem (14-15) denklemleri ile ifade edilir (Abou El-Ela et al. 2016).

$$P_{kayıp,k} = I_k^2 \cdot R_k = \left(\frac{P_{eff/q}^2 + Q_{eff/q}^2}{|V_q|^2} \right) \cdot R_k \quad (14)$$

$$Q_{kayıp,k} = I_k^2 \cdot X_k = \left(\frac{P_{eff/q}^2 + Q_{eff/q}^2}{|V_q|^2} \right) \cdot X_k \quad (15)$$

Bu eşitlikler dikkate alınarak N_b bara sistemdeki toplam sayısı olmak üzere, radyal bir sistem için toplam aktif ve reaktif güç değerleri denklem (x)-(y) ile tanımlanır.

$$P_{kayıp}^{toplam} = \sum_{q=2}^{N_b} \sum_{k=1}^{N_b-1} \left(\frac{P_{eff/q}^2 + Q_{eff/q}^2}{|V_q|^2} \right) \cdot R_k \quad (16)$$

$$Q_{kayıp}^{toplam} = \sum_{q=2}^{N_b} \sum_{k=1}^{N_b-1} \left(\frac{P_{eff/q}^2 + Q_{eff/q}^2}{|V_q|^2} \right) \cdot X_k \quad (17)$$

Burada, $P_{eff/q}$ ve $Q_{eff/q}$, sırasıyla q düğümünün çektiği toplam etkin aktif ve reaktif güç yükleridir. N_{b-1} ise toplam sistemdeki dal sayısını ifade eder. Sunulan bu denklemlerde verilen değişkenlere göre Yük Duyarlılık İndeksi (LSI-Load Sensitive Index) aşağıdaki gibi ifade edilebilir.

$$LSI = \frac{dP_{kayıp,k}}{dQ_{eff/q}} = \frac{2 \cdot Q_{eff/q} \cdot R_k}{V_q^2} \quad (18)$$

4. Backward/Forward Sweep (BFS) Algoritması

Elektrik şebekelerinde yük akış analizi için Newton Raphson, Gauss Siedel ve Fast Decoupled gibi geleneksel yük akış algoritmaları kullanılmaktadır. Elektrik dağıtım şebekelerinde R/X veya I/V oranı yüksek olmasından dolayı ağ tipi sistemlerde kullanılan geleneksel metotlar istenilen hassasiyette çözüm

üretmemektedir. Bu nedenle radyal yapıdaki sistemleri modelleyebilmek için farklı algoritmalar geliştirilmiştir. Bunlardan bir tanesi İleri/Geri Süpürme (Bacward/Forward Sweep -BFS) algoritmasıdır.

Adım 1 : Başlangıç için tüm bara gerilim değerleri 1 p.u olarak kabul edilir. ($v_k^{init} = 1$ p.u).

Adım 2 : Baralara bağlı yüklerin (s_d^k) talep ettikleri bara sonu toplam güçleri hesaplanır ve 'k' barasına ait admintansı (y_d^k) üzerinden geçen güç belirlenir.

$$S_t^k = s_d^k + \frac{(y_d^k)^*}{v_k^2} \quad k = 1, 2, 3, \dots, n_b \quad (19)$$

Adım 3 : Backward-Sweep: Hat sonunda itibaren tüketilin güç ve kayıplar toplamı Eşitlik 4.2 kullanılarak hesaplanır. Bu işlem hat sonundan başlayarak slack bus'a kadar devam eder.

$$S_f^k = S_t^k + z_s^k \cdot \left[\frac{S_t^k}{v_k} \right]^2 \quad k = n_1, n_{1-1}, n_{1-2}, \dots, 2 \quad (20)$$

$$S_{t,new}^i = S_t^i + S_f^k \quad k = n_1, n_{1-1}, n_{1-2}, \dots, 2 \quad (21)$$

Adım 4 : Forward-Sweep : Gönderilen baranın (PV) değerleri kullanarak 'i-k' barasındaki gerilim düşümünü hesaplanır ve hat sonuna kadar aynı işlemi tekrar edilir.

$$v_k = v_i - z_s^k \cdot \left(\frac{S_f^k}{v_i} \right)^* \quad k = 2, 3, \dots, n_1 \quad (22)$$

Adım 5 : Hat sonundaki baranın gerilim değeri ile 4.basamakta bulunan değer karşılaştırılır. Önceki ve sonraki iterasyon değeri ile hata miktarı bulunur.

$$\max_{i=1 \dots n_b} \{ |v_i^{(v)} - v_i^{(v-1)}| \} < \epsilon \quad (23)$$

Bulunan değer ϵ değerinden küçükse iterasyonu sonlandırılır. ϵ değerine ulaşılmadıysa algoritma basamak 2. adıma geri dönerek devam eder.

5. Binary Parçacık Sürü Optimizasyon Algoritması (BPSO)

Parçacık sürü algoritması (PSA), 1995 yılında Kenendy ve Eberhart tarafından geliştirilmiştir ve sürülerin sosyal davranışlarını temel alan bir optimizasyon tekniğidir (Eberhart and Sixth 1997). PSO'nun temel olarak matematiksel ifadesi (24-25) denklemleri ile tanımlanmıştır.

$$V_{ij}(t+1) = \omega \cdot V_{ij}(t) + r_1 \cdot c_1 \cdot [P_{ij}(t) - x_{ij}(t)] + r_2 \cdot c_2 [G_j(t) - x_{ij}(t)] \quad (24)$$

$$X_{ij}(t+1) = X_{ij}(t) + V_{ij}(t+1) \quad (25)$$

Bu ifadelerde;

$r_1 \cdot c_1 \cdot [P_{ij}(t) - x_{ij}(t)]$: Bilişsel bileşen

$r_2 \cdot c_2 [G_j(t) - x_{ij}(t)]$: Sosyal bileşen

$\omega \cdot V_{ij}(t)$: Atalet ağırlık katsayısıdır.

Bu ifadelerde r_1 ve $r_2 \in R^+$ olmak üzere $0 \leq r_1 \leq 1$ ve $0 \leq r_2 \leq 1$ aralığında seçilir. C_1 ve C_2 katsayıları ise popülasyonun kendi içerisinde bilgi akışını sağlayan değerlerdir. Eğer $C_1=0$ seçilirse sürü adaylarının deneyimleri yok edilmiş olur ve sürü lokal optimum noktasına hapsedilmiş olur. $C_2=0$ seçildiği takdirde ise sosyal kavram yok edilmiş olur. Bu durumda sürüdeki bireyler arasında herhangi bir bilgi alış-verişi olmaz. Bunun sonucu olarak da uzay düzlemi içerisinde en iyi sonucun ne olduğu ve nerede olduğu sürü elemanları tarafından belirlenemez. Sürü elemanları sadece kendi bulundukları uzayın çevresinde lokal minimum noktasına ulaşmaktadır. C_1 ve C_2 ifadesinin seçilebilecek maksimum değeri (Clerc and Kennedy 2002)' da tanımlanmıştır. Denklem (26) ve (27)'deki matematiksel eşitliklerle tanımlanır.

$$k = \frac{2}{|2 - \phi - \sqrt{\phi^2 - 4\phi}|} \quad (26)$$

$$\phi = C_1 + C_2 \quad \text{ve} \quad \phi > 4 \quad (27)$$

$\phi > 4$ olması kararlılığın sağlanmasını garanti altına alır. Φ değerinin büyümesi "k" değerinin düşmesine, çeşitlenmenin azalmasına sebep olur. Buda sistemin vereceği cevabın yavaşlamasının yol açar. Anahtarlama işlemleri nedeniyle elektriksel sistemler ayrık sistem yapısına sahiptir. Bu nedenle uygulanacak optimizasyon yöntemi de ayrık olarak çalışmaya uygun olmalıdır [48,12]. Elektrik şebekelerinin optimizasyonunda standart PSO kullanılması; genellikle iterasyon sayısının artmasına ve yakınsama hızının yavaşlamasına neden olmaktadır. Standart PSO'nun ayrık olarak tanımlanması BPSO olarak ifade edilir ve BPSO'nun genel formülizasyonu denklem (28) ve denklem (29)' deki gibidir. Bu durum optimizasyon süresinin uzamasına neden olur.

$$x_{id}^{t+1} = \begin{cases} 1, & \text{Eğer } \text{rand}(\cdot) < \frac{1}{1 + e^{-v_{id}^{t+1}}} \\ 0, & \text{Diğer durumlarda} \end{cases} \quad (28)$$

$$V_{id}^{(t+1)} = \omega \cdot V_{id}^{(t)} + r_1 \cdot c_1 \cdot [P_{id}^{(t)} - x_{id}^{(t)}] + r_2 \cdot c_2 [G_d^{(t)} - x_{id}^{(t)}] \quad (29)$$

Bu değerler kullanılarak, BPSO içerisindeki değişkenler ve atalet değerine ait formülasyonlar tanımlanmış olur. BPSO kullanılarak dağıtım hatlarındaki aktif hat kayıplarının azaltılması için sunulan akış algoritmasına ait diyagram Şekil 2' deki gibidir. Ayrıca algoritmada sunulan


6. Sistem Yapılandırması ve PSO kullanılarak Optimal Kapasitör Yerleşimi

Dağıtım Şebekesinin yapılandırılmasında Şekil 3' de sunulan 33 baralı dağıtım sistemi referans alınmıştır. Sistem 1 adet fider, 5 adet T.S (kesikli çizgiler) ve 32 adet S.S. içermektedir. Yeniden yapılandırma işlemindeki amaç fonksiyonu olarak gerilim değerinin iyileştirilmesi ve hatlarda meydana gelecek aktif güç kayıp miktarının en aza indirilmesi amaçlanmıştır ve BPSO algoritması kullanılarak en uygun anahtarlama pozisyonuna göre optimal kapasitör lokasyonu ve kapasitör büyüklüğü bölüm 2'de sunulan kısıtlamalara göre belirlenmiştir. Analizler i5 işlemcili, 2.4 GHz işlem hızına ve 8 Gb RAM özelliğine sahip bilgisayar kullanılarak Matlab ortamında gerçekleştirilmiştir.


Bakım ve işletme maliyetleri ihmal edildiğinde, K_p yaklaşık olarak 3400 TL/(kw-yıl) ve K_c 'nin 90 TL/kVAR olduğu ve ekonomik ömrün 10 yıl olduğu varsayılmıştır. Gerilimin sınır aralığı 0,95 ile 1,05 p.u arasında alınır. Olası durumlar için kapasitör sayısının Olası konumların (maksimum sayısı)- $N_{mak,c}$ için 4 olduğu kabul edilmiştir. Analizde anahtarlama kondansatörlerin 150-1200 kVAR aralığında ve 150 kVAR kademe değişimi ile anahtarlama kapasitörler kullanıldığı varsayılmıştır. BPSO için kullanılan parametre değerleri ise Tablo 1'de sunulmuştur.

Tablo 1. BPSO için analizde kullanılan parametre değerleri.

Parameter	Value
Maksimum itersyon	100
Populasyon sayısı (n)	100
c_1	2.05
c_2	2.05
Maximum ağırlık değeri (ω_2)	0.80
Minimum ağırlık değeri (ω_1)	0.35




Şekil 2. 33 baralı sistemin yapılandırılmasında kullanılan BPSO Algoritma akış şeması



Şekil 3. 33 baralı Radyal Dağıtım Şebekesi

Analizde üç farklı durum dikkate alınmıştır. İlk olarak sistemin yapılandırmadan önceki ve yapılandırmadan sonraki durumları incelenmiştir. Başlangıçta 33-34-35-36 ve 37. Anahtarlar açık durumda iken; yapılandırma sonrasında en uygun anahtarlama pozisyonu 7-9-14-32 ve 37. anahtarlar olarak belirlenmiştir. Sistem için yapılandırma öncesi ve sonrasındaki bara gerilim değerleri grafiksel olarak Yapılandırmadan önce baralardaki en düşük gerilim seviyesi 18 numaralı barada 0.9131pu. olarak hesaplanmıştır. Yapılandırma sonrasında ise en düşük gerilim seviyesi 32. barada ve 0.9378 pu olarak elde edilmiştir. Gerilim değerinde % 2.71 iyileştirme sağlanmıştır. Yeniden yapılandırma öncesi 202.6771 kW' lık bir kayıp oluşurken, yeniden yapılandırma sonrası kayıp miktarı 139.5513 kW'a düşmüştür. Kayıplarda %31,14'lik bir iyileştirme elde edilmiştir.




Şekil 4. Yapılandırma öncesi ve BPSO algoritması kullanılarak yapılandırma sonrası bara gerilimleri


İkinci durumda ise yapılandırma yapılmadan kademeli kompanzasyon uygulanması durumunda BPSO algoritması ile optimal kapasitör lokasyonları ve kapasitör güçleri belirlenmiştir. Son olarak da yapılandırma sonrası optimal kapasitör lokasyonlarının ve güçlerinin belirlenmesi ve sabit kondansatör ve anahtarlama kondansatör kullanılması durumunda sistemde elde edilen iyileştirmeler değerlendirilmiştir.

Standart durum için yapılandırma öncesi ve BPSO algoritması kullanılarak yapılandırma sonrası elde edilen bara gerilimleri Şekil 4'de sunulmuştur. Yapılandırma sonrasında ise BPSO algoritması kullanılarak optimal sabit kapasitör ve anahtarlama kapasitör kullanılması durumunda elde edilen bara gerilimleri ise Şekil 5'de gösterilmiştir. Analiz sonucunda elde edilen sonuçlar ise özet olarak Tablo 2'de verilmiştir.

Tablo 2'den görüldüğü gibi, herhangi bir kapasitör kullanmaksızın sistem yapılandırması yapılarak uygun anahtarlama pozisyonlarının belirlenmesi sunulan sistem için kayıplar yönünden daha faydalı iken, gerilim profili açısından kapasitör uygulaması daha iyi bir iyileştirme sağlamaktadır. Yapılandırma sonrası optimal kapasitör seçimi ise hem kayıp hem de gerilim profili açısından sistemde daha faydalı iyileştirmeler sağlamaktadır. Kapasitör maliyeti açısından değerlendirildiğinde yapılandırmaz durumda optimal kapasitör seçiminde toplam kapasitör maliyeti yaklaşık 30.000 TL olurken, yapılandırma sonrasında optimal kapasitör yerleşimi ile bu değer yaklaşık 17.000 TL ye kadar azaltılabilmektedir.



Şekil 5. Yapılandırma öncesi ve BPSO algoritması kullanılarak standart konfigürasyon ve optimal kapasitör yerleşimi ile elde edilen bara gerilim profili.



Şekil 6. Yapılandırma sonrası BPSO algoritması kullanılarak optimal sabit kapasitör ve anahtarlama kapasitör kullanılması durumunda elde edilen bara gerilim profili.

Tablo 2. Farklı analiz sonucunda elde edilen anahtarlama pozisyonu, kayıp ve kapasitör yerleşimi değerleri.

Koşul	Anahtarlama Durumu	Toplam Aktif Kayıp (kW)	Maksimum Gerilim	Minimum Gerilim	Optimal Kapasitör Lokasyonu	Optimal Kapasitör Büyüklüğü (kVAR)
Standart Durum	33-34-35-36-37	208,04	2. Bara 0.99697 pu	19. bara 0.91218 pu	-----	-----
Optimal Kapasitör Yerleşimi ile Standart Durum	33-34-35-36-37	149.59	2. Bara 0.99798 pu	18. Bara 0.95025 pu	32 8 14 2	900 750 450 1200
BPSO ile sistem yapılandırması	33-34-35-36-37	139,55	2. Bara 0.99698 pu	32. bara 0.9378	-----	-----
BPSO ile Sistem Yapılandırması ile sabit kondansatör kullanılarak optimal kapasitör yerleşimi ile	7, 9, 14, 32, 37	107,32	2. Bara 0.99753 pu	32. Bara 0.93748 pu	30 31	425.91 171.09
BPSO Sistem Yapılandırması ile Anahtarlama kapasitör kullanarak Optimal Kapasitör Yerleşimi ile	7, 9, 14, 32, 37	65,1104	2. Bara 0.99814pu	32. Bara 0.96136 pu	24 30 5 21	450 900 300 300

6. Sonuçlar

Elektriksel sistemlerde dağıtım hatlarının planlanmasında, sistem kayıpları ve gerilim düşümü değerleri önemli bir kriter olmaktadır. Dağıtım şebekeleri genel olarak radyal yapıda çalışacak şekilde tasarlanır. Bu çalışma BPSO algoritması kullanılarak 33 baralı elektrik dağıtım sisteminin yapılandırılması incelenmiştir. Ayrıca sunulan optimizasyon algoritması aracılığı ile 33 baralı sistemde optimal kapasitör lokasyonun ve kapasitör büyüklüğünün belirlenmesi gerçekleştirilmiştir. Sonuçlar kayıplar, gerilim profili iyileştirmeleri ve maliyet yönünden değerlendirilerek karşılaştırılmıştır. Elde edilen sonuçlar, dağıtım şebekeleri için optimizasyon algoritmaları kullanarak uygun anahtarlama pozisyonlarının seçilmesi ile şebekenin daha kararlı, ekonomik, güvenilir ve kesintisiz bir şekilde enerji iletmesini sağlayacağını göstermektedir. Optimal kapasitör noktası belirlenerek sistemde yapılandırma yapıldığında ise şebeke daha kararlı bir hale gelmektedir. Ayrıca, dağıtım sistemlerinde

yapılacak yatırımların belirlenmesinde sistemin yapılandırılması ve optimal kapasitör noktaları belirlendikten sonra yatırımların değerlendirilmesi gerektiğini göstermektedir. Standart şebeke konfigürasyonunda sistem kaybı 208 kW olmaktadır. Bu kayıp miktarı radyal sistemin optimal yapılandırması ile 139,55 kW'a kadar azaltılabilmektedir. Sistem yapılandırma ve optimal kapasitör yerleşimi ile kayıpların 65 kW'a kadar azaltılabileceği ve aynı zamanda gerilim profillerinde ciddi iyileştirilmeler elde edilebileceği görülmektedir.

Gelecekteki çalışmalarda, uygulanan optimizasyon yönteminin farklı optimizasyon algoritmaları ile değerlendirilmesi amaçlanmaktadır. Ayrıca, sunulan yaklaşımın gerçek dağıtım firmasının elektriksel sistemine uygulanarak sonuçların değerlendirilmesi hedeflenmektedir.

8. Referanslar

- A.H. Etemadi, M. Fotuhi-Firuzabad. 2008. "Distribution System Reliability Enhancement Using Optimal Capacitor Placement." *IET Gener. Transm. Distrib* 2 (5): 621–31.
- Abou El-Ela, Adel Ali, Ragab A. El-Sehiemy, Abdel Mohsen Kinawy, and Mohamed Taha Mouwafi. 2016. "Optimal Capacitor Placement in Distribution Systems for Power Loss Reduction and Voltage Profile Improvement." *IET Generation, Transmission and Distribution* 10 (5): 1209–21. <https://doi.org/10.1049/iet-gtd.2015.0799>.
- Baran, Mesut E., and Felix F. Wu. 1989. "Network Reconfiguration in Distribution Systems for Loss Reduction and Load Balancing." *IEEE Power Engineering Review* 9 (4): 101–2. <https://doi.org/10.1109/MPER.1989.4310642>.
- Cikan, Murat, and Bedri Kekezoglu. 2022. "Comparison of Metaheuristic Optimization Techniques Including Equilibrium Optimizer Algorithm in Power Distribution Network Reconfiguration." *Alexandria Engineering Journal* 61 (2): 991–1031. <https://doi.org/10.1016/j.aej.2021.06.079>.
- Clerc, M., and J. Kennedy. 2002. "The Particle Swarm - Explosion, Stability, and Convergence in a Multidimensional Complex Space." *IEEE Transactions on Evolutionary Computation* 6 (1): 58–73. <https://doi.org/10.1109/4235.985692>.
- Eberhart, R., and J. Kennedy. 1997. "A New Optimizer Using Particle Swarm Theory." In: *Proceedings of the IEEE Symposium on Micro Machine and Human Science, Nagoya, Japan*, 39–43. https://ieeexplore.ieee.org/abstract/document/494215?casa_token=VRHbIOq0xY0AAAAA:tigoKrFPGIOWOZPL3HUCxeJDwpHdMr7AdrNcyfXSzfY9zdeQ3AAVzx9vd-b63ZQ8Q1ZwFq8E5okfcE.
- K. Prakash; M. Sydulu. 2007. "Particle Swarm Optimization Based Capacitor Placement on Radial Distribution Systems." *IEEE Power Engineering Society General Meeting*, 1–5. <https://doi.org/doi: 10.1109/PES.2007.386149>.
- Mekhamer, S. F., A. Y. Abdelaziz, F. M. Mohammed, and M. A.L. Badr. 2008. "A New Intelligent Optimization Technique for Distribution Systems Reconfiguration." *2008 12th International Middle East Power System Conference, MEPCON 2008*, 397–401. <https://doi.org/10.1109/MEPCON.2008.4562296>.
- Merlin A., Back, H. 1975. "Search for a Minimal - Loss Operating Spanning Tree Configuration in Urban Power Distribution Systems." In *Proc. of 5 Th Power Systems Comp. Con.*
- Mohamed Imran, A., and M. Kowsalya. 2014. "A New Power System Reconfiguration Scheme for Power Loss Minimization and Voltage Profile Enhancement Using Fireworks Algorithm." *International Journal of Electrical Power and Energy Systems* 62: 312–22. <https://doi.org/10.1016/j.ijepes.2014.04.034>.
- Mohammadi-Ivatloo B., Asadi S. Teimourzadeh H. 2020. "Binary Group Search Optimization for Distribution Network Reconfiguration." In *Studies in Systems, Decision and Control*, edited by Mohammadi-Ivatloo B. Pesaran Hajiabbas M., 262:103–26. Springer, Cham. https://doi.org/10.1007/978-3-030-34050-6_5.
- Niknam, Taher, and Mokhtar Sha Sadeghi. 2011. "An Efficient Evolutionary Optimization Algorithm

- for Multiobjective Distribution Feeder Reconfiguration.” *International Journal of Control, Automation and Systems* 9 (1): 112–17. <https://doi.org/10.1007/s12555-011-0114-6>.
- Nojavan, Sayyad, Mehdi Jalali, and Kazem Zare. 2014. “Optimal Allocation of Capacitors in Radial/Mesh Distribution Systems Using Mixed Integer Nonlinear Programming Approach.” *Electric Power Systems Research* 107 (February): 119–24. <https://doi.org/10.1016/J.EPSR.2013.09.019>.
- Oliveira, Leonardo W. De, Edimar J. De Oliveira, Flávio V. Gomes, Ivo C. Silva, André L.M. Marcato, and Paulo V.C. Resende. 2014. “Artificial Immune Systems Applied to the Reconfiguration of Electrical Power Distribution Networks for Energy Loss Minimization.” *International Journal of Electrical Power and Energy Systems* 56: 64–74. <https://doi.org/10.1016/j.ijepes.2013.11.008>.
- Ramalinga Raju, M., K. V.S. Ramachandra Murthy, and K. Ravindra. 2012. “Direct Search Algorithm for Capacitive Compensation in Radial Distribution Systems.” *International Journal of Electrical Power & Energy Systems* 42 (1): 24–30. <https://doi.org/10.1016/J.IJEPES.2012.03.006>.
- Reddy, M. Sydulu V. 2014. “Index and GA Based Optimal Location and Sizing of Distribution System Capacitors.” In *2007 IEEE Power Engineering Society General Meeting*.
- Saffar, A., R. Hooshmand, and A. Khodabakhshian. 2011. “A New Fuzzy Optimal Reconfiguration of Distribution Systems for Loss Reduction and Load Balancing Using Ant Colony Search-Based Algorithm.” *Applied Soft Computing Journal* 11 (5): 4021–28. <https://doi.org/10.1016/j.asoc.2011.03.003>.
- Srinivasa Rao, Rayapudi, Sadhu Venkata Lakshmi Narasimham, Manyala Ramalinga Raju, and A. Srinivasa Rao. 2011. “Optimal Network Reconfiguration of Large-Scale Distribution System Using Harmony Search Algorithm.” *IEEE Transactions on Power Systems* 26 (3): 1080–88. <https://doi.org/10.1109/TPWRS.2010.2076839>.
- Tabatabaei, S. M., and B. Vahidi. 2011. “Bacterial Foraging Solution Based Fuzzy Logic Decision for Optimal Capacitor Allocation in Radial Distribution System.” *Electric Power Systems Research* 81 (4): 1045–50. <https://doi.org/10.1016/J.EPSR.2010.12.002>.
- Teimourzadeh, Saeed, and Kazem Zare. 2014. “Application of Binary Group Search Optimization to Distribution Network Reconfiguration.” *International Journal of Electrical Power and Energy Systems* 62: 461–68. <https://doi.org/10.1016/j.ijepes.2014.04.064>.
- Wang, Chun, and Hao Zhong Cheng. 2008. “Optimization of Network Configuration in Large Distribution Systems Using Plant Growth Simulation Algorithm.” *IEEE Transactions on Power Systems* 23 (1): 119–26. <https://doi.org/10.1109/TPWRS.2007.913293>.
- Yan Xu; Zhao Yang Dong; Kit Po Wong; Evan Liu; Benjamin Yue. 2013. “Optimal Capacitor Placement to Distribution Transformers for Power Loss Reduction in Radial Distribution Systems.” *IEEE Transactions on Power Systems* 28 (4): 4072–79.

Yazılım Güvenlik Açıklarının Derin Öğrenme Kullanılarak Sınıflandırılması

Classification of Software Vulnerabilities Using Deep Learning

Edanur Özdemir^{*1} , İbrahim Türkoğlu² 

¹Yazılım Mühendisliği Anabilim Dalı, Fırat Üniversitesi, Elazığ, Türkiye

²Yazılım Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

(edanurozdemir23@gmail.com, iturkoglu@firat.edu.tr)

Özetçe— Her geçen gün artan güvenlik açıklarının detaylı bir şekilde raporlanması siber güvenlikte önemli bir süreçtir. Güvenlik açığı hakkındaki bilgiler güvenli yazılım geliştirilmesinde, güvenlik açığının yönetiminde kolaylık sağlayabilir. Yazılım güvenlik açıklarını önleyebilmek ve sayısını azaltmak için güvenlik açığı özelliklerinin bilinmesi gereklidir. Bu çalışmada derin öğrenme kullanarak güvenlik açığı açıklamalarını türlerine göre otomatik sınıflandıran bir yöntem önerilmiştir. Önerilen yöntemi eğitmek ve test etmek için ABD Ulusal Güvenlik Açığı Veri tabanı (NVD) kullanılmıştır. Çalışmada kullanılan LSTM modelinin yazılım güvenlik açıklarının otomatik sınıflandırılmasında etkili olduğu gözlemlenmiştir.

Anahtar Kelimeler : yazılım güvenliği, güvenlik açığı sınıflandırması, yazılım güvenlik açıkları, derin öğrenme.

Abstract— Detailed reporting of security vulnerabilities, which are increasing day by day, is an important process in cyber security. Information about the vulnerability can facilitate the development of secure software and the management of the vulnerability. In order to prevent and reduce the number of software vulnerabilities, it is necessary to know the vulnerability features. In this study, a method that automatically classifies vulnerability descriptions according to their types using deep learning is proposed. The US National Vulnerability Database (NVD) was used to train and test the proposed method. It has been observed that the LSTM model used in the study is effective in the automatic classification of software security vulnerabilities.

Keywords : software security, vulnerability classification, software vulnerabilities, deep learning.

1.Giriş

Teknolojik gelişmelerin artmasıyla, yazılım sistemlerinin miktarı artmaktadır. Çoğu yazılım, birden fazla teknolojinin bir araya gelmesiyle geliştirilmektedir. Artan bu çeşitlilik sonucunda yazılım güvenliğini yönetmek zor hale gelmektedir. Bir siber güvenlik saldırısına sebep olacak yazılımdaki zayıflık veya kusura yazılım güvenlik açığı denir (Le, Sabir & Babar, 2019). Şekil 1’de gösterildiği gibi güvenlik açığının üç durumun kesişimi olduğunu belirtmişlerdir (Garg, Singh & Mohapatra, 2019). Ulusal Güvenlik Açığı Veritabanına (NVD) göre 2021 yılında art arda 5’nci yılda rekor sayıya ulaşarak 20.156 ve 2022 yılının ağustos ayına kadar olan sürede 15.335 güvenlik açığı kaydedildi. Bir yazılımda bulunan güvenlik açıkları istismar edilirse yazılım şirketleri, devlet sistemleri, eğitim kurumları ve müşteriler için büyük ölçüde zarara sebep olacaktır. Bu sebeple güvenlik açıklarının tespiti, yazılım güvenliği ve yazılım kalitesi açısından çok önemlidir (Şahin, Dinler & Abualigah, 2021).



Şekil 7. Güvenlik açığı modeli

Yazılımda bulunan güvenlik açıklarından tamamıyla kaçınmak olası bir durum değildir. Yazılımda oluşabilecek veya var olan potansiyel zayıflıkları önleyebilmek için mümkün olduğunca yazılım geliştirme yaşam döngüsünün erken aşamalarında tespit edilip yönetilmesi çok önemlidir. Güvenlik açıklarının uygulama aşamasından önce tespiti edilip düzeltilmesi sayesinde, test maliyetleri en aza indirilebilir buna bağlı olarak yazılım üretim firmaları pazardaki itibarını koruyabilir (Şahin, Dinler & Abualigah, 2021).

Güvenlik açıklarını erken aşamada tespit etme yaklaşımlarından biri, daha önceden bilinen güvenlik açıklarını bilmek ve düzeltmek için var olan çözümleri kullanmaktır (Rahman & Mustafa, 2012). CERT/CC'ye (Bilgisayar Acil Müdahale Ekibi) göre, yazılım geliştirmedeki çok sayıda güvenlik açığı, diğer sistemlerde tespit edilen güvenlik açıklarının tekrarıdır (Davari, Zulkernine, & Jaafar, 2017). Güvenlik açıklarının iyi bir şekilde analiz edilmesi, var olan veya oluşabilecek güvenlik açıklarını önlemede yardımcı olabilir. Güvenlik açığı türüne göre farklı çözümler, önlemler bulunmaktadır. Bu nedenle güvenlik açığı türlerini belirlemek, güvenlik açıklarının yönetimi için çok önemlidir (Aota ve ark, 2020).

Bu çalışmada, çok sınıflı bir metin sınıflandırma problemi olarak yazılım güvenlik açıkları, türlerine göre sınıflandırılmıştır. Çalışmada Ulusal Güvenlik Açığı Veritabanı (NVD)'ndan alınan güvenlik açığı bilgileri kullanılmıştır. 8 güvenlik açığı türüne ait açıklama verileri kullanılarak ilk aşamada metin işleme yöntemleri ile veriler ön işlem, vektörleştirme gibi aşamalara tabi tutulmuştur. Daha sonra derin öğrenme yöntemlerinden olan Uzun Kısa Süreli Bellek (LSTM) kullanılarak yazılım güvenlik açıklarının türlerine göre kategorisi tanımlanmıştır.

Çalışmanın geri kalanı şu şekilde organize edilmiştir; İkinci aşamada bu alanda gerçekleştirilen çalışmalar incelenmiştir. Üçüncü bölümde NVD veri seti ve derin öğrenme modeli hakkında bilgi verilmiştir. Dördüncü bölümde çalışmanın sonuçları hakkında bilgi verilmiştir. Çalışmanın son bölümünde ise sonuçlar irdelenerek gelecek çalışmalar hakkında bilgi verilmiştir.

2. İlgili Çalışmalar

Bu bölümde literatürde bulunan yazılım güvenlik açıklarının yapay zekâ yöntemleri ile otomatik olarak yönetilmesi için gerçekleştirilen çalışmalar hakkında bilgi verilmiştir.

Rahman ve Mustafa (2012), yazılım yaşam döngüsü aşamalarından olan tasarım aşamasına ait NVD veritabanından elde ettikleri 427 güvenlik açıklarını türlerine göre sınıflandırmışlardır. Destek Vektör Makinesi algoritmasını kullandıkları modelde sonuç olarak 6 güvenlik açığı türü için tatmin edici sonuca varılmıştır. Gawron, Cheng & Meinel (2018) yaptıkları çalışmada, güvenlik açıklarının sınıflandırılması için güvenlik açığı açıklamaları kullanmışlardır. Doğruluğu değerlendirmek için Naif Bayes algoritması ve Sinir ağı kullanılmışlardır. Sonuç olarak yazılım güvenlik açıklarının otomatik olarak sınıflandırılmasının mümkün olduğunu ve veri setine bağlı olarak doğruluğun %70 ile %90 arasında sonuç verdiğini gözlemlemişlerdir. Ren ve ark. (2019) yaptıkları çalışmada, C/C++ ve Java

programlarındaki yazılım kaynak kodundaki bir yazılım arabelleği taşıması güvenlik açığı tahmin yöntemi önerdi. Deneysel sonuçlar, yöntemin Bayes, Adaboost ve Rastgele Orman algoritmalarından daha kısa sürede çalıştığını gösterdi. Huang ve ark. (2019) tarafından yapılan çalışmada NVD veri tabanı kullanılarak güvenlik açığı açıklamalarının güvenlik açığı türlerine göre sınıflandırılması gerçekleştirilmiştir. Veriler üzerinde uygulanan TFI-DNN; TFI-KNN, TFI-SVM, TFI-NB modelleri ile karşılaştırıldığında daha iyi sonuç verdiği gözlemlenmiştir. Rahimi ve Zargham (2013) kod özelliklerine dayalı güvenlik açığı tespiti için bir model önerdiler. Sonuç olarak güvenlik açığı taramasının zaman içinde daha az sapmayla tahmin edebileceğine ulaşılar. Chernis ve Verma (2018), yazılım güvenlik açığı tespiti için C kaynak kodundaki fonksiyonlardan metin özelliklerini çıkardı ve makine öğrenimi sınıflandırıcısı ile analiz ederek hata yüzdesinin tespit edilmesinin mümkün olduğu sonucuna ulaşılar. Kaya ve ark. (2019) tarafından yapılan çalışmada, yazılım güvenlik açıklarını sınıflandırmak için veri dengeleme teknikleri ile Rastgele Orman, Destek Vektör Makinesi, SD, RUSBoosted trees, AdaBoost, LDA, W-kNN sınıflandırma algoritmaları kullanılmıştır. PHPMyAdmin, Drupal ve Moodle projeleriyle ilgili üç genel veri kümesi üzerinde uygulanmıştır. Sonuç olarak Rastgele Orman algoritmasının küçük veri kümeleri için, RusboostTree algoritmasının büyük veri kümeleri için daha iyi performans sağladığına vamişlardır. (Le, Sabir & Babar, 2019) tarafından yapılan çalışmada yazılım güvenlik açıklarının tanımları kullanılarak otomatik değerlendirilmesini gerçekleştirmek için, hem karakter hem de kelime özelliklerini birleştiren bir yaklaşım önerdiler. Sonuç olarak NVD veritabanında 100.000'den fazla güvenlik açığı verisi üzerinde yazılım güvenlik açıklarının tanımlarının kavram kayması sorununu etkili bir şekilde çözebileceğini göstermektedir.

3. Materyal ve Yöntem

3.1. Veri Seti

Bu çalışmada oluşturulan modeli doğrulamak için kullanılan veri seti, Ulusal Güvenlik Açığı Veri Tabanı'ndan (NVD) elde edilmiştir. NVD, ABD hükümetinin güvenlik açığı yönetimi verilerinin deposudur. NVD, güvenlikle ilgili yazılım kusurları, güvenlik listesi referansları, yanlış yapılandırmalar, etki ölçümleri ve ürün adlarının veritabanlarını içerir.

Çalışmada kullanılan veri setinde toplam 75.870 güvenlik açığı kayıtları bulunmaktadır. Veri seti oluşturulurken OWASP 2021 en yaygın güvenlik açıkları listesinde olan 8 güvenlik açığı türü kullanılmıştır. Tablo 1'de görüldüğü gibi veri setinde her güvenlik açığı türüne ait güvenlik açığı kimlik numarası, önem derecesi, güvenlik açığı açıklamaları, güvenlik açığı tipi, yayınlandığı tarih, erişim gibi bilgiler bulunmaktadır. Çalışmada gerçekleştirilen model için güvenlik açığı açıklama ve güvenlik açığı türü verileri kullanılmıştır.

Tablo 2. Çalışmada kullanılan veri seti örnekleri

CVE ID	CWE ID	Vulnerability Type(s)	Publish Date	Score	Acces	Description
CVE-2021-45906	79	XSS	2021-12-28	4.3	Remote	SLICAN WebCTI 1.01 2015 is affected by a Cross Site Scripting (XSS) vulnerability. The attacker can steal the user's session by injecting malicious JavaScript codes which leads to Session Hijacking and cause user's credentials theft.
CVE-2021-29757	352	CSRF	2021-08-02	6.8	Remote	IBM QRadar User Behavior Analytics 4.1.1 is vulnerable to cross-site request forgery which could allow an attacker to execute malicious and unauthorized actions transmitted from a user that the website trusts. IBM X-Force ID: 202168.

3.2. Yöntem

Bu çalışmada yazılım güvenlik açıklarını sınıflandırmak için derin öğrenme yöntemlerinden olan Uzun Süreli Kısa Bellek (LSTM) kullanılarak model oluşturulmuştur. Veri setinde uygulanan modelin

akış şeması Şekil 2’de gösterilmektedir. Modelde ilk olarak NVD veritabanından alınan veri seti, metin ön işleme aşamalarından geçirilmiştir. Model, Google Colab ortamında Python 3.8 ile Tensorflow, Keras kütüphaneleri kullanılarak programlanmıştır.

3.2.1. Ön işlem


Ön işlem aşamasında ilk olarak modelin doğruluğuna etki edecek güvenlik açığı açıklamasında bulunan güvenlik açığı türüne ait anahtar kelimeler temizlenmiştir. Daha sonra veri setinde bulunan noktalama işaretleri, boşluk, sembol gibi ifadeler temizlenerek bütün harfler küçük harfe dönüştürülmüştür. Kelimeler köklerine ayrılarak, metnin sınıflandırılmasında katkı sağlamayacak kelimeler kaldırılmıştır.

3.2.2. Özellik Çıkarma

Bu aşamada her bir kelimenin ağırlığı Keras kütüphanesine ait Tokenizer sınıfı tarafından hesaplanır. `fit_on_texts()` metodu ile kelimelerin yoğunluğuna göre bir dizin oluşturulur. Her kelimenin benzersiz bir değeri olacak şekilde veri kümesi oluşturulmuştur. Daha sonra `texts_to_sequences()` metodu ile her benzersiz kelime belirteci karşılık gelen tamsayı değeri oluşturulup dizi haline getirilmiştir. `pad_sequences()` metodu ile tüm dizilerin aynı uzunlukta olması sağlanmıştır.

3.2.3. Kelime vektör uzayı


Her kelimeyi sabit uzunlukta gerçek değerli vektöre dönüştürmek için gömme katmanı (Embedding Layer) kullanılmıştır. Böylece kelimelerin boyutu küçültülmüştür.



Şekil 8. Yazılım güvenlik açıklarını sınıflandırma sürecinin akış şeması

3.2.4. Uzun Kısa Süreli Bellek (LSTM) ile Sınıflandırma

Derin öğrenme yöntemlerinden biri olan LSTM, geri besleme bağlantılarına sahip bir yapay sinir ağıdır. LSTM yapay sinir ağı mimarisi, tekrarlayan sinir ağının (RNN) bir türüdür. LSTM, RNN’in aksine bilgileri uzun süreli bellekte tutmak amacıyla tasarlanmıştır. LSTM ağları bu özellikleri sayesinde bağlamsal bilgileri daha iyi ifade edebildikleri için doğal dil işlemede yaygın olarak kullanılmaktadır (Wu ve ark. 2017). Şekil 3’te gösterilen LSTM ağı mimarisi, giriş kapısı, unutma kapısı ve çıkış kapısından oluşur.



Şekil 9. Uzun Kısa Süreli Bellek (LSTM) mimarisi


Çalışmada geliştirdiğimiz modelde, vektörleştirme işleminden sonra veri seti makine tarafından tanınabilen hale gelmiştir. LSTM modelini oluşturmak için derin öğrenme kütüphanesi olan TensorFlow kütüphanesi kullanılmıştır. Modelde ilk olarak SpatialDropout1D katmanı kullanılmıştır. SpatialDropout1D sınıfı, Dropout (seyreltme) ile aynı işlemi gerçekleştirir fakat Dropout sınıfında her eleman bağımsız olarak tutulur veya bırakılır. SpatialDropout1D sınıfında ise tek tek elemanlar yerine tüm 1B özellik haritaları düşürülür (Keras, 2022). Daha sonra veriler 2 tane LSTM katmanından geçirilmiştir. Problemimiz çoklu sınıflandırma işlemi olduğu için çıkış katmanında 8 düğüm ve aktivasyon fonksiyonu olarak softmax kullanılmıştır.

Tablo 3. Modelin parametreleri


Hiper parametreler ve standart parametreler	Değer
Eğitim Verisi (Train Data)	%80
Test Verisi (Test Data)	%20
Giriş (Input)	64.047
Batch Boyutu (Batch Size)	500
Eğitim Sayısı (Epoch)	200
Seyreltme Değeri (SpatialDropout1D)	0.4
Katman (Layer)	2
Çıkış (Output)	1

4. Bulgular ve Tartışma

Bu bölümde LSTM derin öğrenme modelinin uygulama sonuçları incelenmiştir. Modelin performansını değerlendirmek için Şekil 4'te görüldüğü gibi çok sınıflı karışıklık matrisi kullanılmıştır. Modelin doğruluk değerine ait grafiği ise Şekil 5'te gösterilmiştir.



Şekil 10. LSTM modelinin karışıklık matrisi



Şekil 11. LSTM modelinin doğruluk (accuracy) grafiği

Verilerin %80'i eğitim seti ve %20'si test amaçlı kullanılmıştır. Şekil 5'de görüldüğü gibi doğruluk eğrileri belirli eğitim sayısına kadar sabit devam ettikten sonra artmaya başlamıştır. Daha sonra tekrar değişmeden devam etmektedir. LSTM modelimizin doğruluk değeri puanı %87 olarak hesaplanmıştır.

Çalışmada kullanılan veri seti, türlerine göre dengesiz olarak dağılmıştır. Şekil 4'teki karışıklık matrisini incelediğimizde bazı güvenlik açığı türleri yanlış sınıflandırılmıştır. Bu durumun sebebi, veri setindeki sınıfların dengesiz dağılımında veya bir güvenlik açığı verisinin birden fazla güvenlik açığı türüne ait olmasından kaynaklanabilir. Literatürdeki çalışmalarda kullanılan veri seti standart olmadığı için modelimizi diğer çalışmalar ile karşılaştıramadık.

Modelin performansını daha fazla arttırmak için güvenlik açığı verileri, veri madenciliği yöntemlerinde kullanılan dengeleme yöntemleri ile dengeli bir hale getirilebilir. Ayrıca farklı parametrelerde, kelime gömme teknikleri veya derin öğrenme tekniği kullanılarak performans başarımları artırılabilir.

5. Sonuç

Yazılım güvenlik açıklarının sınıflandırılması, yazılım güvenliği araştırmaları için önemli bir role sahiptir. Bu çalışmada yazılım güvenlik açıklarının türlerine göre sınıflandırılması için derin öğrenme tabanlı yaklaşım önerilmiştir. ABD Ulusal Güvenlik Açığı Veri tabanı'ndan (NVD) elde edilen 75.870 veri setinden yazılım güvenlik açığı açıklama verileri ve türleri önerilen modelin giriş verileri olarak kullanılmıştır. Veri seti, metin ön işleme aşamalarından geçirilerek sınıflandırma aşaması için Uzun Kısa Süreli Bellek (LSTM) derin öğrenme yöntemine sunulmuştur. Önerilen LSTM modelinin performansı, yazılım güvenlik açığı sınıflandırmasında %87 doğruluk puanı olarak sonuç vermiştir.

Gelecekteki çalışmalarda, veri sayısının artırılması, farklı metin işleme yöntemleri ve derin öğrenme yöntemlerinin kullanılması hedeflenmektedir.

Teşekkür

Bu çalışma TEKF.21.14 nolu Proje ile Fırat Üniversitesi Bilimsel Araştırmalar Projesi Birimi tarafından desteklenmiştir.

Kaynaklar

Le, T. H. M., Sabir, B., & Babar, M. A. (2019) Automated Software Vulnerability Assessment with Concept Drift. 2019 IEEE/ACM 16th International Conference on Mining Software Repositories (MSR), pp.371-382.

Garg, S., Singh, R. K., & Mohapatra, A. K. (2019) Analysis of software vulnerability classification based on different technical parameters. *Information Security Journal: A Global Perspective* 28(1-2): 1–19.

National Vulnerability Database (NVD) (2022). <https://nvd.nist.gov/> Accessed 01 Augst 2022

Şahin, C. B., Dinler, Ö. B., & Abualigah, L. (2021) Prediction of software vulnerability based deep symbiotic genetic algorithms: Phenotyping of dominant-features. *Applied Intelligence* 51:8271–8287.

Rehman S., Mustafa K. (2012) Software Design Level Vulnerability Classification Model. *International Journal of Computer Science and Security (IJCSS)* 6(4):238-255.

Davari, M., Zulkernine, M., & Jaafar, F. (2017) An Automatic Software Vulnerability Classification Framework. 2017 International Conference on Software Security and Assurance (ICSSA), Altoona, PA, USA, pp.44-49.

Aota, M., Kanehara, H., Kubo, M., Murata, N., Sun, B., & Takahashi, T. (2020) Automation of Vulnerability Classification from its Description using Machine Learning. 2020 IEEE Symposium on Computers and Communications (ISCC), Tokyo, Japan.

Gawron, M., Cheng, F., & Meinel, C. (2018). Automatic Vulnerability Classification Using Machine Learning. *Risks and Security of Internet and Systems*, 3–17.

Ren, J., Zheng, Z., Liu, Q., Wei, Z., & Yan, H. (2019) A Buffer Overflow Prediction Approach Based on Software Metrics and Machine Learning. *Security and Communication Networks*, 1–13.

Huang G, Li Y, Wang Q, Ren J, Cheng Y, Zhao XA. (2019) Automatic Classification Method For Software Vulnerability Based On Deep Neural Network, *IEEE Access* 2019; 1(1): 1-9.

Rahimi, S., & Zargham, M. (2013). Vulnerability Scrying Method for Software Vulnerability Discovery Prediction Without a Vulnerability Database. *IEEE Transactions on Reliability*, 62(2):395–407.

Chernis, B., & Verma, R. (2018). Machine Learning Methods for Software Vulnerability Detection. Proceedings of the Fourth ACM International Workshop on Security and Privacy Analytics - IWSPA

Kaya A, Keceli AS, Catal C, Tekinerdogan B. (2019) The impact of feature types, classifiers, and data balancing techniques on software vulnerability prediction models. *Journal of Software: Evolution and Process*, 31(1): 1-25.

Wu F, Wang J, Liu J, Wang W. (2017) Vulnerability Detection with Deep Learning. 3rd IEEE International Conference on Computer and Communications, Nanjing, China, pp.1298-1302.

Keras (2022). https://keras.io/api/layers/regularization_layers/spatial_dropout1d/. Accessed 05 Augst 2022

LSTM tabanlı ağlarda ilave hiper parametre ile konuşmacı tanıma

Speaker recognition with extra hyper parameter in LSTM based networks

Erkan GÜNERHAN^{*1,2} , Cemal KÖSE³ 

¹Bilgisayar Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye

²Bilgisayar Mühendisliği Bölümü, Kafkas Üniversitesi, Kars, Türkiye

³Bilgisayar Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye

(erkan.gunerhan@gmail.com, ckose@ktu.edu.tr)

Özetçe— Konuşmacı tanıma için yayınlanan algoritmaların çoğu metne bağlı konuşmacı tanıma üzerine çalışılmıştır. Öte yandan, konuşmacı serbestçe konuşabildiği için metinden bağımsız konuşmacı tanıma daha avantajlıdır. Bu makalede, gürültü ve yankılanma gibi bazı bozulma etkilerinin altında metinden bağımsız konuşmacı tanıma konusunu ele alınmıştır. Özellik çıkarımı için Mel-Frekans Cepstral Katsayıları (MFCC'ler) kullanılmıştır. Bu özellikler, konuşmacı tanımak için bir sınıflandırma aracı olarak Uzun-Kısa Süreli Bellek (LSTM) tarafından eğitilir. Ağ, ses kayıt koşulları aynı olduğunda konuşmacıları metinden bağımsız bir şekilde başarılı bir şekilde tanımayı öğrenir. Özellik çıkarımı için MFCC'ler kullanıldığında ve LSTM ile eğitildiğinde %95.2 kadar doğruluk seviyesine ulaşılmıştır. Bu seviyeyi daha yukarı çıkarmak için LSTM'e ek olarak yeni hiper parametreler eklendiğinde tanıma oranı %99'a ulaşmaktadır. Önerilen yaklaşım, CNN ve YSA algoritmalarına kıyasla üstünlük göstermektedir. **Anahtar Kelimeler** : LSTM, MFCC, CNN , hiper parametre, konuşmacı tanıma

Abstract— Most of the published algorithms for speaker recognition are based on text-dependent speaker recognition. On the other hand, text-independent speaker recognition is more advantageous since the speaker can speak freely. In this paper, we address the issue of text-independent speaker recognition under some distortion effects such as noise and reverberation. Mel-Frequency Cepstral Coefficients (MFCCs) are used for feature extraction. These features are trained by Long-Short Term Memory (LSTM) as a classification tool for speaker recognition. The network learns to successfully recognize speakers in a text-independent manner when the audio recording conditions are the same. Accuracies as high as 95.2% were achieved when using MFCCs for feature extraction and trained with LSTM. When new hyperparameters are added to the LSTM to increase this level, the recognition rate reaches 99%. The proposed approach is superior to CNN and ANN algorithms.

Translated with www.DeepL.com/Translator (free version)

Keywords : LSTM, MFCC, CNN , hyper parameter, speaker recognition

1. Giriş

Biyometrik tanıma sistemleri, farklı ölçümlere veya konuşma sinyalleri gibi sinyallere bağlıdır. Konuşma sinyali önemli bir biyometriktir, çünkü ses doğal olarak üretilen bir sinyaldir. Ayrıca telefon uygulamalarında erişim sırasında kullanılacak özel sinyal dönüştürücülere veya ağlara gerek yoktur. Konuşmacı tanıma sistemleri, konuşma içeriğine göre iki türe ayrılabilir: metne bağlı ve metinden bağımsız sistemler. Metne bağlı sistemlerde, konuşmacı hem eğitim hem de test sırasında belirli bir ifade söylemelidir; metinden bağımsız sistemlerde ise sistem, konuşmacıyı ifade içeriğinden bağımsız olarak konuşulan herhangi bir ifadeden tanımlar. Özellik çıkarma, konuşmacı tanıma sistemlerinin en önemli adımıdır. MFCC'ler, burada konuşmacı tanımlamak için kullanılır. Sınıflandırma aşaması olarak da adlandırılan test aşamasında, eğitimde oluşturulana benzer bir model yapılır ve saklanan tüm modellerle eşleştirilir. Bu makalede, spesifik bir RNN mimarisi olan LSTM kullanılmıştır. Akustik modellemede, LSTM-RNN(Dominguez et al., 2014), Derin Sinir Ağı'ndan (DNN) daha etkilidir. İleri beslemeli sistemlerin aksine, RNN'ler döngüseldir. Zaman adımlarında girdileri olduğu için geriye dönüş hafızası olmuş olur. Bu onları ardışık verileri öğrenmede başarılı kılar. Böylece zaman içinde bir tür çapraz bellek elde etmiş olur. Dolayısıyla, tekrarlayan ağların, yeni bilgilere nasıl tepki verebileceklerine karar vermek için iki girdi kaynağı

vardır: şimdiki zaman ve bir önceki geçmiş. Yankılanma ve gürültü gibi bazı çevresel koşullar nedeniyle konuşma sinyali bozulabilir. Sonuç olarak, konuşmacı tanıma sistemi performansını iyileştirmek için bazı konuşma geliştirme stratejileri kullanılmaktadır. Spektral çıkarma (Kaladharan, 2014) ve dalgacık gürültüsünü giderme (Mihov et al., 2009), başarılı öznelilikler elde etmek amacıyla öznelilikleri çıkarma aşamasından önce ön işleme aşamasında kullanılır.

Bu nedenle, bu makalede, MFCC kullanılarak gürültü ve yankılanma gibi bazı bozulma etkilerinin varlığında metinden bağımsız bir konuşmacı tanıma sistemi test edilmiştir. Öznelilikler, sınıflandırma için LSTM-RNN ile işlenir. Eğitim ağı, konuşmacıları metinden bağımsız olarak tanımlayabilir. Elde edilen doğruluk, LSTM kullanılarak %99'a ulaşmıştır. Test ifadeleri gürültü ve yankı ile bozulduğunda ağın performansı değişkenlik göstermektedir. Önerilen yaklaşımın sonuçları, derin öğrenme modeli olan Evrimsel sinir ağları (Convolution Neural Network - CNN) ve Yapay Sinir Ağları(Artificial Neural Networks - ANN) kullanılarak karşılaştırılmıştır.

Konuşulan ifadeden bağımsız olarak konuşmacıların nasıl tanınacağı konusunda çeşitli çalışmalar sunulmuştur. Bu, sistem tanımlayabildiğinden metinden bağımsız konuşmacı tanıma olarak bilinir. Konuşmacı tanıma sistemlerindeki ana yapı, özellik çıkarma ve sınıflandırmadır. MFCC'ler, Doğrusal Tahmin Katsayıları (Linear Prediction Coefficients -LPCs) ve Doğrusal Öngörü Cepstral Katsayıları (Linear Prediction Cepstral Coefficients - LPCCs) gibi ayırt edici özellikleri çıkarmak için birçok teknik vardır.

2. İlişkili Çalışmalar

Konuşmacı tanımlama süreci genellikle aşağıdaki aşamalardan oluşur: Konuşma verilerinin ön işleme, özellik çıkarma, konuşmacı modelleme ve puanlama. Konuşma ön işleme, ön vurgu, çerçeveleme, pencereleme vb. adımları içerir. Özellik çıkarma, konuşmacının özelliklerini konuşma sinyallerinden etkin bir şekilde karakterize eden karakteristik parametreleri çıkarmaktır. Tipik özellikler arasında MFCC'ler (Wang et al., 2010), LPC'ler (Gudnason et al., 2008), LPCC'ler (Lawson et al., 2008) vb. bulunur. Ardından konuşmacı modeller, bu çıkarılan özelliklerin bir analizi yoluyla oluşturulur. Şu anda, Gauss Karışım Modelleri (Gaussian Mixture Models - GMM) (Gudnason et al., 2008), GMM-Evrensel arka plan modeli (Georgescu et al., 2018), Gizli Markov Modeli (Hidden Markov Model -HMM) (Shahin, 2008) ve Sinir Ağı Modeli (Neural Network - NN) gibi konuşmacı modelleme için hala birçok yöntem kullanılmaktadır.

Son 10 yılda derin öğrenmenin gelişmesiyle(Khan et al., 2021; Şafik et al., 2021),

CNN konuşmacı tanımlama görevlerinde kullanılmıştır. Bir sinir ağı modelinde, etiketli veriler verildiğinde, derin öğrenmeye dayalı bir konuşmacı tanıma sistemi, her konuşmacının derin özelliklerini çıkarır ve denetimli öğrenme gerçekleştirir. Y. Lukic, TIMIT veri setinde %97.0 doğruluk elde eden, 630 konuşmacıdan oluşan bir sette 19 yanlış tanımlanmış konuşmacıya karşılık gelen bir evrimsel sinir ağı tasarladı (Lukic et al., 2016). Aynı zamanda, LSTM ağları (Hochreiter et al., 1997) ve geleneksel RNN (Graves et al., 2013), çeşitli dizi tahmini ve dizi etiketleme görevlerine başarıyla uygulanmıştır. Dil modelleme yapısında, geleneksel bir RNN modeli, standart n-gram modellerine göre karmaşık önemli bir ölçüde azaltmıştır (Mikolov et al., 2010). LSTM ağı, bazı geçit yapılarını tasarlayarak, geleneksel RNN'deki uzun vadeli bağımlılık problemini çözer ve kaybolan gradyan problemini azaltır. Şu anda, LSTM ağı, dil tanımlama görevlerinde geleneksel RNN'den daha iyi performans göstermiştir (Gelly et al., 2016). LSTM modelleri ayrıca metinden bağımsız ve içeriğe duyarlı dilleri öğrenmede geleneksel RNN modellerinden daha iyi performans gösterir (Gers et al., 2001). Derin bir LSTM ağı ile benzer teknikler, grafik tabanlı konuşma tanımayı gerçekleştirmek için önerilmiştir (Eyben et al., 2009). LSTM ağları ayrıca kesintisiz konuşma tanıma için çok akışlı bir çerçevede ses birimi tahmini için önerilmiştir (Wollmer et al., 2011). Bununla birlikte, LSTM network eğitimi için parametre sayısı, geleneksel RNN'den dört kat daha fazladır ve bu yüzden eşleşme yapması daha kolaydır. Kapı Özyinelemeli Geçitler (Gated Recurrent Unit - GRU) ağı ise, performans açısından LSTM ağına benzer, ancak eğitim aşaması daha hızlıdır ve sapma olasılığı daha düşüktür. Mevcut derin öğrenme çözümlerinde, LSTM ve GRU genellikle görsel yerelleştirme (Kim et al., 2020), trafik gürültüsü tahmini (Zhang et al., 2021), stok market tahmini (Althelaya et al., 2018) ve hava kirliliği tahmini (Liu et al., 2020) gibi görevlere uygulanır.

Yukarıda bahsedildiği gibi, konuşma sinyali sürekli tek boyutlu bir zaman serisi olduğundan, mevcut araştırma yöntemlerinin çoğu CNN veya RNN'ye dayanmaktadır. Dolayısıyla, bu ağlar bazı veri setlerinde (Nagrani et al., 2017) iyi performans gösterir. Bu çalışmada ise konuşmacı tanıma için RNN'nin kaybolan gradyan problemine çözüm olarak sunulan LSTM ağları kullanılmıştır. LSTM den elde edilen sonuçlara yeni hiper parametreler eklenerek sonuçları iyileştirilmeye çalışılmıştır. Aynı veri seti üzerinden CNN ve ANN ağları üzerinden test edilerek sonuçlar karşılaştırılmıştır.

3. Materyaller ve Metotlar

3.1. Gelişim:

Eğitim olarak da adlandırılan geliştirme aşamasında, konuşmacı model temsili için ideal olarak evrensel bir model olması gereken arka plan modeli üretimi için konuşmacı ifadeleri kullanılır. DNN'ler, özellik çıkarma gücünden dolayı kullanılır. Derin modeller kullanılarak, evrensel modelde konuşmacıyı temsil eden bir çıktı alanı oluşturmak için öznelik öğrenme yapılacaktır.

3.2. Veri seti:

Konuşmacı tanıma sistemi için konuşmacıların seslerini kaydedilme işlemidir. Konuşmacı için kayıt edilecek sesler farklı kelimelere ait ve çok olursa eğitim daha başarılı olur. Veri seti olarak konuşmacı sesleri kaydetmek yerine "VoxForge" adlı web sitesinden açık kaynaklı ve ücretsiz erişe açılmış hazır ses dosyaları kullanılmıştır. Konuşma dili Türkçe konuşan 20 adet konuşmacı seçilmiş olup, her konuşmacının 10 adet ses dosyası bulunmaktadır.

3.3. Değerlendirme:


Değerlendirme aşaması farklı üç farklı eğitim ağı kullanılmıştır. Bunlar karşılaştırılarak doğru tespit performans değerlendirmeleri yapılmıştır. Eğitimin doğruluk değerleri (train accuracy), eğitimin kayıp değerleri (train loss), test doğruluğu değerleri (test accuracy) ve test kayıp değerleri (test loss) üzerinden grafikler karşılaştırmalar yapılmıştır.

4. Uygulanan Eğitim Ağları

Ana amaç, LSTM modelini konuşmadan çıkarılan özelliklerin üzerine uygulamaktır. Modelin girdisi ve mimarının kendisi aşağıdaki alt bölümlerde açıklanmıştır.

4.1. Giriş :


Ham giriş verisi gürültüden temizlemeden olduğu gibi kabul edilmiştir. Çünkü gerçek zamanlı konuşmacı tespitini önemsiyoruz. Öznelik çıkarımı için MFCC Şekil 1'deki gibi kullanılmıştır. Konuşma sinyali kısa bölümlere ayrılır. Her bölümün güç spektrumu tahmin edilir. Mel filtre bankası güç spektrumlarına uygulanır ve her filtre için enerji toplanır. Filtre bankası enerjilerinin logaritması alınır. Filtre bankası enerjilerinin logaritmalarının ayrık kosinüs dönüşümü (Discrete Cosine Transform, DCT'si hesaplanır. Her segment için 1'den 13'e kadar olan katsayılar alınır ve diğerleri atılır. Ses dosyalarının örnekleme sayısı 16 Khz'dir. Ve konuşma süresi 3 saniyeden uzunsu fazla kısmı kesilmiş, eğer kısa ise sıfır verisiyle doldurularak tüm dosyalar 3 saniyeye eşitlenmiştir. Her 10 dosyanın 9 tanesi eğitim 1 tanesi test olarak kullanılmıştır.



Şekil 1. MFCC blok diyagramı.

4.2. Uygulanan LSTM Mimarisi :

LSTM'ler, RNN modelinde farklı olarak bilgileri daha iyi depolayarak standart RNN'in kısa vadeli bellek problemini ortadan kaldırmak için tasarlanmıştır. LSTM'in gerçekleştirdiği adımlar Şekil 2'de açıklanmıştır. İlk olarak unutma geçidi olan (forget gate) bir sigmoid katmanı ile hangi bilgilerin geçişine izin verileceği belirleniyor. İkinci adımda yeni bilgilerin eklenip eklenmeyeceği *tahn* fonksiyonundan çıkan karara göre veriliyor. Ardından durum ünite durumu güncelleniyor, bir sonraki adım için yeni durum oluşmuş oluyor.



Şekil 2. Temel LSTM blog diyagramı

Bu makale LSTM modeli uygulandıktan sonra çıkan sonuca ayrıca, yeni hiper parametreler eklenerek doğruluk sonuçlarını yükseltmeyi hedeflenmiştir. LSTM modeline *dropout* ve aktivasyon türü *relu* olan *dense* hiper parametreleri eklenerek sonuçlar gözlemlenmiştir.

4.3. Doğrulama aşaması:

Konuşmacı tanımlama sonuçlarını elde etmek için özellikleri öğrenmek ve puanlamak için softmax sınıflandırıcı kullanılmıştır. Softmax'ın işlevi, ham değerleri (işlevlerin bir sonucu olarak) olasılıklara dönüştürür.


$$\text{softmax}(x)_{\text{Speaker}} = \frac{e^{x_{\text{Speaker}}}}{\sum_{\text{Dev Spk}} e^{x_{\text{Dev Spk}}}} \quad (1)$$

$$\begin{cases} x_{\text{Speaker}} = W_{\text{Speaker}} \times y + b \\ x_{\text{Dev Spk}} = W_{\text{Dev Spk}} \times y + b \end{cases} \quad (2)$$


Burada *Speaker* ve *DevSpk* sırasıyla örnek konuşmacıyı ve konuşmacı geliştirme kümesinden bir kimliği belirtir.

5. DeneySEL Sonuçlar


Derin öğrenme modelini oluşturup eğitmek için TensorFlow Keras kütüphanesi kullanılmıştır. 20 konuşmacının 10 farklı sesi ANN, CNN ve LSTM ağları ile eğitildi. Ayrıca her bir LSTM eğitim sonrasında yeni hiper parametreler eklenerek performans artışı sağlanmaya çalışılmıştır. 160 kez eğitildiğinde grafikler aşağıdaki gibi Şekil 3'te gösterilmiştir.




Şekil 3.a. LSTM train loss – accuracy grafiği



Şekil 3.b. LSTM validation loss – accuracy grafiği



Şekil 3.c. CNN train loss – accuracy grafiği



Şekil 3.d. CNN validation loss – accuracy grafiği

Aşağıdaki tablo 1’de farklı eğitim ağı türlerine, konuşmacı sayısına, veri setine ve doğruluk yüzdesine göre karşılaştırmalar yapılmıştır.

Tablo 1. Eğitim Ağı Sonuçları

Eğitim Ağı Türü	Konuşmacı Sayısı	Veri Seti	Doğruluk Yüzdesi
GMM-UBM (Fasounaki et al., 2021)	40	Çağrı Merkezi	89.5
GMM-UBM (Fasounaki et al., 2021)	180	Çağrı Merkezi	82.5
ANN	20	VoxForge	66.7
CNN	20	VoxForge	84.5
LSTM	20	VoxForge	95.2
LSTM ek hiper parametre ile (Önerilen Yöntem)	20	VoxForge	99

Tablodaki sonuçlara göre en iyi sonucu %99 ile standart LSTM modeline ek olarak eklenen yeni hiper parametreler ile elde edilmiştir. CNN’de eğitim sayısı arttıkça doğruluk yüzdesinin arttığı gözlemlenmiştir. Ayrıca farklı çalışmalardan yapılan sonuçlar tabloya eklenmiştir.

6. Sonuç

Konuşmacı tanıma sistemi için LSTM, CNN ve ANN tabanlı ağlarda eğitilen veri setinin performans ölçüm testleri yapılmıştır. MFCC ile özellik çıkarımdan sonra LSTM ağı ile eğitilmiş ortalama 160 kez eğitildikten sonra %95.24 doğruluk elde edilmiştir. LSTM doğruluk yüzdesinin yüksek çıktığı deneylerde sonuç değerlerini artırmak için LSTM ile her bir devir (epoch) aşamasında yeni hiper parametreler eklenerek doğruluk seviyesinin %99 seviyesine ulaşılmıştır. 20 kişilik metinden bağımsız eğitim veri seti için yüksek sonuçlar çıkmasına rağmen bu eğitimdeki kişi sayısı artında doğruluk oranların düştüğü gözlemlenmiştir. Ayrıca farklı uygun yeni hiper parametreler eklenmez ise yine doğruluk seviyesinin düştüğü gözlemlenmiştir.

VI. Kaynaklar

- [1] Dominguez JG et al (2014) Automatic language identification using long short-term memory recurrent neural networks. *Inter Speech* 2014:2155–2159.
- [2] Kaladharan N. (2014) Speech enhancement by spectral subtraction method. *International Journal of Computer Applications* 96(13):45–48.
- [3] Mihov S. G, Ivanov R. M. and Popov A.N (2009) Denoising speech signals by wavelet transform. *Annual Journal of Electronics* 1(6): 2–5.
- [4] Wang L, Minami K, Yamamoto K, Nakagawa S. (2010) Speaker Identification by Combining MFCC and Phase Information in Noisy Environments. In *Proceedings of the 2010 IEEE International Conference on Acoustics, Speech and Signal Processing*, Dallas, TX, USA, pp. 4502–4505.

- [5] Gudnason, J, Brookes M. (2008) Voice source cepstrum coefficients for speaker identification. In Proceedings of the 2008 IEEE International Conference on Acoustics, Speech and Signal Processing, Las Vegas, NV, pp. 4821–4824.
- [6] Lawson A, Vabishchevich P, Huggins M, Ardis P, Battles B, Stauffer A. (2008) Survey and Evaluation of Acoustic Features for Speaker Recognition. In Proceedings of the 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Prague, Czech Republic, pp. 5444–5447.
- [7] Georgescu A, Cucu H. (2018) GMM-UBM Modeling for Speaker Recognition on a Romanian Large Speech Corpora. In Proceedings of the 2018 International Conference on Communications (COMM), Bucharest, pp. 547–551.
- [8] Shahin I (2008) Speaker Identification in the Shouted Environment Using Suprasegmental Hidden Markov Models. *Signal Process* 88:2700–2708.
- [9] Khan M.A, Kim Y (2021) Deep Learning-Based Hybrid Intelligent Intrusion Detection System. *Comput. Mater. Contin* 68:671–687.
- [10] Shafik A, Sedik A, Abd El-Rahiem B, El-Rabaie E.S.M, El Banby G.M, Abd El-Samie F.E, Khalaf A.A.M, Song O.Y, Iliyasu, A.M (2021) Speaker identification based on Radon transform and CNNs in the presence of different types of interference for Robotic Applications. *Appl. Acoust* 177: 107665.
- [11] Lukic Y, Vogt C, Dürr O, Stadelmann T. (2016) Speaker Identification and Clustering Using Convolutional Neural Networks. In Proceedings of the 2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP), Vietri sul Mare, pp. 1–6.
- [12] Hochreiter S, Schmidhuber J (1997) Long Short-Term Memory. *Neural Comput* 9:1735–1780.
- [13] Graves A, Jaitly N, Mohamed A. (2013) Hybrid speech recognition with Deep Bidirectional LSTM. In Proceedings of the 2013 IEEE Workshop on Automatic Speech Recognition and Understanding, Olomouc, Czech Republic, pp. 273–278.
- [14] Mikolov T, Karafiát M, Burget L, Cernocký J, Khudanpur S. (2010) Recurrent Neural Network Based Language Model. In Proceedings of the INTERSPEECH 2010 11th Annual Conference of the International Speech Communication Association, Makuhari, Chiba, pp. 1045–1048.
- [15] Gelly G, Gauvain J.L, Le V.B. Messaoudi, A. (2016) A Divide-and-Conquer Approach for Language Identification Based on Recurrent Neural Networks. In Proceedings of the INTERSPEECH, San Francisco, CA, pp. 3231–3235.
- [16] Gers F.A, Schmidhuber E (2001) LSTM recurrent networks learn simple context-free and context-sensitive languages. *IEEE Trans. Neural Netw* 12:1333–1340.
- [17] Eyben F, Wöllmer M, Schuller B, Graves A, Schlüter R, Ney H. (2009) From speech to letters—Using a novel neural network architecture for grapheme based ASR. In Proceedings of the 2009 IEEE Workshop on Automatic Speech Recognition & Understanding, Moreno, pp. 376–380.
- [18] Wollmer M, Eyben F, Schuller B, Rigoll G, Ney H. (2011) A Multi-Stream ASR Framework for BLSTM Modeling of Conversational Speech. In Proceedings of the 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Prague, pp. 4860–4863.
- [19] Kim S, Kim I, Vecchietti L.F, Har D (2020) Pose Estimation Utilizing a Gated Recurrent Unit Network for Visual Localization. *Appl. Sci* 10: 8876.
- [20] Zhang X, Kuehnelt H, De Roeck W (2021) Traffic Noise Prediction Applying Multivariate Bi-Directional Recurrent Neural Network. *Appl. Sci.* 11:2714.
- [21] Althelaya K.A, El-Alfy E.M, Mohammed S. (2018) Stock market forecast using multivariate analysis with bidirectional and stacked (LSTM, GRU). In Proceeding of the 2018 21st Saudi Computer Society National Computer Conference (NCC), Riyadh, Saudi Arabia, pp. 1–7.
- [22] Liu D.R, Lee S.J, Huang Y, Chiu C.J (2020) Air pollution forecasting based on attention-based LSTM neural network and ensemble learning. *Expert Syst.* 37:e12511.

- [23] Nagrani A, Chung J.S, Zisserman A (2017) (Voxceleb: A large-scale speaker identification dataset. arXiv 2017, arXiv:1706.08612.
- [24] Fasounaki, M, Yüce, E, Öncül S, İnce G. (2021). A Comparative Assessment of Text-independent Automatic Speaker Identification Methods Using Limited Data. European Journal of Science and Technology, pp. 217-222.

Fotovoltaik Sistemlerde Kullanılan Geleneksel MPPT Metotlarının Uniform Radyasyon ve Parçalı Gölgeleme Durumundaki Performanslarının Matlab/Simulink Yardımıyla İncelenmesi

Investigation of the Performance of Traditional MPPT Methods Used in Photovoltaic Systems in Uniform Irradiance and Partial Shading with the Help of Matlab/Simulink

Sinem Melike TURAN^{*1} , Mustafa ŞEKER² 

¹Elektrik Elektronik Mühendisliği (Lisans Öğrencisi), Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye

²²Hafik Kamer Örnek Meslek Yüksekokulu, Ulaştırma Hizmetleri Bölümü, Raylı Sistemler İşletmeciliği Programı, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye

(2019117052@cumhuriyet.edu.tr, mustafaseker@cumhuriyet.edu.tr)

Özetçe—PV hücrelerin verimliliği %11-28 civarındadır. Bu nedenle, PV sistemler enerji üretiminde maksimum verim elde edilebilecek şekilde tasarlanmalıdır. Bu çalışmada, fotovoltaik sistemlerde maksimum güç noktasının (MPPT) izlenmesinde kullanılan geleneksel metotlardan Perturb and Observe (P&O), Hill Climbing (HC) ve Incremental Conductance (IC) algoritmalarının üniform radyasyon ve parçalı gölgeleme durumu altındaki performansları Matlab/Simulink kullanılarak incelenmiştir, PV sistem 4 seri 4 paralel panel bağlantı durumunu için modellenmiştir ve dört farklı gölgeleme durumu için test edilmiştir. Sistemde konvertör olarak sepic konvertör kullanılmıştır. Ede edilen sonuçlar üniform radyasyon durumunda geleneksel MPPT metotlarının %3-4 hata ile MPPT noktasını yakalama yeteneğine sahip olduğunu göstermektedir. Parçalı gölgelemede ise hata oranı gölgeleme miktarına bağlı olarak %10 üzerine çıkabilmektedir. Parçalı gölgeleme durumunda HC algoritmasının daha iyi performansa sahip olduğu gözlenmiştir.

Anahtar Kelimeler : Fotovoltaik sistem, Sepic Konvertör, Maksimum Güç Noktası İzleme (MPPT), Geleneksel MPPT algoritmaları

Abstract— The efficiency of PV cells is around 11-28%. Therefore, PV systems should be designed in such a way that maximum efficiency can be obtained in energy production. In this study, the performances of Perturb and Observe (P&O), Hill Climbing (HC), and Incremental conductance (IC) algorithms, which are traditional methods used in monitoring the maximum power point (MPPT) in photovoltaic systems, under uniform radiation and patchy shadowing conditions were investigated using Matlab/Simulink. The PV system is modeled for my 4 series 4 parallel panel connection situation and tested for four different shadowing situations. A sepic converter is used as a converter in the system. The results show that conventional MPPT methods are capable of capturing the MPPT point with %3-4 error in case of uniform radiation. In partial shading, the error rate may exceed 10% depending on the amount of shading. It has been observed that the HC algorithm has better performance in the case of partial shadowing.

Keywords : Photovoltaic system, Sepic Converter, Maximum Power Point Tracking (MPPT), Conventional MPPT algorithms

1.Giriş

İnsanoğlunun günlük ihtiyaçlarını devam ettirmesinde ihtiyaç duyduğu en önemli kaynak elektrik enerjisidir. Günümüzde ihtiyaç duyulan elektrik enerjisinin büyük bir kısmı fosil yakıtlardan elde edilmektedir. Fakat fosil yakıtlar sınırlı bir rezerve sahiptir. Ayrıca fosil yakıtların yanmaları sonucu oluşan gazların günümüz en büyük sorunu haline gelen iklim değişikliklerinin ortaya çıkmasında da önemli bir rol oynamaktadır(Zaki Diab & Rezk, 2017). Ülkeler bu olumsuzlukları aşmak için çevreye duyarlı yenilenebilir enerji kaynaklarına yönelmektedir. Fotovoltaik (PV) teknolojiler ise güneş gibi sınırsız bir enerji kaynağına sahip olması ve diğer yenilenebilir enerji üretim yöntemleriyle karşılaştırıldığında daha fazla kurulabilir alana sahip olmaları nedeniyle daha fazla tercih edilir hale gelmiştir(Gosumbonggot et al., 2018; Ishaque et al., 2011; Rezk, 2016; Rezk & Dousoky, 2016).

PV sistemlerin en önemli dezavantajı ise verimliliklerinin düşük olmasıdır. Her ne kadar PV hücrelerin verimleri arttırmak için Ar-Ge çalışmaları devam etse de, mevcut durumda hücre verimlilikleri yaklaşık %11-28 civarında olmaktadır(Aygül et al., 2019). Bu nedenle PV sistemler maksimum verim elde edilebilecek şekilde tasarlanmalı ve uygun coğrafi lokasyonlarda kurulmalıdır. Bazen PV hücreler yapılan yanlış tasarımlar sonucunda binaların gölgelenmeye neden olması veya bulutlanma nedeniyle güneş yoğunluklarını kaybederler. PV hücrelerin üreteceği enerji miktarı direk olarak solar radyasyon değeri ile orantılı olduğundan, bu durumlar oluştuğunda PV hücreler maksimum verimde çalıştırılmaz.

Normal koşullarda (1000 W/m^2 ve 25 C°) PV modüller global maksimum güç noktası (GMPP) olarak adlandırılan maksimum güç noktasına (MPP) sahiptir. PV dizileri seri, paralel veya seri-paralel kombinasyon şeklinde bağlanabilir. PV dizilerinin aynı radyasyon miktarına sahip olması (uniform) durumunda, tek maksimum güç noktası oluşturur(Xu et al., 2017). Bulutlanma veya herhangi bir sebeple PV dizilerinin gölgelenmeye maruz kalması durumunda ise PV modüllerin maruz kalacağı radyasyon miktarları birbirinden farklı olacağından, birden fazla maksimum güç noktasına oluşacaktır. Her bir panel için tanımlanan bu farklı maksimum güç noktaları lokal maksimum güç noktası (LMPP) olarak adlandırılır ve LMPP durumunda elde edilen maksimum güç noktası, GMPP durumunda elde edilen güç noktasından daha düşük olmaktadır(Aygül et al., 2019).


PV hücrelerin Güç-Gerilim (P-V) eğrileri lineer olmayan karakteristik yapısına sahiptir. PV sistemlerin çıkış gücünü maksimize etmek için maksimum güç noktasında (MPP) çalıştırılması gereklidir. PV sistemlerin MPP noktasında çalıştırılabilmesi için maksimum güç noktası izleyiciler (Maksimum Power Point Tracer- MPPT) tasarlanmaktadır. Bu amaç için çok sayıda araştırmacı tarafından farklı optimizasyon teknikleri geliştirilmiştir. Hill Climbing (Xiao & Dunford, 2004), Incremental Conductance (IC) (Femia et al., 2005; Tey & Mekhilef, 2014; Xu et al., 2017) ve Perturb&Observe (P&O)(Femia et al., 2005) algoritması gibi geleneksel optimizasyon algoritmaları MPPT tasarımında yaygın olarak kullanılmaktadır. Geleneksel optimizasyon algoritmalarının haricinde parçacık sürü optimizasyon algoritması (Ishaque & Salam, 2013; Koad et al., 2017), genetik algoritma(Daraban et al., 2013) ve Meta-Sezgisel optimizasyon yaklaşımını içeren çok sayıda algoritma MPPT için geliştirilmiştir (Chao et al., 2015; Ishaque & Salam, 2013; Jiang et al., 2013; Mohanty et al., 2016; Radjai et al., 2014).

Bu çalışmada, PV dizilerinin parçalı gölgelenme durumuna maruz kalması durumunda geleneksel MPPT metotlardan IC, HC ve P&O algoritmalarının performansları Matlab/Simulink kullanılarak incelenmiştir. Sunulan çalışma altı bölüm halinde düzenlenmiştir. Çalışmanın ikinci bölümünde analizde kullanılan PV sistemin modellenmesi açıklanmıştır. Sistemde DC-DC konvertör olarak sepic konvertör topolojisi seçilmiştir ve sepic konvertörün çalışma yapısı yine bu bölümde ele alınmıştır. Çalışmanın üçüncü bölümünde ise uniform ve parçalı gölgelenme durumunda PV sistemin karakteristik yapısı incelenmiştir. IC, HC ve P&O algoritma yapıları ve MPPT optimizasyonunda nasıl kullanıldığı ise dördüncü bölümde sunulmuştur. Beşinci bölümde ise Matlab/Simulink kullanılarak elde edilen sonuçlar verilmiş ve son bölümde sonuçlara ilişkin özet bir değerlendirme sunulmuştur.

VII. 2. PV sistemin modellenmesi

PV sistemin oluşturan temel sistem elemanlarının blok olarak gösterimi Şekil 1’de sunulduğu gibi PV modüller ve DC-DC konvertörlerden oluşur. PV modüllerin üretecekleri güç miktarı belirleyen en


önemli faktörler ise güneş radyasyonu ve sıcaklıktır. MPPT için gerekli olan akım gerilim değerleri konvertör girişinden ölçülür. Ölçülen akım ve gerilim değerlerine bağlı olarak MPPT bir duty saykıl üretir. Duty saykıl ve mosfet sürücü devresi kullanılarak sepic konvertördeki MOSFET'in tetikler. Bu işlem sayesinde PV sistemin maksimum güç üretmesi sağlanır.



Şekil 12. Sistemin Blok Yapısı

2.1. PV Hücresinin Karakteristik Yapısı

Fotovoltaik hücrelerin modellenmesinde farklı devre modelleri kullanılmakla (Ciulla et al., 2014) birlikte bu çalışmada Şekil 2'de gösterildiği gibi tek diyotlu devre modeli kullanılmıştır (Araújo et al., 2020). Şekil 2'de gösterilen akım ifadeleri için Kirshoff'un akım yasası uygulandığında PV'nin çıkış akımı (1) denklemi ile ifade edilir.



Şekil 13. PV hücresinin tek diyot eşdeğer devre modeli.

$$I_{out} = I_{pv} - I_d - I_p \quad (1)$$

Bu denklemde, I_{pv} -PV hücresinin ışık akımı, I_d -diyot akımı ve I_p -şönt akım değeridir. I_{out} ise çıkış akımı ifade etmektedir. I_d akımı diyot saturasyonuna bağlı olarak matematiksel ifadesi (2) denklemi ile tanımlanır. I_p akımı içinse $(V+I.R_S)/R_P$ yazılabilir. Bu ifadeler dikkate alındığında (1) ifadesi (3) denklemine gösterildiği gibi tanımlanır.

$$I_d = I_0 \cdot \left[\exp \left(\frac{(V + I.R_S)}{a} \right) - 1 \right] \quad (2)$$

$$I_{out} = I_{pv} - I_0 \cdot \left[\exp \left(\frac{(V + I.R_S)}{a} \right) - 1 \right] - \frac{V + I.R_S}{R_P} \quad (3)$$

(3) denklemine a değeri yaklaşık olarak denklem (4)'de sunulan eşitlik ile hesaplanır.

$$a \cong \frac{N_s n_1 k T_c}{q} \quad (4)$$

Bu ifadede, k : Boltzmann sabiti, q : elektron yükü, n_1 : ideallik faktörü, N_s : seri hücre sayısı ve T_c : hücrenin sıcaklığıdır. Bu çalışmada, PV panel modellenmesinde beş parametrelili devre modeli kullanılmıştır. Bu modelde I_{pv} , I_0 , R_s , R_p ve a değerlerinin bilinmesi gereklidir.

Eşitlik (3)'de PV hücrenin genel matematiksel ifadesi standart koşullarda PV nin akım gerilim karakteristiğini tanımlar. Standart koşullarda PV hücre sıcaklığının 25 0C ve radyasyon (irradiance) miktarı ise 1000 W/m² olduğu kabul edilir (Xu et al., 2017). Farklı sıcaklık ve radyasyon seviyelerinde PV karakteristiğini tanımlamada standart koşullarda verilen parametreler referans olarak kullanılır. Standart parametrelerin belirlenmesinde kısa devre akımı, açık devre gerilimi, maksimum güç durumunda akım ifadesi ve açık devre geriliminin sıcaklık çarpanı (5)-(10) denklemleri kullanılarak hesaplanır.

Kısa devre akımı için; $I = I_{sc,ref}$, $V = 0$ olmalıdır.

$$I_{sc,ref} = I_{pv,ref} - I_{0,ref} \left[e^{\frac{I_{sc,ref} R_{s,ref}}{a_{ref}}} - 1 \right] - \frac{I_{sc,ref} R_{s,ref}}{R_{p,ref}} \quad (5)$$

Açık devre gerilimi için: $I = 0$, $V = V_{oc,ref}$ olur. Bu durumda;

$$0 = I_{pv,ref} - I_{0,ref} \left[e^{\frac{V_{oc,ref}}{a_{ref}}} - 1 \right] - \frac{V_{oc,ref}}{R_{p,ref}} \quad (6)$$

yazılabilir. Maksimum güç noktasında: $I = I_{mp,ref}$ ve $V = V_{mp,ref}$ olarak ifade edilebilir. Bu durumda maksimum akım değeri (7) denklemi ile tanlanır.

$$I_{mp,ref} = I_{pv,ref} - I_{0,ref} \left[e^{\frac{V_{mp,ref} + I_{mp,ref} R_{s,ref}}{a_{ref}}} - 1 \right] - \frac{V_{mp,ref} + I_{mp,ref} R_{s,ref}}{R_{p,ref}} \quad (7)$$

Maksimum güç noktasında gücün türev ifadesi sıfıra eşit olacağından;

$$\left. \frac{d(IV)}{dV} \right|_{mp} = I_{mp} - V_{mp} \left. \frac{d(IV)}{dV} \right|_{mp} = 0 \quad (8)$$

yazılabilir. Bu ifadede $\left. \frac{d(IV)}{dV} \right|_{mp}$ ifadesi (9) denklemi ile tanımlanır.

$$\left. \frac{d(IV)}{dV} \right|_{mp} = \frac{\frac{I_0}{a} e^{\frac{V_{mp} + I_{mp} R_s}{a}} - \frac{1}{R_s}}{1 + \frac{I_0 R_s}{a} e^{\frac{V_{mp} + I_{mp} R_s}{a}} + \frac{R_s}{R_p}} \quad (9)$$

Açık devre geriliminin sıcaklık çarpanı ise (10) denklemi ile ifade edilir.

$$\mu_{V_{oc}} = \left. \frac{\partial V}{\partial T} \right|_{mp} \approx \frac{V_{oc,ref} - V_{oc,T_c}}{T_{ref} - T_c} \quad (10)$$

Gerilim sıcaklık çarpanının bilinmesi için V_{oc,T_c} değerinin bilinmesi gereklidir. Bu değer standart koşullardaki referans sıcaklığında açık devre gerilimidir (V_{oc}).

PV hücrenin çalışma koşulları altında ideallik faktörü hücre sıcaklığına bağlı lineer bir fonksiyon olarak ifade edilir (Denklem 11). Ters Diyot (reverse) saturasyon akımı ise denklem (12)'de verilmiştir.

$$\frac{a}{a_{ref}} = \frac{T_c}{T_{c,ref}} \quad (11)$$

$$I_0 = I_{0,ref} \left[\frac{T}{T_{ref}} \right]^3 \exp \left[\frac{E_{g,ref}}{k T_{ref}} - \frac{E_g}{k T} \right] \quad (12)$$

(11) ve (12) denklemlerinde; k Boltzmann sabitidir ve E_g malzeme bant aralığı. a_{ref} ve $T_{c,ref}$ sırasıyla referans koşullara göre modifiye edilmiş diyot ideallik faktörü ve hücre sıcaklığıdır. Farklı hücre tipleri için hesaplanan E_g değerleri ekler kısmında Tablo A1' de sunulmuştur. Silikon hücreler için $E_g=1.121$ eV olarak alınır. E_g ve $E_{g,ref}$ arasındaki matematiksel ilişki sıcaklık değerine bağlıdır ve denklem (13) ile ifade edilir.

$$\frac{E_g}{E_{g,ref}} = 1 - 0.0002677(T - T_{ref}) \quad (13)$$

PV'nin ürettiği akım radyasyon miktarına bağlı lineer bir fonksiyon olarak tanımlanır ve (14) ile ifade edilir.

$$I_{pv} = I_{pv,ref} \left(\frac{G}{G_{ref}} \right) [1 + \alpha_T'(T - T_{ref})] \quad (14)$$

$$\alpha_T = \alpha_T' I_{pv,ref} \quad (15)$$


Bu eşitliklerde, G : PV hücrenin çalışma sırasında ölçülen radyasyon değeri, T : hücre sıcaklığı, T_{ref} : 25 Co de sıcaklık değeri, α_T : kısa devre akım sıcaklık çarpanıdır. Nominal koşullardaki referans radyasyon değeri $G_{ref}=1000$ W/m²'dir.

PV hücrelerin seri veya paralel bağlanması durumunda akım-gerilim ilişkisi denklem (16) ile tanımlanır. Bu denklemde N_S : seri panel sayısı, N_P :paralel panel sayısını ifade eder.

$$I_A = N_P I_{pv} - N_P I_0 \cdot \left[\exp \left(\frac{q(V_A + I_A \frac{N_S}{N_P} \cdot R_S)}{N_S n k T} \right) - 1 \right] - \frac{V_A + I_A \frac{N_S}{N_P} R_S}{\frac{N_S}{N_P} R_P} \quad (16)$$

2.2. DC-DC Sepic Konvertörün Modellenmesi

SEPIC (The single-ended primary-inductor converter) çıkış geriliminin, giriş geriliminden büyük veya düşük seviyede gerilim üretilmesine izin veren DC-DC konvertör tipidir. SEPIC konvertörün temel devre şeması Şekil 3'de gösterilmiştir. SEPIC konvertörün çıkış gerilimi mosfet kullanılarak duty saykıl ile kontrol edilir. Sepic konvertörün çalışma yapısı buck-boost konvertör çalışma yapısına benzerdir. Fakat çıkış polaritesi buck-boost konvertörün aksine pozitifdir (Falin, 2008).



Şekil 14. Sepic konvertörün temel devre şeması.

SEPIC konvertörün çalışmasında diyot anahtar olarak kullanılır ve anahtarın iletimde veya kesimde olmasına göre çalışması değerlendirilir. Anahtar iletimde iken L1a bobini enerjilenir, akım lineer olarak artar. Bu durumda Cp kapasitörü deşarj olur ve enerjisini L1b bobinine aktarır. Bobin akımı lineer olarak artar. Diğer taraftan Cout kapasitörü yükü beslemeye devam eder. Anahtar kesime gittiğinde, D1 diyodu iletime geçer, C1 kapasitörü, L1a bobini ve DC kaynak tarafından şarj edilir(Falin 2008). Aynı zamanda C2 kapasitörü kaynak, L1a ve L1b tarafında şarj edilir ve yük beslenir. SEPIC konvertörün devre parametrelerinin seçimi için gerekli olan hesaplamalar denklem (16-20) de sunulmuştur.

- Duty Saykıl

SEPIC konvertörün sürekli iletim modunda (Continuous Conduction mode (CCM)) çalışabilmesi için uygulanacak Duty saykıl denklem (16) ile tanımlanır.

$$\frac{V_{out}}{V_{in}} = \frac{D}{1-D} \quad (16)$$

- **Bobin değerlerinin seçimi**

Darbe sinyalinin belirlenmesinde indüktör dalgalanma akımının (ΔI_L) ne kadar olmasına karar verilmelidir. Kural olarak dalgalanma akımı giriş akımının %20 ile %40'ı aralığında seçilir. Dalgalanma akımının matematiksel denklemi (17) denklemi ile ifade edilir.

$$\Delta I_L = \%40 \cdot I_{in} = I_{out} \frac{V_{out}}{V_{in(min)}} \cdot 40\% \quad (17)$$

Dalgalanma akımına bağlı olarak L1a ve L1b indüktans değerlerinin minimum ifadesi (18) denklemi ile tanımlanır. Bu ifadede ΔI_L , dalgalanma akımı ve f_{swmin} anahtarlama frekansdır. Yük geçici durumları dikkate alındığında bobin çiftinin saturasyon oranı yüksek taraftaki pik akımının en az %20 fazlası olması gerekmektedir. L1a bobinini maksimum akım değeri ise denklem (19) ile tanımlanır.

$$L_{1a(min)} = L_{1b(min)} = \frac{1}{2} \frac{V_{in(min)} \times D_{max}}{\Delta I_L \times f_{swmin}} \quad (18)$$

$$I_{L1a(peak)} = I_{in} + \left(\frac{\Delta I_{L1}}{2} \right) \quad (19)$$

Standart olarak bobin değerlerinin maksimum değeri (20) denklemi ile ifade edilir;

$$L_{1a(max)} = L_{1b(max)} = \frac{V_{in(min)} \times D_{max}}{\Delta I_L \times f_{swmin}} \quad (20)$$

SEPIC konvertörün parametrelerinin hesaplanmasında kullanılan diğer eşitlikler (21-24) denklemleri ile tanımlanır.

- **Maksimum MOSFET akımının pik ve RMS değeri;**

$$I_{Q1(peak)} = I_{L1a(peak)} + I_{L1b(peak)} \quad (21)$$

$$I_{Q1(rms)} = I_{out} \sqrt{\frac{(V_{out} + V_{in(min)} + V_D)(V_{out} + V_D)}{V_{in}^2}} \quad (22)$$

- **Çıkış diyodunun seçimi;**


$$V_{RD1} = V_{in(max)} + V_{out(max)} \quad (23)$$

- **SEPIC kapasitörün seçimi (Cp);**


$$I_{cp} = I_{out} \sqrt{\frac{V_{out} + V_d}{V_{in(min)}}} \quad (24)$$

3. Uniform ve Parçalı Gölgeleme Altında (Partial Shading Condition-PSC) PV Karakteristikleri

PV paneller seri veya paralel olarak farklı kombinasyonlarda bağlanabilir. PV hücrelerin çıkış gücü sıcaklık ve radyasyon miktarına bağlı olarak değişmektedir. Standart koşullarda bir PV hücrenin karakteristik değişim eğrileri Şekil 4a ve Şekil 4b' deki gibidir.



(a)




(b)

Şekil 15. Standart koşullarda bir PV hücrenin sıcaklık ve radyasyon değişimi. a) 1000, 700, 300 ve 100 W/m² radyasyon değerleri için V-I ve P-I eğrisi, b) 25, 45, 65 ve 85 C° sıcaklık seviyeleri için V-I ve P-I eğrisi.

Şekil 4' den görüldüğü gibi sıcaklık ve radyasyon seviyesine bağlı olarak global maksimum güç noktası değişmektedir. Parçalı gölgelenme etkisi oluştuğunda PV karakteristik eğrisinde birden fazla güç noktası görülebilir. Hot-spot durumda PV panel yük gibi davranır. PV modüle paralel olarak bağlanan baypass diyot PSC durumunda hot-spot olasılığını azaltır.


Bu çalışmada analiz edilen PV paneller Şekil 5'te gösterildiği gibi 4 seri ve 4 paralel (4S4P) kombinasyonu içerecek şekilde bağlanmıştır. Sistemin verilen bağlantı durumunda toplam gücü 1.332 kW'tır. Tablo 2'de gösterildiği gibi, uniform radyasyon durumu ve üç farklı parçalı gölgelenme durumunda incelendiğinde sistemin akım-gerilim ve güç-gerilim karakteristik eğrisi sırası ile Şekil 6 ve Şekil 7' deki gibidir.




Şekil 16. 4S4P PV hücrenin bağlantı şeması

Tablo 4. Uniform ve farklı Parçalı gölgelenme koşullarında (PSC) durumunda PV hücrelerin maruz kaldığı radyasyon miktarlar (W/m^2).

	Uniform Irradiance	PSC Pattern #2	PSC Pattern #3	PSC Pattern #4
G11	1000	1000	1000	100
G12	1000	1000	1000	100
G13	1000	1000	500	175
G14	1000	1000	500	250
G21	1000	700	1000	300
G22	1000	700	1000	300
G23	1000	700	500	400
G24	1000	700	500	125
G31	1000	300	1000	500
G32	1000	300	1000	350
G33	1000	300	300	325
G34	1000	300	300	50
G41	1000	100	1000	300
G42	1000	100	1000	200
G43	1000	100	100	100
G44	1000	100	100	800



Şekil 17. Uniform radyasyon ve farklı parçalı gölgelenme durumunda 4S4P konfigürasyonunun akım-gerilim karakteristik eğrisi



Şekil 18. Uniform radyasyon ve farklı farklı parçalı gölgelenme durumunda 4S4P konfigürasyonunun güç-gerilim karakteristik eğrisi

4. PSC altında Geleneksel Optimizasyon Teknikleri ile MPPT Metodolojisi

Bu çalışmada PSC ve uniform radyasyon durumunda PV sistemin MPPT optimizasyonu için geleneksel metotlardan Perturb&Observe (PO), Incremental Conductance (IC) ve Hill Climbing (HC) algoritmalarının performansı Matlab/Simulink ortamında analiz edilmiştir. Bu bölümde P&O, IC, HC algoritmalarının çalışma prensibi açıklanmıştır.

4.1. Geleneksel MPPT Metotları


4.1.1. Perturb and Observe (P&O)

P&O metodu PV panellerde maksimum güç noktasının araştırılmasında kullanılan en temel metottur. P&O metodunda PV panelinin akım ve gerilimi ölçülür. Modül çalışma gerilim değişimi incelenerek panelin anlık güç değeri hesaplanır (Bendib et al., 2015). Çıkış gücü anlık olarak elde edilen bir önceki değerle karşılaştırılır. Eğer çıkış gücü artmışsa gerilimin değişim yönünün doğru olduğu belirlenir. Bu işlem devam ederek MPPT noktasına ulaşıncaya kadar tekrarlanır (Femia et al., 2005, 2009). Eğer gücün değişimi negatif ise sistem optimal noktadan uzaklaşır ve bu durumda perturbation size değerinin MPP'nin çalışma noktasını yakalayabilmesi için gerilim değerinin azaltılması gerekir. P&O algoritmasının akış diyagramı Şekil 8'de sunulmuştur.


4.1.2. Incremental Conductance (IC)

Incremental Conductance (IC) yönteminde temel amaç PV panelin çıkış gücünün değişimini incelemektir. IC algoritması; PV panelin çıkış gücündeki anlık değişimin (dP), panel geriliminin değişimine oranının (dV) maksimum güç noktasında sıfır olacağı prensibine göre çalışır (Kim et al., 2001; Lee et al., 2007).

Eğer $dP/dV > 0$ ise sistemin o anki çalışma noktasının MPP noktasının sol tarafında olduğu anlaşılmaktadır. Ters olarak $dP/dV < 0$ ise çalışma noktası MPP noktasının sağında olacaktır [70-71]. Bu yöntemde P&O algoritmasında olduğu gibi PV panelin çıkış akım ve gerilimi ölçülerek anlık güç değişimi hesaplanır. IC algoritması güç değişiminde $dP/dV=0$ olana kadar MPP noktasını aramaya devam eder. Bu yöntem hızlı bir değişim olması durumunda P&O yönteminde karşılaşılan yanlış hesapların üstesinden gelmek için önerilmektedir. IC metodunun akış şeması Şekil 9'da gösterilmiştir.




Şekil 19. P&O algoritma akış şeması.



Şekil 20. IC algoritma akış şeması.

4.1.3. Hill Climbing


Hill Climbing (HC) metodu P&O metoduna benzer yapıdadır. HC algoritması, V-I karakteristik eğrisi üzerinde çalışma noktasında anlık gücün arttığı yönde hareket ederek maksimum tepe noktasını yakalamaya çalışır. Bu durumda arttırım DC-DC konvertörün duty cycle' ına uygulanır. Konvertörün D anahtarı çalışma gücü MPP noktasında salınana kadar değişmeye devam eder. HC metodunun akış şeması Şekil 10' da sunulmuştur.




Şekil 21. HC algoritma akış şeması.

5. Benzetim Sonuçları

Simülasyon analizinde kullanılan sistem bileşenleri Şekil 15' de gösterilmiştir. Sistem 4S4P PV dizisi, yük, sepic konvertör ve MPPT kontrol birimini içermektedir. Çalışmada sunulan MPPT algoritmaların test edilmesi için 4 farklı senaryo oluşturulmuştur. Tablo 2' de sunulan dört farklı senaryo için P-V ve I-V karakteristik eğrileri Şekil 16' daki gibidir.



Şekil 22. MPPT sistemi için sepic konvertör kullanımı.




Şekil 23. Farklı solar radyasyon altında fotovoltaik sistemin P-V ve I-V karakteristikleri a) Uniform Rasyasyon, b) Pattern #2, c) Pattern #3, d) Pattern #4.


Tüm senaryolarda sıcaklık değeri 25°C seçilmiştir ve DC-DC konvertörün anahtarlama frekansı 10 kHz olarak alınmıştır. Yük direnci $50\ \Omega$ ’dur.

5.1. Geleneksel Yöntemlerle MPPT algoritmalarının simülasyon sonuçları


P&O, IC ve HC MPPT algoritmaları Şekil 15’de verilen sistem kullanılarak 4 farklı senaryo için test edilmiştir. Test sonuçları sırası ile grafiksel olarak Şekil 17-Şekil 20’de sunulmuştur.




Şekil 24. P&O, IC ve HC konvansiyonel yöntemlerle tek tip ışınım altında MPPT algoritmalarının simülasyon sonuçları



Şekil 25. P&O, IC ve HC konvansiyonel yöntemlerle Pattern#2 altında MPPT algoritmalarının simülasyon sonuçları.



Şekil 26. P&O, IC ve HC konvansiyonel yöntemlerle Pattern#3 altında MPPT algoritmalarının simülasyon sonuçları.




Şekil 27. P&O, IC ve HC konvansiyonel yöntemlerle Pattern#4 altında MPPT algoritmalarının simülasyon sonuçları.

Şekil 17-20’ de sunulan test sonuçlarında elde edilen maksimum güç noktaları özet olarak Tablo 4’ de gösterilmiştir. Tablo 4 incelendiğinde uniform irradiance ve pattern#2 durumunda P&O, IC ve HC algoritmalarının %3-4 hata payı ile MPPT noktasını yakaladığı görülmektedir. Uniform irradiance durumunda P&O, IC ve HC algoritmalarının hızı sırası ile 0.012, 0.006 ve 0.020 s olmaktadır. Fakat Pattern#3 ve Pattern#4 koşullarında üç algoritmanın da MPPT noktasının altında kaldığı görülmektedir.

Tablo 5. Geleneksel yöntemler ile elde edilen MPPT algoritmalarının karşılaştırılması.

Koşul	MPPT Algoritması	GMPP	P _{mak}	P _{min}	Port	Hata (%)	Ripple (%)	Oturma Süresi
Uniform Radyasyon	P&O	1332.46	1293.3	1264.2	1292.9	2,97	2,25	0.012
	IC	1332.46	1317.7	1220.8	1279.5	3,97	7,35	0.006
	HC	1332.46	1301.4	1263.7	1279.8	3,95	2,90	0.020
Pattern #2	P&O	466.11	444.71	428.40	438.03	6,02	3,67	0.012
	IC	466.11	443.96	424.32	437.48	6,14	4,42	0.006
	HC	466.11	435.96	432.90	434.40	6,80	0,70	0.025
Pattern #3	P&O	737.10	702.82	667.73	688.28	6,62	4,99	0.055
	IC	737.10	704.10	651.01	678.13	8,00	7,54	0.065
	HC	737.10	701.04	688.15	701.04	4,89	1,84	0.130
Pattern #4	P&O	209.39	185.63	174.11	181.11	13,51	6,21	0.009
	IC	209.39	186.99	179.49	185.65	11,34	4,01	0.063
	HC	209.39	190.79	190.54	190.67	8,94	0,13	0.010

**Şekil 28.** Local MPPT noktası civarında hapsolmuş P&O, IC ve HC algoritmalarının görsel olarak tanımlanması.

Şekil 21’ den de görüleceği gibi geleneksel yöntemler parçalı gölgelenme oluşması durumunda istenilen GMPP noktasının yakalanmasını kararlı bir şekilde sağlamamaktadır. LMPPT noktalarına hapsolabilmektedir. Bu nedenle MPPT tasarımında geleneksel metotların kullanılması her zaman istenilen MPPT noktasının yakalanmasını tam olarak yakalayamadığı görülmektedir.

6. Sonuçlar

Fotovoltaik sistemlerden maksimum güç üretiminin sağlanması için değişen solar radyasyon altında sistemin maksimum güç üretecek şekilde çalışması gereklidir. Bu çalışmada, Fotovoltaik sistemlerin maksimum güç noktasının izlenmesinde kullanılan geleneksel optimizasyon algoritmalarından Perturb and Observe (P&O), Hill Climbing (HC) ve Incremental Conductance (IC) algoritmalarının üniform radyasyon ve parçalı gölgelenme durumu altındaki performansları Matlab/Simulink kullanılarak incelenmiştir, PV sistem 4 seri 4 paralel panel bağlantı durumunu için modellenmiştir ve dört farklı gölgelenme durumu için test edilmiştir. Sistemde konvertör olarak sepic konvertör kullanılmıştır. Elde edilen sonuçlar üniform radyasyon durumunda geleneksel MPPT metotlarından Perturb and Observe (P&O) algoritmasının HC ve IC algoritmalarına göre daha iyi performansa sahip olduğunu göstermektedir. Üniform radyasyon altında sunulan algoritmaların %3-4 hata ile MPPT noktasını yakalama yeteneğine sahip olduğunu görülmektedir. Fakat parçalı gölgelenme altında gölgelenme miktarına bağlı olarak hata miktarı %10’un üzerine çıkabilmektedir. Parçalı gölgelenme durumunda HC algoritmasının daha iyi performansa sahip olduğu gözlemlenmiştir.

Bu çalışmada elde edilen sonuçlar sepic konvertör yapısı kullanılarak değerlendirilmiştir. Gelecek çalışmalarda farklı konvertör topolojilerinin MPPT performansı üzerindeki etkileri değerlendirilerek, algoritma performansları deneysel olarak incelenecektir.

7. Destekleyen Kuruluşlar

Bu çalışma TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı (BİDEB) tarafından yürütülen, 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı 2021 yılı 2 dönem kapsamında 1919B012111890 numaralı proje ve Sivas Cumhuriyet Üniversitesi Bilim Araştırma Birimi (CUBAP) tarafından HAMYO003 numaralı proje kapsamında desteklenmiştir.

8. Ekler

A.1.

Hücre Tipi	Silikon Film	Mono Kristal	Poli Kristal	Üç-Janksiyonlu amorf
Ns	40	72	72	22
E_g (eV) at 25 °C	1.12	1.12	1.14	1.6

9. Referanslar

- Araújo, N. M. F. T. S., Sousa, F. J. P., & Costa, F. B. (2020). Equivalent Models for Photovoltaic Cell – a Review. *Revista de Engenharia Térmica*, 19(2), 77. <https://doi.org/10.5380/reterm.v19i2.78625>
- Aygül, K., Cikan, M., Demirdelen, T., & Tumay, M. (2019). Butterfly optimization algorithm based maximum power point tracking of photovoltaic systems under partial shading condition. *Energy Sources, Part A: Recovery, Utilization and Environmental Effects*, 00(00), 1–19. <https://doi.org/10.1080/15567036.2019.1677818>
- Bendib, B., Belmili, H., & Krim, F. (2015). A survey of the most used MPPT methods: Conventional and advanced algorithms applied for photovoltaic systems. *Renewable and Sustainable Energy Reviews*, 45, 637–648. <https://doi.org/10.1016/j.rser.2015.02.009>
- Chao, K. H., Lin, Y. S., & Lai, U. D. (2015). Improved particle swarm optimization for maximum power point tracking in photovoltaic module arrays. *Applied Energy*, 158, 609–618. <https://doi.org/10.1016/j.apenergy.2015.08.047>
- Ciulla, G., Io Brano, V., di Dio, V., & Cipriani, G. (2014). A comparison of different one-diode models for the representation of I-V characteristic of a PV cell. *Renewable and Sustainable Energy Reviews*, 32, 684–696. <https://doi.org/10.1016/j.rser.2014.01.027>
- Daraban, S., Petreus, D., & Morel, C. (2013). A novel global MPPT based on genetic algorithms for photovoltaic systems under the influence of partial shading. *IECON Proceedings (Industrial Electronics Conference)*, 1490–1495. <https://doi.org/10.1109/IECON.2013.6699353>
- Falin, J. (2008). Designing DC/DC Converters based on SEPIC Topology. *Texas Instruments Documents*.
- Femia, N., Petrone, G., Spagnuolo, G., & Vitelli, M. (2005). Optimization of perturb and observe maximum power point tracking method. *IEEE Transactions on Power Electronics*, 20(4), 963–973. <https://doi.org/10.1109/TPEL.2005.850975>
- Femia, N., Petrone, G., Spagnuolo, G., & Vitelli, M. (2009). A technique for improving P&O MPPT performances of double-stage grid-connected photovoltaic systems. *IEEE Transactions on Industrial Electronics*, 56(11), 4473–4482. <https://doi.org/10.1109/TIE.2009.2029589>
- Gosumbonggot, J., Nguyen, D. D., & Fujita, G. (2018). Partial Shading and Global Maximum Power Point Detections Enhancing MPPT for Photovoltaic Systems Operated in Shading Condition. *Proceedings - 2018 53rd International Universities Power Engineering Conference, UPEC 2018*, 1, 1–6. <https://doi.org/10.1109/UPEC.2018.8541880>
- Ishaque, K., & Salam, Z. (2013). A deterministic particle swarm optimization maximum power point tracker for photovoltaic system under partial shading condition. *IEEE Transactions on Industrial Electronics*, 60(8), 3195–3206. <https://doi.org/10.1109/TIE.2012.2200223>
- Ishaque, K., Salam, Z., & Syafaruddin. (2011). A comprehensive MATLAB Simulink PV system simulator with partial shading capability based on two-diode model. *Solar Energy*, 85(9), 2217–2227. <https://doi.org/10.1016/j.solener.2011.06.008>

- Jiang, L. L., Maskell, D. L., & Patra, J. C. (2013). A novel ant colony optimization-based maximum power point tracking for photovoltaic systems under partially shaded conditions. *Energy and Buildings*, 58, 227–236. <https://doi.org/10.1016/j.enbuild.2012.12.001>
- Kim, T. Y., Ahn, H. G., Park, S. K., & Lee, Y. K. (2001). A novel maximum power point tracking control for photovoltaic power system under rapidly changing solar radiation. *IEEE International Symposium on Industrial Electronics*, 2, 1011–1014. <https://doi.org/10.1109/isie.2001.931613>
- Koad, R. B. A., Zobaa, A. F., & El-Shahat, A. (2017). A Novel MPPT Algorithm Based on Particle Swarm Optimization for Photovoltaic Systems. *IEEE Transactions on Sustainable Energy*, 8(2), 468–476. <https://doi.org/10.1109/TSTE.2016.2606421>
- Lee, J. H., Bae, H. S., & Cho, B. H. (2007). Advanced incremental conductance MPPT algorithm with a variable step size. *EPE-PEMC 2006: 12th International Power Electronics and Motion Control Conference, Proceedings*, V, 603–607. <https://doi.org/10.1109/EPEPEMC.2006.283227>
- Mohanty, S., Subudhi, B., & Ray, P. K. (2016). A new MPPT design using grey Wolf optimization technique for photovoltaic system under partial shading conditions. *IEEE Transactions on Sustainable Energy*, 7(1), 181–188. <https://doi.org/10.1109/TSTE.2015.2482120>
- Radjai, T., Rahmani, L., Mekhilef, S., & Gaubert, J. P. (2014). Implementation of a modified incremental conductance MPPT algorithm with direct control based on a fuzzy duty cycle change estimator using dSPACE. *Solar Energy*, 110, 325–337. <https://doi.org/10.1016/j.solener.2014.09.014>
- Rezk, H. (2016). A comprehensive sizing methodology for stand-alone battery-less photovoltaic water pumping system under the Egyptian climate. *Cogent Engineering*, 3(1), 1–12. <https://doi.org/10.1080/23311916.2016.1242110>
- Rezk, H., & Dousoky, G. M. (2016). Technical and economic analysis of different configurations of stand-alone hybrid renewable power systems – A case study. *Renewable and Sustainable Energy Reviews*, 62, 941–953. <https://doi.org/10.1016/j.rser.2016.05.023>
- Tey, K. S., & Mekhilef, S. (2014). Modified incremental conductance MPPT algorithm to mitigate inaccurate responses under fast-changing solar irradiation level. *Solar Energy*, 101, 333–342. <https://doi.org/10.1016/j.solener.2014.01.003>
- Xiao, W., & Dunford, W. G. (2004). A modified adaptive hill climbing MPPT method for photovoltaic power systems. *PESC Record - IEEE Annual Power Electronics Specialists Conference*, 3, 1957–1963. <https://doi.org/10.1109/PESC.2004.1355417>
- Xu, H., Liu, X., & Su, J. (2017). An improved grey Wolf optimizer algorithm integrated with Cuckoo Search. *Proceedings of the 2017 IEEE 9th International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, IDAACS 2017*, 1(61602162), 490–493. <https://doi.org/10.1109/IDAACS.2017.8095129>
- Zaki Diab, A. A., & Rezk, H. (2017). Global MPPT based on flower pollination and differential evolution algorithms to mitigate partial shading in building integrated PV system. *Solar Energy*, 157, 171–186. <https://doi.org/10.1016/j.solener.2017.08.024>

Steganography Approach Based on the Least Significant Bit Technique

Salman Yakut ^{*1} 

¹ Department of Software Engineering, İnönü University, Malatya, Turkey

(selman.yakut@inonu.edu.tr)

Abstract — Information security is one of the important problems of the modern age and the digitalizing world. Steganography, on the other hand, is a secure data transmission method that forms an important part of information security. Steganographic methods basically aim to send the data to be transmitted on a carrier message without being noticed. Many steganography techniques are available, depending on the type of embedded and carrier data. As a steganography technique, it was initially used with primitive methods, but today more modern methods are used. LSB method is a steganography technique that is used in different data types and has a widespread use. In this article study, a new approach based on LSB bits is proposed. In the classical LSB method, the data carrier to be transmitted is placed in the least significant bits of the message. In this proposed method, the message to be transmitted is carried without any change on the LSB bits of the carrier data. The bits of this message and the bits of the image are passed to the XOR process and the result data is produced. This data is transmitted from a separate source to the sender, and the original data is produced by XOR'ed with the relevant bits. In this approach, the hidden message cannot be detected because there is no change on the bits of the carrier message. Thus, the transmitted data cannot be detected by steganographic methods such as histogram analysis and visual analysis. In addition, since it does not make any changes on the original bits, there is no distortion on the carrier image. However, the proposed method imposes an additional burden on the system as the result string is sent to the receiver.

Keywords: *Steganography, LSB, confidential transmission of data.*

1. Introduction

Information security is one of the important problems of today's digitalized world ¹. Many methods, protocols, approaches... have been proposed and solutions have been presented to ensure information security. These methods and similar structures used to ensure information security are generally examined under the science of ². An important part of information security, which has a comprehensive structure, is steganography ².

Steganography is a secure data transmission method that forms an important part of information security. Steganographic methods basically aim to send the data to be transmitted on a carrier message without being noticed ³. While steganography was performed with primitive methods in the past, more modern methods have been proposed today. However, especially the multitude of digital sources, the transmission and sharing of these data makes these systems even more important ⁴.

steganography techniques are available, depending on the type of embedded and carrier data. It can be used for data types such as image, audio, video, text as carrier data type [5]. The message to be conveyed confidentially can be any of these data types. Different methods are used for embedding and these methods form the most important part of steganographic methods. Different derivatives in these methods are used according to the data types used.

steganography technique that is used in different data types and has a widespread use [4], [6]. It has an adaptive structure and usage for almost all data types. In the classical LSB method, the bits of the message to be transmitted are replaced with the least significant bits of the carrier message [7]. Then the carrier message is transmitted to the receiver over an insecure channel [6]. Thus, when the carrier message is delivered to the receiver, the secret message is also transmitted.

When only the least significant bits of the carrier data are changed, little effect is expected on this data [8]. However, with advanced stegoanalysis techniques, it is possible to detect the existence of the message by third parties and to obtain its content. This situation is an important problem for the security of the message to be transmitted confidentially. As a result, the data to be transmitted becomes vulnerable to attacks. However, a certain deterioration is expected in these methods and the success of the proposed method is measured according to the low rate of this deterioration.

Many steganography methods have been proposed in the literature. One of the commonly used methods is the LSB method [9]. In this method, the least significant bits of the carrier message and the bits of the transmitted message are replaced [7], ¹⁰. This process can be done on gray-level images as well as on color images ⁶. It includes different techniques on different planes used in these proposed methods ^{11 12 13}. Histogram-based methods are another approach ¹⁴. It is also used to distribute the transmitted data over more than one carrier message ¹⁵. Another approach is to distribute the transmitted message on the carrier message with chaotic functions ¹⁶. It is also possible to design steganographic systems by ⁸. It is also common to use ⁸.

Steganography method proposed in this study, no changes are made to the bits of the carrier message. The message to be transmitted secretly is converted to binary format and XORed with the least significant bits of the carrier message. The resulting string in binary format and the carrier message obtained as a result of this process are transmitted to the receiver. Since no changes are made on the least significant bits of the carrier message, the existence and content of the message to be transmitted cannot be detected. Even if the transmitted result matrix is obtained by third parties, it does not make any sense on its own, so it does not create any security vulnerability. Thus, confidential data transmission is carried out without making any changes to the carrier message.

The chapters in this article are as follows, respectively. In the second part, the proposed method and details about this method are given. In the third chapter, the evaluation and analysis of the proposed method were mentioned. In the last part, the results of the proposed method were evaluated.

2. Recommended Method

In this article study, a new approach based on LSB bits is proposed. The general structure of the proposed method is given in Figure 1. In this method, the secret message is transmitted without any change on the LSB bits of the carrier message. The message to be transmitted is first converted to binary format. Then, these bits are XORed with the least significant bits of the carrier image. The bits obtained from this operation are taken as result data. The carrier message and the resulting string are transmitted to the receiver through separate channels. On the receiver side, the result string and the least significant bits of the carrier message are XORed to obtain the original data to be transmitted.




Figure 1. General structure of the proposed Method

The values of the carrier message are given in Table 1. The least significant bits in the relevant table were used and no changes were made to these bits.

Table 1. Original bits of carrier image

	1	2	3	4	5	6	7	8	9	10	11
1	225	226	225	226	227	228	228	228	227	229	228
2	224	225	225	226	227	228	227	228	228	228	228
3	224	225	226	226	227	228	228	227	227	229	228
4	224	225	225	228	227	226	228	228	228	229	228
5	222	225	224	226	226	228	227	228	228	228	228
6	223	224	224	226	226	226	227	227	228	228	228
7	224	224	225	226	226	226	226	226	227	228	228
8	223	223	224	225	226	226	227	227	227	228	226
9	224	224	224	226	226	227	228	228	229	227	228
10	224	224	225	225	226	228	227	228	229	229	229

3. Evaluation of the Proposed Method and Results

Steganographic systems are used three basic parameters: capacity, robustness and imperceptibility. Capacity; the amount of data that can be transmitted on the carrier, the robustness; minimum distortion in the picture, imperceptibility; is expressed as not being noticed while the message is being transmitted. The evaluation of the proposed methods is made by considering these parameters. In either of these parameters there is improvement, while in the other, losses are usually given. However, in the proposed method, there is no limitation in terms of capacity as confidential data transmission is carried out without any change on the carrier bits. Data of any size can be transferred without any loss or distortion on the transmitted and carrier message.

Steganalysis techniques are used to detect the presence and content of confidential data transmission. With these methods, it is aimed to detect the existence of confidential communication first and then to determine the content of the message. Methods such as histogram analysis and visual analysis are used to detect changes on the carrier message. Detection of confidential data transmission is an important security problem on the security of the message to be transmitted.

Table 2. Data transport bits for the proposed method

	1	2	3	4	5	6	7	8	9	10	11
1	1	0	1	0	1	0	0	0	1	1	0
2	0	1	1	0	1	0	1	0	0	0	0
3	0	1	0	0	1	0	0	1	1	1	0
4	0	1	1	0	1	0	0	0	0	1	0
5	0	1	0	0	0	0	1	0	0	0	0
6	1	0	0	0	0	0	1	1	0	0	0
7	0	0	1	0	0	0	0	0	1	0	0
8	1	1	0	1	0	0	1	1	1	0	0
9	0	0	0	0	0	1	0	0	1	1	0
10	0	0	1	1	0	0	1	0	1	1	1

In the proposed approach, the least significant bits of the carrier image are used for transport. With this method, the data is transmitted without any change on the relevant bits. The carry bits are given in Table 2. Thus, the presence and content of the message to be transmitted was prevented from being detected. Since detecting the secret message transmitted in confidential data transmission is a security weakness, this data should not be detected by steganalysis methods such as histogram analysis and visual analysis. Therefore, these messages cannot be detected with the proposed method.

An important advantage of the proposed method is that it does not cause any negative effects on the quality of the picture. In methods such as LSB, which are widely used in confidential data transmission, losses occur on the picture as the bits of the carrier message are replaced with the bits of the secret message. These losses cause various distortions in the picture. In the proposed method, since the carrier

does not make any changes on the least significant bits of the message, no loss or corruption occurs on the original bits of this message.

The data, called the result array, is produced in the proposed method. Sending this data from a secure source to the receiver imposes an additional burden on the system. However, since this data alone does not make sense, it does not create any security weakness in the proposed method. In addition, an additional key data is used in many approaches in the literature.

4. Conclusion

Information security is one of the great challenges of today's digital world. One of the important problems of information security is steganography. Steganography is the confidential transmission of any message intended to be transmitted on another carrier message. Many steganography techniques are available, depending on the type of transmitted and carrier data. While steganography was initially made with primitive methods, modern methods are used today. LSB method is a steganography technique used in various data types. In this article, a new approach based on LSB bits is proposed. In the classical LSB method, the data to be transmitted confidentially is replaced with the least significant bits of the carrier message. In the proposed method, the message to be transmitted is carried without any change in the LSB bits of the carrier data. The transmitted bits and the bits of the carrier are XORed and the result data is produced. This data is transmitted to the receiver and the output data is XORed with the corresponding bits. In this approach, message detection is not possible as the bits are not changed. Therefore, in the proposed method, the transmitted data is not detected by steganographic techniques such as histogram analysis and visual analysis. In addition, in this method, there is no distortion in the image since there is no change in the carrier bits. However, the proposed method imposes an additional burden on the system as the result array is sent to the receiver.

5. Bibliography

- Prasad S, Pal AK. (2017) An RGB colour image steganography scheme using overlapping block-based pixel-value differencing. *R Soc Open Sci.* 4(4). doi:10.1098/rsos.161066
- Nashat D, Mamdouh L. (2019) An efficient steganographic technique for hiding data. *J Egypt Math Soc.* 27(1):57. doi:10.1186/s42787-019-0061-6
- Ravazı N. (2017) *Lsb Steganografi Yönteminde Yüksek Kapasiteli Veri Gizleme.*
- Pak C, Kim J, An K, Kim C, Kim K, Pak C. (2020) A novel color image LSB steganography using improved 1D chaotic map. *Multimed Tools Appl.* 79(1-2):1409-1425. doi:10.1007/s11042-019-08103-0
- Mstafa RJ, Younis YM, Hussein HI, Atto M. (2020) A New Video Steganography Scheme Based on Shi-Tomasi Corner Detector. *IEEE Access.* 8:161825-161837. doi:10.1109/ACCESS.2020.3021356
- Kordov K, Zhelezov S. (2021) Steganography in color images with random order of pixel selection and encrypted text message embedding. *PeerJ Comput Sci.* 7:e380. doi:10.7717/peerj-cs.380
- Solak S, Altınışık U. (2019) Steganografi için yeni bir yaklaşım: (SED-LSB) LSB ile şifrelenmiş verilerin bit kaydırma işlemi. *Bilişim Teknol Derg.* Published online January 31, 75-81. doi:10.17671/gazibtd.435437
- Wahab OFA, Khalaf AAM, Hussein AI, Hamed HFA. (2021) Hiding Data Using Efficient Combination of RSA Cryptography, and Compression Steganography Techniques. *IEEE Access.* 9:31805-31815. doi:10.1109/ACCESS.2021.3060317
- Çelik H, Doğan N. (2022) K-En Az Anlamlı Bitlere Dayalı Kaotik Bir Harita Kullanan Renkli Görüntü Steganografisi. *J Polytech.* 0900:0-2. doi:10.2339/politeknik.1008594
- Macit HB, Koyun A. (2020) A New Imperceptible Steganography Method for Grayscale Images. *Mühendislik Bilim ve Tasarım Derg.* 8(2):357-365. doi:10.21923/jesd.537183

- Sarı Z, Yıldırım M. 202(2) Uzamsal Alan Görüntü Steganografisi için Blok Veri Gizlemede Kanal Seçimi. *Eur J Sci Technol.* (34):305-310. doi:10.31590/ejosat.1081746
- Karakış R, Gürkahraman K, Çiğdem B, Öztoprak I, Topaktaş AS. (2021) Bölütlenen beyin bölgelerinin tıbbi görüntü steganografisi için değerlendirilmesi. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Derg.* 36(4):2301-2314. doi:10.17341/gazimmfd.753989
- Durdu A. (2021) A new data hiding method with high capacity, low distortion, and reversible loss that hides 24-bit color image into 24-bit color image (YKKG). *Pamukkale Univ J Eng Sci.* 27(2):96-113. doi:10.5505/pajes.2020.50215
- Kurnaz H, Konyar MZ, Sondaş A. (2020) Yakın Histogramlar Temelli Yeni Bir Hibrit Veri Gizleme Yöntemi. *Eur J Sci Technol.*; (18):683-694. doi:10.31590/ejosat.695672
- Yağcıoğlu H, Sondaş A. (2021) Çoklu Görsel Nesnelere Veri Gizleme (Steganografi).;4(1):1-5. <http://dergipark.org.tr/koufbd>
- Akyüz D, Kasapbaşı MC. (2021) Yeni Kaotik Video Şifreleme Metodu. *Haliç Üniversitesi Fen Bilim Derg.* 4(1):25-40. doi:10.46373/hafebid.858834

Deep Learning for Mobile Robot Position Prediction in RSSI Based Positioning Systems

Fatih Okumuş*¹ 

¹Department of Software Engineering, Inonu University, Malatya, Türkiye

(fatih.okumus@inonu.edu.tr)

Abstract— There is an increasing demand for autonomous robots for indoor logistics in industrial production areas. It is critical that autonomous logistics systems developed in response to this demand are flexible, reliable, and easily integrated. The positioning and navigation system must work accurately and precisely for flexible and safe autonomous driving. This study proposes a high-precision positioning system for autonomous robots used for logistics purposes in indoor areas. For the positioning system, a tag reading model was created by using RFID technology. Then, a signal map containing the RSSI values of the RFID signals read from the tags was created, and the CNN + LSTM model was constructed by learning from this map and making a location estimation. According to the observations in the experiments carried out in the laboratory, the proposed system produced better results than the traditional methods.

Keywords : *Robot localization, RSSI, CNN, LSTM, Deep Learning*

1.Introduction

There is an increasing demand for the autonomous use of mobile logistics robots in industrial enterprises, especially logistics (Okumuş et al., 2020). These robots must have an advanced positioning system to be guided autonomously (Guo et al., 2018). Using mechanical or wireless equipment, positioning systems used in indoor industrial logistics can detect the robot's position inside the building. Therefore, wireless positioning systems have come to the forefront for industrial enterprises that need flexible and reflective navigation.

Special equipment such as GPS, RFID, Bluetooth, Wi-Fi, and Lidar is used in wireless positioning systems (OKUMUŞ, 2020). In addition, some methods estimate position using motion information obtained from wheel turns. These studies were mainly developed using information from RSSI (Signal Strength Indicator) (Wattananavin et al., 2020). Indoors, RSSI data is often used because of the complexity of managing positioning systems with wheel movements and because global systems such as GPS have insufficient signal strength.

Calculating position information with the RSSI technique indoors can become complicated due to the irregularity of signals and undesirable interactions of metallic substances in the environment. RSSI variation occurs prominently in environments where mobile assets are present (Booranawong et al., 2019). In this case, positioning systems based entirely on RSSI fail significantly. By supporting RSSI-based positioning systems with different methods and hardware, forecasting methods and application models need to be improved (Jondhale et al., 2017).

In positioning systems, estimation methods such as Min-Max, trilateration, WCL, and REWL are generally applied for position detection with RSSI. Studies have shown that the Min-Max method gives better results in accurate location detection than other methods and achieves the same success in environments with moving assets (Wattananavin et al., 2020). These estimation methods are beneficial in terms of being optimal. However, at the point of improving the positioning error, it is impossible to exceed a specific capacity with the improvements to be made in these methods.

The motivation of this study is to make precise position estimations for mobile robots using deep learning methods with RSSI values obtained from wireless devices used in industrial environments. In the deep learning phase, CNN and LSTM models, which are very successful in recommendation engines, were used. Due to their powerful ability to model sequential data and capture temporal dependencies in data, CNN and LSTM have been successfully applied in many applications (Jingwei Song et al., 2022; Ma, 2021; Poullose, 2021; Xu et al., 2020). Furthermore, the study created an RFID-based environment model to minimize the factors affecting the reading to increase positioning accuracy.

In order to observe the success of the proposed system, a laboratory environment was designed, and training and test data, including RSSI and factual location information, were produced from this environment. The data obtained in laboratory studies show that an average error rate of 1.52 cm occurs in location determination. This value was compared with the value obtained by traditional methods, and it was determined that the proposed method produced more effective results than traditional methods.

2. Proposed Positioning System

The proposed positioning system proposes an environment model for precise position measurement. The CNN + LSTM method uses RSSI values obtained by RFID readers and tags for location estimation.

2.1. Environment Model:

Distortion of the RFID signal can affect the location's detection, manipulating the positioning system's correct operation. Metal objects in the environment, Wi-Fi access points, radio frequency emitting devices, signal absorbing liquids, people on the move, etc. prevent the RFID signal from being read correctly. In addition, weak antenna power and wrong tag selection increase the reading error. No matter how robust the position estimation algorithm is, all these factors seriously affect reading accuracy. For this reason, a reading model that reduces environmental factors has been created to increase the study's sensitivity. According to this proposed environment model, RFID tags are placed on the floor in the form of a grid with the principle of neighborhood at fixed intervals. An RFID reader is mounted on the mobile robot, and four directional RFID antennas are connected to this reader so that it can read in all directions. The environment model is simulated in Figure 1.




Figure 1. Environment model for the proposed system

The distance between each label is determined by a fixed of 1.2m. Since the distance between the tags is determined with a fixed value, the robot's position can be measured more precisely by reading multiple tags using neighborhood relations. The reader can receive signals from multiple tags at the same time. However, the first three tags with the highest RSSI value are used among the tags read. In addition, these first three tags must be adjacent to each other.

In the proposed environment model, the tags were placed on the ground to provide a directional reading of the antennas. The effect of foreign substances and foreign RF signals in the environment was reduced. Since the location determination will be made in real time, the robot must be able to observe all four directions at the same time. In the literature, some studies have been done for the antennas to be able to read all directions with a stepper motor to observe all directions simultaneously. However, the rotation speed directly affects the reading speed depending on the motor's rotational speed. In addition, it was observed that when the rotation speed is increased, it negatively affects the propagation of the signal. For this reason, four antennas are used so the robot can see all the tags around it.

The tag type is also essential so that the RSSI can be obtained more clearly. Since the labels will be placed on the floor, labels that can be read on concrete or tile surfaces are used. For the antennas to read the labels better, they must be inclined towards the ground. The tilt angle is calculated according to the area that the robot can see at the same time.

2.2. Position Estimation with Min-Max Method (Traditional Method):

The Min-Max method uses RSSI values from three nodes (n_1, n_2, n_3) as references. The distance of the RFID antenna to these tags, d_1, d_2 and d_3 , is calculated according to the incoming RSSI data. This distance is relative to the signal strength due to various environmental factors and may not be known precisely. However, the range of distance can be estimated. Before applying the Min-Max method, it is necessary to determine the nodes to be taken as reference and convert the RSSI data from these nodes into distance information. Since many tags can be read when the robot reads simultaneously, the first three tags with the highest RSSI value are selected as the reference nodes. An experienced conversion table converts these RSSI values to distance information. In order to create this conversion table, RSSI data obtained at locations where the distance of the tags to the antenna is known in the real environment is used. Figure 2 shows how the location estimation is performed with the Min-Max method.




Figure 29. Location estimation with Min-Max method

2.3. Position Estimation with CNN+LSTM:

CNN Model: This artificial neural network architecture is designed specifically for categorizing images. The CNN model's ability to provide precise categorization results is both its most alluring and distinctive quality. This model is employed for face identification, object detection, image categorization, and image recognition. Data characteristics for the CNN model are derived via the local link and layer-by-layer processing. The synthesis of global information is accomplished by full layer connection. A convolutional layer, a pooling layer, and a fully connected layer make up the CNN model (Poulose, 2021).

LSTM Model: An improved form of an RNN, the LSTM model, can train to make predictions about sequences. The model resolves the gradient disappearance and gradient burst issues in RNN. The LSTM model's distinct characteristics demonstrate that it is appropriate for handling long-term sequence data and resolving long-term dependency. Three gates that regulate the memory unit make up the core of the LSTM network. The input gate (IG), the output gate (OG), and the forget gate are the names of these gates (FG). In addition, the LSTM neural network has elements called gates that control the selective

transit of data. The network ignores the data entirely if the sigmoid function returns a value of 0. The network permits the data to pass when the output is 1 (Poulouse, 2021).

In the proposed method, it is aimed to increase efficiency in system performance by combining CNN and LSTM models. In this model, during the training phase, the RSSI data map is first trained with the CNN model, and then the trained data is retrained with LSTM. Thus, a weight matrix is created. When it comes to the testing phase, RSSI test data is firstly predicted with CNN and then predicted with LSTM. Finally, the estimated location is obtained. Conv2D convolution layer and MaxPooling2D pool layer are used in CNN because it is studied on a two-dimensional data. Following these operations, the CNN model uses a fully connected layer (Dense) that extracts the properties of the data as a one-dimensional vector array. The LSTM model applied after the CNN model uses a fully connected layer and returns position values. In Figure 3, the setup of deep learning stages consisting of CNN and LSTM is given.




Figure 3. Setup of deep learning methods for location estimation

3. Experimental Results

Turtlebot 2 was used to test the proposed method in a laboratory environment. RFGate UPM Web 208-3 model RFID tags are placed on the floor at 120 cm intervals. These labels have been preferred because they have the feature of reflecting the signal on the concrete floor or in the concrete. RFGate RGR400 model RFID reader with RSSI support is mounted on the robot to read RFID tags. In order for the robot to read all the tags around it, four ANT-263 12 DBI UHF Circular model RFID antennas are connected to the ports of the reader and placed on the robot facing the ground at a 30-degree angle. To control the robot, the Raspberry Pi 3 circuit was connected and the Ubuntu Mate operating system was installed. An example view from the laboratory environment is shown in Figure 4.




Figure 4. Real environment adaptation of the proposed model

In order to test the operation of the position detection algorithm, the robot was positioned on the ground in Figure 4 at points with known coordinates in a two-dimensional plane and its estimated position was determined. The error was measured by the Euclidean distance between the estimated location and the actual location. In this way, the results in Table 1 were obtained by making measurements at different locations for 900 training data and 100 test data under the same conditions in a 360 cm² area.

Table 6. Amount of Errors Occurring in the Positioning System in the Tests

Test Number	d_1 (cm)	d_2 (cm)	d_3 (cm)	Error of Min-Max (cm)	Error of CNN+LSTM (cm)
1	69,11	126,71	51,15	26,68	2,45
2	84,17	85,58	82,73	12,72	1,32
3	54,70	103,31	78,18	4,47	2,06
4	99,72	24,18	110,02	6,40	0,84
5	89,81	45,45	97,49	8,06	1,23
6	50,44	118,59	72,00	20,09	2,87
...	...	...	...	...	...
100	65,45	114,73	61,68	19,69	0,45
Average	95,50	91,77	89,62	12,26	1,52

As can be seen in Table 1, the average error amount was measured as 12.26 cm with the Min-Max method as a result of 100 test data. With the proposed deep learning method, the average error amount was measured as 1.52 cm. These values show that very successful results were obtained in the estimated position measurement obtained with CNN and LSTM learning models compared to traditional methods.

4. Conclusions

Positioning and real-time navigation are among the most important problems in indoor autonomous robot management in industrial enterprises. In the study, a high precision positioning system is proposed for mobile robots working indoors. In the developed position estimation system, CNN and LSTM learning models are used to make position estimation with RSSI values generated from wireless devices. The problem of RSSI measurement being affected by environmental factors and causing false readings has been focused on and an environment model has been proposed to reduce these factors as much as possible. The proposed environment model is based on the reading of RFID tags placed on the floor in the form of a grid at certain intervals, by means of RFID antennas on the robot, which are mounted inclined towards the ground. In the position estimation, an average error rate of 1.52 cm was obtained

as a result of laboratory experiments. This ratio is a better result compared to traditional systems that make position estimation such as Min-Max. Laboratory tests reveal the effectiveness and success of the system we propose. This system, which is offered as a solution proposal for autonomous vehicle management in industrial enterprises, can be used in hospitals, airports, stores and many other sectors.

References

- Booranawong, A., Sengchuai, K., & Jindapetch, N. (2019). Implementation and test of an RSSI-based indoor target localization system: Human movement effects on the accuracy. *Measurement: Journal of the International Measurement Confederation*, 133, 370–382. <https://doi.org/10.1016/j.measurement.2018.10.031>
- Guo, S., Fang, T. T., Song, T., Xi, F. F., & Wei, B. G. (2018). Tracking and localization for omnidirectional mobile industrial robot using reflectors. *Advances in Manufacturing*, 6(1), 118–125. <https://doi.org/10.1007/s40436-018-0216-y>
- Jingwei Song, Mitesh Patel, & Ghaffari, M. (2022). Fusing Convolutional Neural Network and Geometric Constraint for Image-Based Indoor Localization. *IEEE Robotics and Automation Letters*, 7(2), 1674–1681. <https://doi.org/10.1109/LRA.2022.3140832>
- Jondhale, S. R., Deshpande, R. S., Walke, S. M., & Jondhale, A. S. (2017). Issues and challenges in RSSI based target localization and tracking in wireless sensor networks. *International Conference on Automatic Control and Dynamic Optimization Techniques, ICACDOT 2016*, 594–598. <https://doi.org/10.1109/ICACDOT.2016.7877655>
- Ma, Y. (2021). A pilot study on robotic puncture system. March 2020, 1–10. <https://doi.org/10.1002/rcs.2247>
- OKUMUŞ, F. (2020). Bina içi lojistik faaliyetler için bulut tabanlı otonom robot yönetimi. https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=wf-FPgY-5qjHEzEoOgvMs4BvlCrP0kdnV_eIwbTMfwJqrDdJeju73mBiXuKfJ7FB
- Okumuş, F., Dönmez, E., & Kocamaz, A. F. (2020). A Cloudware Architecture for Collaboration of Multiple AGVs in Indoor Logistics: Case Study in Fabric Manufacturing Enterprises. *Electronics*, 9(12), 2023. <https://doi.org/10.3390/electronics9122023>
- Poulose, A. (2021). *Hybrid Deep Learning Model Based Indoor Positioning Using Wi-Fi RSSI Heat Maps for Autonomous Applications*.
- Wattananavin, T., Sengchuai, K., Jindapetch, N., & Booranawong, A. (2020). A Comparative Study of RSSI-Based Localization Methods: RSSI Variation Caused by Human Presence and Movement. *Sensing and Imaging*, 21(1), 31. <https://doi.org/10.1007/s11220-020-00296-1>
- Xu, M., Wang, L., Ren, J., & Poslad, S. (2020). Use of LSTM Regression and Rotation Classification to Improve Camera Pose Localization Estimation. 6–10. <https://doi.org/10.1109/ASID50160.2020.9271762>

ADDIM GƏRGİNLİYİ TƏHLÜKƏSİ VƏ ONDAN ETİBARLI MÜHAFİZƏ

Elşad Səfiyev , Elbrus Əhmədov , Sona Rzayeva 

Energetika fakültəsi, Azərbaycan Dövlət Neft və Sənaye Universiteti, Bakı, Azərbaycan

(elshad.safiyev@asoiu.edu.az , elbrus.ahmedov@asoiu.edu.az , sona.rzayeva@asoiu.edu.az)

Annotasiya— Məqalədə addım gərginliyinin yaranmasının müxtəlif yollarına (ildırım vurması, yüksək gərginlik xəttinin qırılması və s.) baxılmış, onun insana təsiri və bu fiziki hadisədən mühafizənin müxtəlif üsulları, o cümlədən təhlükəli zonanın tərk edilməsi yolu göstərilmişdir. Addım gərginliyinin nəzəri hesabı verilmiş və onun real hadisə ilə müqayisə olunmasına – 20 kA ildırım cərəyanında addım gərginliyinin məsafədən asılılığına – diqqət yetirilmişdir.

Açar sözlər: *addım gərginliyi, potensiallar fərqi, ildırım vurması, torpaqlama, xüsusi elektrik müqaviməti, təhlükəli zona*

Abstract— This article discusses different types of step voltage occurrence (lightning strike, high-voltage line break, etc.), its impact on a person, and some ways to protect against it. The method of avoiding the danger zone is shown. A theoretical calculation of the step voltage and its comparison with a real event, i.e. with the dependence of the step voltage at a lightning current at 20 kA, on the distance.

Keywords: *step voltage, potential difference, lightning strike, grounding, electrical resistivity, hazardous area.*

1. Giriş

Addım gərginliyi torpağın iki hissəsi arasında potensiallar fərqidir. İldırımın yerə vurması (şəkil 1), yüksək gərginlik xəttinin qırılaraq yerə düşməsi (şəkil 2) və digər səbəblərdən (məsələn şəkil 3 və 4) torpaq hissələri arasında yaranan addım gərginliyinin çox təhlükəli olmasına baxmayaraq bu fiziki effekt kifayət qədər öyrənilməyib. Torpağın xüsusi elektrik müqaviməti sıfıra bərabər olmadığı üçün göstərilən hər bir halda cərəyan torpaqda “axaraq” yüksək potensiallı zona yaradır. Əgər torpaq üzərində keçirici olarsa, elektrik dövrəsi yarana bilər. Belə keçirici olaraq torpaq üzərində olan insan da ola bilər, bu halda cərəyan onun bir ayağına keçərək digərindən çıxır və insan bədənini “elektrik yükünə” çevirir. Bu isə çox təhlükəlidir, çünki yüksək gərginlik əzələlərin iflicinə səbəb ola bilər. Nəticədə insan əlləri üstə yerə yığıla bilər və ildırım cərəyanının sonrakı boşalmalarında cərəyan ürək nahiyyəsindən keçərək onun dayanma riskini artırır. İnsanın başı yerə toxunduqda isə mərkəzi əsəb sisteminin dönməz zədələnmə riski yüksəlir [1-4].

Şəkil 5-də solda addım gərginliyinin paylanma modelini görmək olar. İldırımın vurması ilə cərəyan (dI) torpağa istiqamətlənir və o torpağın müqavimətinin şerti radiusu boyunca axaraq gərginliyini (dU) artırır. Radiuslar arası potensiallar fərqi – addım gərginliyidir. İldırım cərəyanı çox olduqca, gərginlik və ölüm potensialı da yüksək olur. Təcrübə göstərir ki, cərəyanın yerə daxil olduğu yerdən 1 m məsafədə potensial 68%, 10 m məsafədə 92% azalır. 20 m məsafədə isə yer səthindəki nöqtələrdə potensial praktiki olaraq sıfıra düşür.


Şək.5-in sağ tərəfində addım gərginliyinin təsiri sxematik olaraq göstərilir, o yükü ayaqdan keçməklə yaratdığı üçün (oxla göstərildiyi kimi) addım gərginliyi adlanır. Adi ildırım on min amperlərlə cərəyan daşıyır (I_{1-2}), nəticədə potensiallar fərqi ($U_1 - U_2$) on min voltdan da çox ola bilər. İki nöqtə arasında (ayaqlar arasında) potensiallar fərqi olduğundan, insan bədənini kompleks elektrik müqaviməti olan elektrik yükü rolunu oynayır. Bu halda bədənə keçən cərəyan I_b ayaqların və bədən müqavimətlərindən (R_a və R_b) asılı olur. Müəyyən şəraitdə (tərlənmiş insan, nəm ayaqqabı) ayaqlar arası müqavimət 1 Om-dan az ola bilər, ona görə aşağı gərginlik (bir-neçə on volt) həmişə təhlükəsiz olur. İstehsalatda 36 V və daha aşağı gərginlikdə xeyli bədbəxt hadisələrin baş verməsi halları məlumdur [5-6].




Şəkil 1. İldırımın yerə vurmasından qalmış iz




Şəkil 2. YG xəttinin qırılıb yerə düşməsi



Şəkil 3. YG-in ağacdən yerə keçməsi



Şəkil 4. YG-in avadanlıqdan yerə keçməsi



Şəkil 5. Addım gərginliyinin paylanması

2. Məsələnin qoyuluşu

İldırımın impuls cərəyanının canlı orqanizmlərə təsiri yaxşı öyrənilməyib. Addım gərginliyi və cərəyanının qiymətini təxmini olaraq hesablamaq imkanı olduğu halda onların insan orqanizmi ilə qarşılıqlı təsirinin nəticəsi barədə fikir söyləmək olmur. İldırım vurmasının, o cümlədən addım gərginliyi ilə vurmasının, unikal “fizioloji xüsusiyyətləri” vardır. Bu, ilk növbədə, onunla əlaqədardır ki, ildırım çox böyük enerji daşısa da, o çox qısa zaman müddətində: $1/10000 \text{ san}$ – də baş verir. Belə ildırım vurması, adi elektrik avadanlıqlarından cərəyan vurmasında olduğu kimi, nadir halda güclü yanıqlara və daxili orqanların zədələnməsinə səbəb olur. Lakin ildırım ürəyə və əsəb sisteminə, o cümlədən periferik əsəb sisteminə təsir edə bilər. Ona görə addım gərginliyi ilə cərəyan vurmasının nəticələri gözlənilməz, təhlükəli və çox müxtəlif ola bilər: katarakt, ətraf çıxıntıların iflici, yuxunun və əqli fəaliyyətin pozulması, eşitmə qabiliyyətinin və yaddaşın itirilməsi və s. Ölüm hadisələrinin əsas səbəbi isə ürək fəaliyyətinin dayanmasıdır.

Addım gərginliyinin təhlükəli qiymətinin dəqiq təyini müəyyən edilməyib. Məlumdur ki, 6 kV ildırımın impuls təsiri ürəyin fibrilyasiyasına və ürək döyüntüsünün dayanmasına səbəb ola bilər. Lakin insan orqanizminin fiziologiyası mürəkkəbdir və hətta az təsirdə də ağır zədələnmə və ölümlə nəticələnmə halları ola bilər. Kardiostimulyasiya və ürək əzələlərinin fibrilyasiyası üçün qısamüddətli 1mA cərəyan kifayət edir. Bu halda ürəyi quru dərinin yüksək müqaviməti də etibarlı mühafizə etmir. Addım gərginliyində isə mürəkkəblik var, çünki cərəyan adətən əl-ayaqdan axır, oynaqların müqaviməti isə damar və əzələ müqavimətindən çoxdur. Belə halda damar yaxınlığındakı toxumalar ciddi zədələnsə, bu əlilliklə nəticələnə bilər.

Addım gərginliyi iri buynuzlu heyvanlar üçün daha təhlükəlidir, çünki bu heyvanların qabaq və arxa ayaqları arasında məsafə çox böyük olduğundan müvafiq olaraq bu məsafəyə düşən gərginlik də çox olur. Belə heyvanların addım gərginliyi ilə ölüm hadisəsi az deyil. Qeyd edək ki, əgər yer səthinin müqaviməti çox olarsa (daşlı və ya quru qumlu sahə və s.) ildırım vuran zaman gərginlik anı olaraq daha geniş sahəyə yayıla bilər və heyvanlar ildırımın vurma nöqtəsindən daha uzaq məsafədə də ölə bilər. Yer səthinin bəzi hissələrinin xüsusi elektrik müqaviməti cədvəl 1-də göstərilir.

Cədvəl 1. Yer səthinin bəzi hissələrinin xüsusi elektrik müqaviməti (Om·m)

Quruntun tərkibi	Müqavimət, Om·m
Qum	400 – 1000 və daha çox
Qumlu gil	150 – 400
Gil	8 – 70
Bağ torpağı	40
Qara torpaq	10 – 50
Torf	20
Daşlı gil	100
Əhəngdaşı, iridənəvərli qum	1000 – 2000
Qaya, daşlar	2000 – 4000
Çay suyu (düzənlikdə)	10 – 80
Dəniz suyu	0,2
Kran suyu	5 – 60

İldırımötürücülərin və hündür obyektlərin yaxınlığında addım gərginliyinin dəqiq təyini üçün nəzəri biliklər olduğu halda, təhlükəsizlik zonasının təyini üçün əlavə bilik lazımdır. Çox halda addım gərginliyinin qurbanları hesab edirdilər ki, onlar təhlükədə deyillər və onların mülkiyyəti də ildırımötürücülərlə mühafizə olunur.

Nəzəriyyə çox vacibdir, lakin praktika üçün həlledici parametrlər addım gərginliyinin zamanətli təhlükəsiz olduğu ildırımötürücüdən olan məsafədir. Bu gərginliyin yayılması üçün ildırımötürücülərin və torların quraşdırılmasında hesabat aparmaq üçün vacibdir. Təəssüf ki, bu mövzuda tədqiqatlar azdır, bu işdə hərbiçilərin ildırım sahəsindəki tədqiqatları mühüm əhəmiyyət kəsb edir. Bu onunla əlaqədardır ki, müxtəlif ölkələrin hərbi hissələrində müxtəlif iqlim zonalarında və hava şəraitində silah ambarlarının ildırımötürücülərinə, texnikanın və hərbiçilərin yerləşdiyi çadırların yaxınlığına ildırım vurmaları nadir hal deyil. Bu hadisələrin dəqiq qeydiyyatı faydalı statistika yığmağa imkan verir.

Amerikanın TRADOC ordusunun 2002-ci il üçün ildırımdan mühafizə tövsiyələrində qeyd olunur ki, ildırımın vurduğu yerdən təxminən 10–20 m məsafədə addım gərginliyindən ölüm hadisələri olmuşdur. Bu halda çox vaxt ildırım vurmaları – ildırım boşalmasının bilavasitə təsiri ilə deyil, qurğulardan olan addım gərginliyinin və qövs boşalmalarının təsiri ilə olmuşdur.


Addım gərginliyinin gözlənilən qiymətinin hesabı xüsusi təminat proqramı və mütəxəssislərin müvafiq xidməti ilə təmin edilir. Addım gərginliyi, qeyd etdiyimiz kimi, cərəyandan və torpağın xüsusi

müqavimətindən asılıdır. Təhlükəli addım gərginliyi elektrik qurğularının torpaqlayıcılarının yaxınlığında qəza qapanma vaxtı baş verə bilər. Ona görə torpaqlayıcıların müqavimətinin buraxıla bilən qiyməti və torpağın xüsusi müqaviməti normalaşmalıdır.

3. Məsələnin həlli

Qeyd etdiyimiz kimi, addım gərginliyinə məruz qaldıqda ayaq əzələlərinin qıc olaraq yığılması baş verir, bu halda insan yerə yıxıla da bilər və nəticədə cərəyan yeni dayaq nöqtələrindən keçməyə başlayır, bu da ölümə səbəb ola bilər.

Təhlükəli zonada davranma qaydalarına əməl etməklə addım gərginliyinin vurma ehtimalını azaltmaq mümkündür. Bunun üçün yerdə potensiallar fərqi azad olmaq lazımdır. Ona görə ayaqlar arasında məsafəni minimuma endirmək və heçbir halda yerə və müxtəlif cisimlərə (polad dayaq, dəmir-beton divarlar və s.) əl ilə toxunmaq olmaz. Əlacsız şəraitdə, yəni ildırımın qəfildən ildırımötürücüyə və ya hündür obyektlərə vurduğu zaman, onların yaxınlığında olduqda, çox qısa və sıx addımlarla ("qaz yerışı" ilə) kənara çəkilmək lazımdır (şəkil 6). Bəzən bir ayaq üstə durmaq tövsiyə olunur, lakin bu halda bədənə dayanıqsız vəziyyəti əl üzərinə yığılmağa və ya insitiv olaraq hər hansı cisimdən tutmağa gətirib çıxara bilər. Yuxarıda göstəriləyimiz fizioloji səbəblərdən, baş – ayaq və ya əl - ayaq dövrəsindən cərəyanın keçməsinə qətiyyən yol vermək olmaz, çünki, bu halda beyin və ürək zədələnmə bilər. Ona görə belə şəraitdə ayaqları sıx birləşdirməklə durmaq lazımdır.



Şəkil 6. Təhlükəli zonanın tərk edilməsi

Addım gərginliyi torpağın müxtəlif qatlarının müqavimətindən asılıdır, buna baxmayaraq onun təxmini hesablanması aparıla bilər. YG naqilinin bir fazasız qırılıb yerə düşdükdə qısa qapanma cərəyanı I_q belə hesablanı bilər:

$$I_q = \frac{U_f}{\sqrt{3}(R_0 + R_{cont})}, \quad (1)$$

burada U_f – faza gərginliyi, R_0 – neytralın işçi gərginliyinin müqaviməti (bir-neçə Om), R_{cont} – kontakt yerində cərəyanın axmasına müqavimətdir (adətən 12 Om qiymətində).


Yer səthində hər hansı x nöqtəsində kontakt yerinin potensialı:

$$\varphi_x = U_x = \frac{I_q \rho}{2\pi x}, \quad (2)$$

burada ρ – yer qatının müqavimətidir. $\frac{I_q}{2\pi x} = k = const$ olduğunu nəzərə alsaq:

$$\varphi_x = U_x = \frac{k}{x}. \quad (3)$$

Bu ifadə hiperbola tənliyidir, deməli torpaq səthinin nöqtələrinin potensialı hiperbolik qanunla dəyişir. Onun praktikada təsdiqini şəkil 7-də görmək olar.



Şəkil 7. 30 kA ildırım cərəyanında addım gərginliyi

İldırım ildırımötürücünü vurduqda və ya elektrik avadanlığının korpusu YG altına düşdükdə torpaqlayıcının səthində t nöqtəsinin potensialı (torpaqlayıcıdakı gərginlik) maksimal qiymətə malik olacaq:

$$\varphi_t = \varphi_{max} = U_t = \frac{I_t \rho}{2\pi x_t} = I_t R_t, \quad (4)$$

burada $R_t = \frac{\rho}{2\pi x_t}$ - torpaqlayıcının müqavimətidir.


Addım gərginliyi (x və $x+a$ nöqtələri arasında) belə hesablanı bilər:

$$U_{ad} = \varphi_x - \varphi_{x+a} = \frac{k}{x} - \frac{k}{x+a} = k \frac{a}{x(x+a)} = \varphi_x \frac{a}{(x+a)} = \frac{I_q \rho a}{2\pi x(x+a)}, \quad (5)$$

burada ρ – torpağın xüsusi müqaviməti (bir-neçə yüz Om·m), x –ildırımın vurduğu nöqtədən və ya YG naqilin düşdüyü yerdən olan məsafə, a – addımın uzunluğudur.

Aydınır ki, addım gərginliyindən ən yaxşı mühafizə potensialları fərqlinin ləğv edilməsidir. Yaxşı mühafizə üçün istehsal sahəsində binanın döşəməsi metaldan olmalı və ya Faradey silindri şəklində olan tam metal qurğu olmalıdır. Lakin bu həmişə mümkün olmur, ona görə bərabər potensiallı zonalar yaratmaq və ildırım cərəyanının torpaqda yayılması üçün ora metal torlar qoyulur. Mühafizə effektini artırmaq üçün onun üzərinə dielektrik material qoyulur. Bu da insanların əlaqədə olduğu səthdə cərəyan şiddətini maksimum azaltmağa imkan verir.

İldırımdan mühafizə barədə hərbi təlimatlarda mühafizənin cərəyanın yayılmasının konstruksiyasının və yerləşməsinin elementlərinin (torunun) əyani sadə sxemləri verilir (şəkil 8). Belə mühafizə sistemlərini hazır komplekt hissələrlə tez yığmaq mümkündür



Şəkil 8. Addım gərginliyindən mühafizənin sadə sxemi

Tor 0,5 – 0,8 m dərinlikdə qoyulmalıdır, üzəri ən azı 0,15 m olmaqla çınqıl və ya oxşar dielektrik material qatı ilə örtülməlidir. Lazım olduqda başqa materiallardan izolyasiya edici lay əlavə edilir. Məsələn,

5 – 10 sm asfalt izoləedici rol oynaya bildiyi halda, adi nəm torpaq toxunma yerlərində belə mühafizəni təmin etmir.

Beton döşəmə istifadə edilən yerlərdə armaturlardan istifadə edilə bilər, onlar öz aralarında etibarlı birləşdirilməlidir. Torlardan hazırda müasir futbol stadionlarında istifadə edilir. Belə obyektlərdə uzunluğu 0,15 m olan kvadrat özəkli torlardan istifadə edilir. Yoxlama göstərmişdir ki, belə mühafizə çox etibarlıdır. Lakin böyük sahələrin torla mühafizəsi bəzi başa gəldiyindən bəzən qənaət etməyə meyl edilir. İnsanların çox yığıldığı yerlərdə, yanacaq və ya zəhərli maddələr anbarlarında buna yol vermək olmaz.

Yüksək müqavimətli daşlı, donmuş və s. torpaq növlərinin keçiriciliyi az olduğundan onlar xüsusilə təhlükəlidir. İldırım vurduqda onlarda çox yüksək gərginliklər yaranır. Adi addım uzunluğunda insanı on minlərlə volt gərginlik vura bilər.

Bina yaxınlığında olmaq da təhlükəlidir, çünki addım gərginliyi fundaməntdən yayıla bilər. Qrafikdən göründüyü kimi (şəkil 7) 30 kA ildırım cərəyanında dəmirbeton özül plitə üzərində 5 m məsafədə addım gərginliyi 4,5 kV təşkil edir. Nəzərə alaq ki, bu gərginlik normativ torpaqlama müqavimətindədir (4 Om).

4. Nəticə

Beləliklə, addım gərginliyi hələ də ildırım vurmasının əlavə təhlükəli effekti olaraq qalmaqdadır. Belə mikrosaniyəli, çoxsaylı impuls gərginliyinin orqanizmə təsiri az öyrənilmişdir. Ona görə ildırım mühafizəsinə və addım gərginliyinin vurmasının riskli şəraitində davranış qaydalarının öyrənilməsinə xüsusi münasibət olmalıdır.

Ədəbiyyat

- [1] Dwarka Prasad, H.C. Significance of step and touch voltages. Sharma. International Journal of Soft Computing and Engineering (IJSCE) ISSN: 2231-2307, Volume-1, Issue-5, November 2011.p193-197.
- [2] <https://studbooks.net/38325/bzhd/opasnost/zamykaniya/zemlyu/elektrostanovkah>.
- [3] <http://electricalschool.info/main/electrobezopasnost/411-chto-takoe-shagovoeaprjazhenie.html>.
- [4] <https://t-zamer.ru/v-pomosh-energetiku/shagovoe-napryazhenie/>
- [5] Saeid Gholami Farkoush , Abdul Wadood , Tahir Khurshaid , Chang-Hwan Kim , Muhammad Irfan, And Sang-Bong Rhee. Reducing the Effect of Lightning on Step and Touch Voltages in a Grounding Grid Using a Nature-Inspired Genetic Algorithm With ATP-EMTP. IEEE Access. Volume 7, 2019.
- [6] Dwarka Prasad, H.C. Sharma. Significance of step and touch voltages. International Journal of Soft Computing and Engineering (IJSCE) ISSN: 2231-2307, Volume-1, Issue-5, November 2011. P.193-197.

Metropolitenin elektrik təchizatı sistemində reaktiv enerjinin kompensasiyasının idarə olunması

Management of compensation of reactive energy in the electricity supply system of the Metro

Gültəkin Həsənova 

Elektrik - Elektronik Mühendisliyi Bölümü, ADNSU Üniversitesi, Bakı, Azərbaycan

arzu969897@gmail.com

Xülasə. Reaktiv gücün kompensasiyası məsələsi əvvəllərdə olduğu kimi bu gün də aktual məsələ hesab olunur. Bu baxımdan verilmiş məqalədə böyük əhəmiyyətə malik metropoliten şəbəkəsinin elektrik təchizatı sistemində reaktiv gücün kompensasiyası məsələsinə baxılmış və tədqiqatın nəticələri məqalədə öz əksini tapmışdır.

Metropolitenin elektrik təchizat sisteminin normal iş rejiminin mövcud olma şərtlərindən biri reaktiv güc balansının təmin edilməsi olduğundan, onun kompensasiya olunması itkilərin azalmasına, elektrik şəbəkəsinin ötürmə qabiliyyətinin artmasına və kompensasiyaedici qurğulardan istifadə edilməklə gərginliyin tənzimlənməsinə şərait yaradır. Həmçinin məqalədə kompensəedici qurğulardan istifadə etmək yolu ilə reaktiv gücün idarə olunması sisteminə baxılıb və nəticədə güc əmsalının qiymətinin 0,97-0,99 –a qədər artırılması qeyd olunub.

Açar sözlər-reaktiv güc, aktiv güc filtri, yüksək tezlikli təhriflər, kompensasiya, gərginliyin keyfiyyəti.

Abstract. The issue of reactive power compensation, as before, is considered an urgent issue today. In this regard, great importance is given in the article to the issue of reactive power compensation in the power supply system of the metro network, and the results of the study are reflected in the article.

Since one of the conditions for the existence of a normal mode of operation of the metro power supply system is to ensure a balance of reactive power, its compensation helps to reduce losses, increase the capacity of the electric network and voltage regulation using compensating devices. Also in the article, the reactive power control system was considered by using control devices, as a result of which the cost of the power factor was increased to 0.97-0.99.

Keywords-reactive power, active power filter, high frequency distortions, compensation, voltage quality.

I. Giriş

Metropolitenin elektrik təchizatı şəbəkəsində elektrik enerjisinin ötürülməsi və çevrilməsi zamanı yaranan itkilərin azaldılması və həmin enerjiden rəşional istifadə olunması metropoliten kimi nəhəng elektrik enerjisi tələbatçıları üçün vacib olan elm və texnologiya sahəsinin əsas məsələlərindən biri hesab olunur. Belə ki, bu sahənin effektiv işinin təmin olunmasında elektrik enerjisinin miqdar və keyfiyyət göstəricilərinin normativ sənədlərdə olduğu kimi saxlanılması böyük əhəmiyyətə malikdir. Metropoliten sistemində elektrik enerjisinin əsas keyfiyyət göstəriciləri aşağıdakılar hesab olunur:

- tələbatçının reaktiv gücünü xarakterizə edən güc əmsalı;
- aktiv-induktiv xarakterli yük səbəbindən yaranan yüksək tezlikli təhrif olunmalar.

Aktiv-induktiv xarakterli yük metropolitenin elektrik təchizatında cərəyan və gərginlik arasında faza sürüşməsinin yaranmasına səbəb olur ki, bu da öz növbəsində metro yarımstansiyasında güc əmsalının aşağı düşməsinə gətirib çıxarır.

Metropoliten elektrik enerji tələbatçıları şərti olaraq aşağıdakı kimi iki qrupa ayrılır:

1. Çox da böyük olmayan və gücü dəyişməyən yüklər; məsələn, 12 saatdan artıq işləyən eskolatorlar, ventilyasiya qurğuları, işıqlanma sistemləri, nasoslar və s. Belə qurğular metro tərəfindən tələb olunan enerjinin təxminən 40-50 %-ni istehlak edirlər [1]. Bu qrupda elektrik enerjisinin keyfiyyət göstəricisinə mənfi təsir edən əsas amil gərginliyin faza sürüşməsi hesab olunur.
2. Daha böyük dəyişən gücə malik elektrik qatarlarını qidalandıran qurğular. Bu zaman elektrik enerji tələbatının təkan şəkilli və düzləndirici sistemlərdə cərəyanın 6 impulsu (5-ci və 7-ci) və ya 12 impulsu (11-ci və 13-cü) harmonik mürəkkəbələrinin yaranması hesabına güc əmsalının dəyişmə diapazonu böyük olur.

Reaktiv gücün kompensasiyası məqsədilə tətbiq edilən statik kondensator batareyaları, passiv filtrlər və s. ətalətlilik səbəbindən şəbəkədə elektromaqnit rezonans hadisələrinin yaranmasına gətirib çıxara bilər [3]. Nəzərə almaq lazımdır ki, tristorlu statik kompensatorlar və STATKOM qurğular reaktiv gücün kompensasiyasını real zaman ərzində yerinə yetirə bilmirlər [7].

Elə bu səbəbdən də son zamanlar kompensəedici təsir göstərən qurğularda harmonik mürəkkəbələrin qiymətini kompensasiya edə bilən, yəni yüksək harmonikaların təsirinin neytrallaşdırılması və reaktiv enerjinin metropoliten şəbəkəsində idarə olunması aktual məsələ hesab olunur.

Verilmiş məqalədə əsas məqsəd metropoliten elektrik təchizatı sistemində reaktiv enerjinin kompensasiyası və onun idarə olunması üçün hibrid kompensasiya sisteminin işlənməsi adlanır.

Qoyulmuş məqsədə nail olmaq üçün məqalədə aşağıdakı məsələlər həll olunur:


- Hibrid reaktiv güc kompensasiya sisteminin iş prinsipinin təsvir olunması;
- Kompensasiya sisteminin hibrid filtrlili idarəetmə sisteminin işlənməsi məsələsinin həlli;
- Matlab Simulinkdən istifadə etməklə qurğunun kompüter simulyasiyasının yerinə yetirilməsi.

II. Hibrid kompensasiya sisteminin işinin təsvir olunması

Qeyd etmək lazımdır ki, dünyanın bir çox ölkələrində məsələn, ABŞ, Yaponiya, Almaniya və s. kimi ölkələrdə elektrik enerji itkilərinin azaldılması və gələcəkdə güc əmsalının 0.98-0.99-a artırılması prioritet məsələ kimi qarşıya qoyulur [2]. Nəzərə almaq lazımdır ki, elektrik enerjisinin keyfiyyəti təkcə onu istehsal edən elektrik stansiyalarından deyil, həm də onu istehlak edən tələbatçılardan da asılıdır. Metropolitenin elektrik təchizatı şəbəkələrində elektrik enerjisinin keyfiyyət göstəricisinə təsir edən faktorlar aşağıdakı kimi xarakterizə olunur:

1. Gərginliklə cərəyan arasında faza sürüşməsinin yaranmasına səbəb olan reaktiv elementlər, elektrik mühərrikləri və digər aktiv-induktiv xarakterli qurğular;
2. Gərginliyin və ya cərəyanın qeyri-sinusoidalılığı səbəbindən şəbəkədə yaranan yüksək harmonik mürəkkəbələr;
3. Gərginliyi 0.4 kV olan şəbəkədə eninə qeyri-simmetriklik (yəni faza yüklərinin qeyri-bərabərliyi).

Elektrik dövrləri nəzəriyyəsidən məlumdur ki, reaktiv güc zamanın bir anında mənbədən işlədiciyə doğru, digər bir anında isə işlədicidən mənbəyə doğru istiqamətlənir və heç bir iş görmür, o yalnız maqnit selinin yaranmasına sərf olunur. Elə bu səbəbdən də generator və tələbatçı arasında dövr edən reaktiv enerji itkilərin yaranmasında birbaşa iştirak etmir. Belə ki, o yük üçün sərf olunmur. Lakin bu enerjinin artması şəkil 1-də göstərilirdiyi kimi şəbəkədə müəyyən mənfi təsirlərin yaranmasına səbəb olur.



Şəkil 1. Reaktiv güc tələbatının artması və ya güc əmsalının azalmasının mənfi təsirləri

Metropolitan elektrik təchizatı sistemində yaranan qeyri-sinusoidalıq sistemdə:

1. Xətt naqillərində əlavə itkilərin yaranmasına;
2. Eskalatorların, elektrik qatarlarının, ventilyasiya və nasos sistemlərinin mühərriklərinin vallarının döyməsinə, dartı qüvvələrinin azalmasına;
3. Yüksək tezlikli harmonikaların yaranması hesabına elektrik avadanlıqlarının izolyasiya sisteminin tez bir zamanda köhnəlməsinə;
4. Elektrik maşınlarının və transformatorların sarğıları arasında tutum müqavimətinin azalmasına;
5. Cərəyanın və gərginliyin dəyişmə əyrilərinin təhrif olunmasına;
3. Histerezis və burulma cərəyanlarının yaratdığı itkilər hesabına dartı yarımsansiyasında quraşdırılan güc transformatorlarında itkilərin artmasına;
4. Şəbəkədə rezonans hadisələrinin yaranmasına və s. gətirib çıxara bilər.

Elə bu səbəbdən də hökmən sistemin sinusoidalıq rejiminin idarə olunması vacib bir məsələdir.

Bunlardan əlavə olaraq qeyd etmək lazımdır ki, üçfazlı dördməfəilli şəbəkələrdə tələb olunan faza güclərinin qeyri-simmetrikliyi:

- neytral xətdə cərəyanın artması;
- üçün dəfəliyi şəklində olan harmonik mürəkkəbələrənin olması;
- mənbənin gərginliyinin təhrif olunması;
- artıq yüklənmiş fazalarda gərginliyin təkən şəklində dəyişməsi ilə xarakterizə olunur.

Metropolitan elektrik təchizatı sistemində elektrik enerjisinin keyfiyyətinin təsir xüsusiyyətlərinin aydınlaşdırılması, güc əmsalının qeyri-xətti təhrif əmsalının və $\cos \varphi$ kimi göstəricilərin yaxşılaşdırılmasının əsasını təşkil edir.

Güç əmsalının artırılması istiqamətində metropoliten sistemində aşağıdakı kimi texniki tədbirlər görülür:

1. Eskalatorları hərəkətə gətirən asinxron mühərriklərin sabit maqnitli sinxron mühərriklərlə əvəz olunması;
2. Yeni PLC sistemindən istifadə etməklə dəyişən cərəyan mühərriklərinin idarə olunması;
3. Reaktiv gücün kompensasiyası;
4. Yüksək harmonik mürəkkəbələrənin yaratdığı sürüşmələrin korreksiyası.


Reaktiv gücün kompensasiyası və harmonik mürəkkəbələrənin aktiv şəkildə filtrasiyası bahalı avadanlıqların işləmə müddətinin uzadılmasına, yeni yüklərin qoşulması üçün əlavə aktiv gücün yaranmasına, səhvən işləmə risklərinin, nəhəng qəzaların və həmçinin də elektrik enerjisi xərclərinin azaldılmasına köməklik edir.

III. Kompensasiya sisteminin hibrid filtrlı idarəetmə sisteminin işlənməsi məsələsinin həlli

Müasir dövrdə güc elektronika texnologiyalarının inkişaf etməsi ilə nəinki reaktiv gücün kompensasiyasının yerinə yetirilməsi, həmçinin də yüksək harmonikaların yaratdıqları təhriflərin korreksiya edilməsi mümkün oldu. Belə məsələlərin yerinə yetirilməsinə imkan verən qurğu aktiv güc filtri adlanır. Bu qurğu real zaman rejimində elektrik şəbəkəsinin parametrləri məsələn, şəbəkə gərginliyi və cərəyanı haqqında aldığı informasiyalar əsasında reaktiv güc tələbatını və ya generasiyasını realizə edir. Həmçinin də bununla yanaşı olaraq yük cərəyanının qeyri-sinusoidalığı və harmonik mürəkkəbələri haqqında informasiyalar almaqla onların qeyri-xətti təhriflərinin də korreksiyasını yerinə yetirir.(Şək.2)


Aktiv güc filtri şəbəkəyə iki əsas qayda ilə, yəni həm ardıcıl, həm də paralel qoşulur. Ardıcıl birləşmədə tələbatçının tələb etdiyi tam cərəyan və yerə nəzərən faza gərginliyi hesablanır. Belə birləşmədə ötürücü xəttin ümumi induktiv reaktansının zəifləməsi üçün tutumu böyük olan kondensatorların qoşulması lazım gəlir ki, bu da böyük xərc tələb edir.

Aktiv güc filtri üçfazlı invertordan ibarətdir və onun da əsas komponentləri izolyasiya olunmuş bipolyar tranzistor, induktiv sarğac, reaktiv enerji mənbəyi olan kondensator batareyaları, cərəyan və gərginlik vericilərindən alınan informasiya əsasında idarəedici siqnalları generasiya edən mikroprosessor adlanır.



Şəkil 2.Şəbəkəni və yükü xarakterizə edən parametrlər


Paralel birləşmə isə (Şək.3) nominal gücün seçilməsində daha yumşaq yanaşma olduğundan, müxtəlif növlü impulsların kompensasiyasının mümkün olmasından, balanslığın pozulmasını və faza sürüşmələrini aradan qaldıra bilməsi və çevirici blokların harmonik təhriflərini aradan qaldıra bilməsi səbəbindən daha geniş yayılıb [4].



Şəkil 3. Aktiv güc filtrinin paralel qoşulma sxemi

Aktiv güc filtri (AGF) bir neçə məsələni paralel olaraq həll etmək imkanına malikdir. Qeyri-xətti təhriflər vasitəsi ilə yaranan yüksək harmonikaların kompensasiyası və əsas harmonikanın yaratdığı reaktiv gücün kompensasiyasından əlavə olaraq aktiv güc filtri yükün fazalar arasında paylanmasını da yerinə yetirə bilər. AGF-nin belə bir imkana malik olması dördnaqill sistemdə neytral naqıl ilə torpaqlama arasındakı potensiallar fərqi azaltmağa imkan verir.

Metropolitenin elektrik təchizatı sistemində reaktiv gücün kompensasiyası üçün hibrid reaktiv güc kompensatorundan da istifadə etmək olar. Onun vasitəsilə faza cərəyanının faza gərginliyinə nəzərən sürüşməsinə və yüksək tezlikli təhrifləri pilləvari formada tənzimləməsi mümkün olur. Burada güc əmsalı cərəyanla gərginlik arasındakı sürüşməni azaltmaqla (Şəkil 4), həmçinin də gücün harmonik təhrifini hamarlamaqla yüksəldilir. Nəticədə güc əmsalının qiyməti 0,97-0,99-a qədər artır.



Şəkil 4. Cərəyanla gərginlik arasındakı sürüşmə bucağının azaldılması

Aktiv güc filtrlərinin müasir idarəetmə sistemi anı gücün əyrisinin formasının tez düzəldilməsi (dizayn olunması) metoduna əsaslanır. Cərəyanın anı qiymətini aktiv və reaktiv hissələrə ayıran ilk alimlərdən biri S.Frayzedır. Onun yanaşmasının əsasını cərəyanın orta kvadratik qiymətinin və qurğunun riyazi inteqrallanmasının yüksək reaktiv güc kompensatorunun iş dinamikasına təsirini nəzərə almaqla hesablanması təşkil edir. Anı güc nəzəriyyəsi istifadə olunması sonradan 1980-ci illərdə Yaponiyada öz inkişafına qədəm qoydu. Burada p-q nəzəriyyəsi H.Akaginin sədrliyi ilə analitik mərkəz tərəfindən hazırlandı. Bir müddət sonra bu nəzəriyyə tam işlənərək modifikasiya olunmuş p-q nəzəriyyəsinə çevrildi [5]. Bu nəzəriyyə aktiv güc süzgəclərinin konstruksiyası sahəsində gücün korreksiyası üsulundan istifadə etməklə onun idarəetmə sisteminin inkişaf etdirilməsinə şərait yaratdı.

H.Akaginin nəzəriyyəsinin sonrakı inkişafı nəticəsində bu nəzəriyyə p-q nəzəriyyəsi və ya d-q nəzəriyyəsi kimi də qəbul edilir. [6]

Burada hesabın sürətləndirilməsi və ölçüsünün azaldılması üçün tam güc-S, aktiv-P və reaktiv-Q güclərin sabit və dəyişən mürəkkəbələrinin cəmi şəklində təsvir olunur.

$$S = \bar{P} + \tilde{P} + \bar{Q} + \tilde{Q} \quad (1)$$

Belə olduqda gücün kompensasiyası kimi P və onun ayrı-ayrı elementlərindən başqa məsələn, $\bar{Q} + \tilde{Q}$ cəmindən (1)-in bütün elementlərini seçmək olar. Hibrid süzgəclər olduqda isə kondensator batareyaları gücün reaktiv komponentini $kb \gg \tilde{Q}$ pilləvari şəkildə kompensasiya edir. Qeyd etmək lazımdır ki, reaktiv enerji


mənbəyini pilləli şəkildə şəbəkəyə qoşduqda reaktiv gücün kompensasiyası tam şəkildə yerinə yetirilə bilmir və nəticədə kompensə edilməmiş qalıq hissə qalmış olur:

$$Q^* = \bar{Q} - \bar{Q}_{kb} \quad (2)$$

Bu çatışmazlığı aradan qaldırmaq üçün isə aktiv güc süzgəcindən istifadə edilir. Yəni:

$$AGF \gg \bar{Q} + Q^*$$

Hibrid reaktiv güc kompensasiyasının idarəetmə sistemi aşağıdakı kimi iş funksiyasını yerinə yetirəcək (şəkil.5)



Şəkil 5. İdarəetmə sisteminin funksional sxemi

Bu prosesin energetik halını xarakterizə edən riyazi modelini Park-Qorev çevrilməsi formasında göstərmək olar [7].

$$\begin{aligned} P_{dq} &= (U_d - jU_q)(I_d + jI_q) = (U_d I_d + U_q I_q) - j(U_d I_q - U_q I_d) = \\ &= P_{dq.a} - jQ_{dq.r} \end{aligned} \quad (3)$$

burada $P_{dq.a}$, $Q_{dq.r}$ - aktiv və reaktiv güclərdir:

$$P_{dq.a} = U_d I_d + U_q I_q \quad (4)$$

$$P_{dq.r} = U_d I_q - U_q I_d \quad (5)$$

gücün “0”-cı mürəkkəbəsi isə

$$P_o = U_o I_o \quad (6)$$


Gücün sabit mürəkkəbəsi də nəzərə alınmaqla tam güc aşağıdakı kimi olacaq

$$S_{dq} = \sqrt{(P_{dq.a} + P_o)^2 + P_{dq.r}^2} = S_{\alpha\beta} \quad (7)$$


IV. Matlab Simulinkdən istifadə etməklə qurğunun kompüter simulyasiyasının yerinə yetirilməsi

Hibrid güc filtrin işinin riyazi modelləşməsi Matlab Simulinkdə yerinə yetirilib. Aktiv –induktiv xarakterli yük üç fazlı, üç naqilli sinusoidal gərginlik mənbəyindən qidalanır. Həmçinin harmonik mürəkkəbləri də daxil edilib.


Bu sistemdə paralel olaraq cərəyanın faza sürüşməsi yaradan passiv tutum filtrindən və qeyri-xətti yüksək harmonik mürəkkəbləri hamarlayan aktiv güc filtrindən istifadə olunur. Kompüter modelləşməsinin nəticələri şəkil 6- a), b) və c)-də göstərilib.



a)



b)



c)

Şəkil 6. Kompüter modelləşməsinin nəticələri

Nəticə

Metropolitenin elektrik təchizatı sistemində reaktiv gücün itkilərə təsiri məsələsi geniş araşdırılmışdır. Burada əsas mənfi təsirlər gərginliyə nəzərən cərəyanın faza sürüşməsi və yüksək tezlik təhrifləri adlanır. Mövcud süzgəclərin müqayisəli təhlili göstərdi ki, aktiv güc filtirlərindən istifadə olunması daha əlverişlidir. Eyni zamanda qeyd etmək lazımdır ki, yüksək harmonikalar daxil edildikdə yük cərəyanının forması əsas harmonikadan 96%-dək fərqlənir. AGF işə düşdükdə isə faza cərəyanının xarakteristikası tam dəqiqliklə düzəlir və nəticədə $\cos\varphi = 0,99$ qiymətini alır. Bu zaman cərəyanın reaktiv hissəsi 56% kompensasiya olunmuş olur. Yüksək harmonikalar isə 1%-dən də az olur.

Ədəbiyyat

1. Шалыгин К.А., Нос О.В. «Техническая реализация принципов энергосбережения на базе силовых активных фильтров» Труды VIII международной (XIX Всероссийской) конференции по автоматизированному электроприводу АЭП-2014. – Саранск, 2014. Ст. 28–32.
2. Andrey E., Petrov A., Nadezhda A. Logutenko, «The analysis of reactive power in metro». IFOST-2016: Mechatronics, Electrical Engineering and Power Electronics, Part 2, pp. 121-123, 2016 Engineering, Vol. 86, №2, pp. 72–78, 2015.
3. Nos O.V., «Control strategy of active power filter for ineffective instantaneous power compensation», The 15 international conference of young specialists on micro/nanotechnologies and electron devices, Novosibirsk : IEEE Press, 2014, pp. 370–374.
4. Petrov A.A., Schurov N.I. Shtang A.A. «Povyshenie kachestva elektroenergii metropolitena» [Electricity quality improving in metro]-2016 c.80-87
5. Akagi H., Kanazawa Y., Nabae A. «Generalized theory of the instantaneous reactive power in three-phase circuits». Proceedings of the International Power Electronics Conference (IPEC'83), Tokyo, Japan, 1983, pp. 1375–1386.
6. Afonso J. L , Aredes M., Watanabe E. H., Martins J. S., «Shunt active filter for power quality improvement», Electricity for a sustainable urban development : proc., the intern. conf., UIE 2000, Portugal, Lisboa, 1–4 Nov., pp. 683–691
7. Nos O.V. , Kharitonov S.A., « A system to control power currents of ineffective instantaneous power compensation», Russian Electrical Engineering, Vol. 86, №2, pp. 72–78, 2015.

LOGICAL ENGINE OVERHEATING PROTECTION PROGRAM

Hasanov Zakir, Khanahmedova Samira,
Alimamrdova Sara, Kerimova Saida

Azerbaijan State Oil and Industry University, Baku, Azerbaijan,

samira1009@mail.ru

Abstract. The engine overheating protection system's program is presented in this article. The Zelio Soft-2 program's Functional Block Diagram (FBD) language is used to compile the program. In order to protect against current overheating, the method of cutting off the motor from the mains is examined. If necessary, an algorithm that takes into consideration a constant value determined based on the parameters and the engine's cooling status will cause a command to disconnect the engine from the mains. The core building components of the FBD programming language are briefly described. Programs are created both before and after the protection system is activated.

Keywords: Zelio Soft-2, Functional Block Diagram, engine, motor protection, current, analog input.

Introduction. It is well known that the windings of the rotor, stator, electrical connection system, etc. can be the cause of engine overheating in a variety of electric machines. An increase in the rated current above the permissible value is the primary cause of engine heating. Gradually raising the rated current above allowable value could put an electric equipment in an emergency state. Therefore, it is required to wait until the stator and rotor temperatures have increased to their limit temperature [1, 2]. Given this, the protective mechanism does not need to immediately disconnect the engine from the mains. Only when a threat exists should the protective system shut off the engine.

Purpose of the work. Motor protection from current cheating is an incorrect form of motor protection that involves monitoring the motor's rated current. The motor is cut off from the mains till the end of the predefined period when the current value exceeds the nominal value and the duration of this process exceeds the nominal value. The motor will continue to operate if the motor current is less than the rated current or equal to it before the aforementioned time period expires.

Protecting the motor from current heating. The protection system program was assembled using the Zelio Soft program and functional blocks of the Functional Block Diagram (FBD) language. The typical method of disconnecting the motor from the mains during the protection against current heating is shown in Figure 1. The figure shows that it takes less time to disconnect the motor from the mains the lower the motor current value from the nominal value [3, 4].

The formula provided below can be solved to get the graph in Fig. 1.

$$t = K / (I - I_n),$$

where t - is the moment the motor is disconnected from the mains, I is its current current, I_n is its rated current, and K - is a constant dictated by the motor's cooling condition and other factors.




Fig. 1. Illustrates the typical engine shutdown form

Engine protection program. Let's create a program to prevent overheating of the engine. Let's add the current value and the duration of the protection at $K=100$ and $I_n=25$ A to the program. We first activate the Q1 motor using the solitary input I1. By converting the analog signal I_b (0-9.9V), which represents the current value of the motor current per unit of current, the **GAIN** block imitates a rise in current over the nominal amount (Fig. 2) of current. We note the highest (A), minimum (C), and standard information volume coefficient ($B=255$) currents in the block's parameters window.




Fig. 2. Parameter of the GAIN block

The **ADD/SUB** block adds and subtracts incoming signals by using the changeable value of the motor I1's current, which is given to it by the **GAIN** block. The second analog input designated for addition receives the alternating current signal in accordance with formula (1). Additionally, the third analog input for signal subtraction is coupled to the nominal value of the motor current via the **NUM** block. To create an algorithm for the equation (I-In), we do as such. Next, you can create the second portion of the formula (1) by executing mathematical operations like multiplication and division using the block **MUL/DIV**. The first analog input designated for multiplication is connected to the **NUM** block, which has the value **K=100** printed on it. The third analog input of the **MUL/DIV** block, which is used to divide signals, receives the output signal of the **ADD/SUB** block. As a result, an algorithm is created for the expression $K/(I-In)$ (Fig. 3).




Fig. 3.

To calculate the time of disconnecting the engine from the mains in case of overheating, an analog timer of type **A/C** is used. The resulting value when calculating formula (1) is fed to the first input of this timer **Delay setpoint value on** – the set value for the on delay. Thus, the compilation of the algorithm for formula (1) is completed. Then, to compare the motor current value with the nominal one, it is necessary to use the **COMPARE** (Comparison of 2 values) block comparator. If the current value of the current is greater than the nominal value (**I>In**), then the comparator gives the command to operate the timer. As a result, the first analog input of the comparator receives a reference value equal to the rated current (25 A) of the motor, and the second analog input of this device is wired to the output of the **GAIN** block. When comparing these signals, the comparator delivers a command to the discrete input of the timer through the logic element **AND**, which is concurrently connected to the input discrete block I1, if the motor current value exceeds the nominal value. **A/C**, in turn, is connected to the motor via the **NOT** and

AND logic components in order to switch the motor on and off from the mains once the given Timer time has passed. The **ARCHIVE** block is initiated in order to start recording the current value, the shutdown time, and the protection operation.

Figure 4, a displays the program before to the protection being triggered, while 4, b displays the protection program following the triggering of the protection.




Fig. 4, a. Protection program before the protection is triggered




Fig. 4, b. The protection program after the protection is triggered

Conclusion. Thus, it is proposed to use the program of the engine overheating protection system compiled by the insert. The process of disconnecting the motor from the mains in the process of protection against overheating by current is analyzed. An algorithm has been compiled for triggering a command to disconnect the engine from the mains if necessary, taking into account a constant value determined depending on the parameters and the cooling condition of the engine.

References

1. <http://electricalschool.info/main/drugoe/379-tokovye-peregruzki-i-ikh-vlijanie-na.html>
2. <https://tehprivod.su/poleznaya-informatsiya/sposoby-zashchity-elektrodvigately.html>
3. Hasanoz Z.A., Khanahmedova S.A. “Programmable logic controllers”, Textbook, Vol. II, p.127, Pub.hous ASOIU, Baku, 2016.
4. Hasanoz Z.A., Khanahmedova S.A. “Problems of programmable logic controllers”, Textbook, p.120, Pub.hous ASOIU, Baku, 2021.

CƏRƏYAN STABİLİZATORLA İDARƏ SİSTEMİNİN XÜSUSİYYƏTLƏRİ

Gülşən Kərimzadə 

Energetika fakültəsi, Azərbaycan Dövlət Neft və Sənaye Universiteti, Bakı, Azərbaycan

(gulschen98@mail.ru)

Annotasiya—Təqdim edilən məqalədə cərəyan stabilizatorla idarəetmə sistemi və tətbiq məsələlərinə baxılmışdır. Tədqiqat üsulu elmi-texniki ədəbiyyatlarda istifadə edilən tədqiqat metodlarına, hesablmf üsulları isə baza hesablama və proqramların metodikalarına əsaslanır. Dəyişən cərəyan idarəetmə sistemlərində geniş tətbiq olunan sinxron əlaqəli cərəyan stabilizatorları sadəlik, yüksək iş qabiliyyəti, dəqiqlik, etibarlılıq və s. əlamətlərlə xarakterizə olunur, cərəyan xətlərində giriş siqnallarını çevirirlər.


Açar sözlər: *cərəyan stabilizatoru, idarə sistemi, siqnal, kanal, diod, tranzistor, iş rejimi, LED, sinxron əlaqə, yük, çıxış müqaviməti, xəta, dövrə*

Abstract— The presented article discusses the application and control system of the current stabilizer. The research method is based on the research methods used in scientific and technical literature, and the calculation methods on the methodology of basic calculations and programs. In AC control systems, widely used current stabilizers with synchronous communication are characterized by simplicity, high performance, accuracy, reliability and other features, convert the input signals of current errors.

Keywords: *current stabilizer, control system, signal, channel, diode, transistor, operation mode, LED, synchronous communication, load, output impedance, error, circuit*

1. Giriş

Cərəyan stabilizatorları yükdəki cərəyanı sabitləşdirmək üçün nəzərdə tutulmuşdur. Yükdəki gərginlik onun müqavimətindən asılı və stabilizatorlar müxtəlif elektron cihazların işləməsi üçün istifadə olunurlar, məsələn qaz boşaltma lampaları. Cərəyan stabilizatorları yüksək keyfiyyətli batareyanın doldurulması üçün də tələb olunur. Konversiya və gücləndirmə mərhələlərinin cərəyanını tənzimləmək üçün mikrosxemlərdə istifadə olunur, mikrosxemlərdə cərəyan generatoru rolunu oynayır. Elektrik dövrlərində həmişə müxtəlif növ müdaxilələr mövcuddur və bu cihaz və elektrik cihazlarının işinə mənfi təsir göstərirdiyindən, cərəyan stabilizatorları (şəkil 1) bu problemin öhdəsindən asanlıqla gəlir [3-8]. Cərəyan stabilizatorunun idarə sisteminin işlənməsində fərqli bir xüsusiyyəti əhəmiyyətli çıxış müqavimətidir ki, bu da girişdə gərginliyin və yük müqavimətinin cihazın çıxışındakı cərəyanın dəyərində təsirini istisna etməyə imkan verir. Cərəyan stabilizatorları yükü axan cərəyanın sabit qalması üçün gərginliyi dəyişdirərək, çıxış cərəyanını müəyyən bir aralıqda saxlayır. Yük cərəyanının qeyri-sabitliyi girişdəki müqavimət və gərginliyin dəyərindən təsirlənir. Məsələn, yük müqavimətinin sabit olduğu və giriş gərginliyi artdığı zaman yük cərəyanı da artır [1-3].



Şəkil 1. Cərəyan stabilizatorun konfigurasiyası

2. Məsələnin qoyuluşu


Güc elektronikasında yüklə cərəyanın sabit səviyyəsinin təmini zəruri məsələlərdən biridir. Cərəyanın sabit səviyyəsinin saxlanması İGBT-tranzistorlar əsasında çevirgəc tipli tənzimləyicilərin və çevirici sxemlərin istifadəsilə yerinə yetirilir. Eninə-impuls modulyasiya vasitəsilə açarın idarə olunması baş verir, bu da çeviricinin, və uyğun olaraq, yük çıxışında cərəyanın idarəsinə gətirir. Yükdə cərəyanın sabit səviyyəsinin saxlanması üçün cərəyan stabilizatorun idarə sisteminin işlənməsi əsas məqsəddir. Bu sistem aktualdır və gəmi və qayıqlarda mühərriklərin idarəsi üçün tətbiq edilir. Cərəyan stabilizatorları elektron cihazların qidalandırılması üçün (məsələn, işıq diodları və ya qazboşaldıcı lampalar) və eləcə də termostabilizatorlarda işçi temperaturun verilməsi üçün istifadə olunurlar. Bundan başqa, cərəyan stabilizatorları müxtəlif tipli akkumulyatorların yüklənməsi üçün tələb olunurlar. Cərəyan stabilizatorları gücləndirici və çevirici kaskadların cərəyanının verilməsi üçün integral mikrosxemlərin tərkibində geniş tətbiq edirlər [1-3].

Sabit gərginlikdən sabit cərəyanın alınması üçün gərginlik çeviricilərindən istifadə olunur. Onların əsas funksiyaları: sabit cərəyan giriş gərginliyinin sabit cərəyan çıxış gərginliyinə çevrilməsi; yükün dəyişmələrindən asılı olaraq, sabit cərəyan çıxış gərginliyinin tənzimi; sabit cərəyan çıxış gərginliyində (tələb olunan səviyyədən aşağı) dəyişən gərginlik döymələrinin azalması; yük və giriş signalın mənbəyi arasındakı izolyasiyanın təmini; sistemin və giriş signalın mənbəyinin elektromaqnit xətalardan mühafizəsi; müxtəlif təhlükəsizlik standartlarının təminatı. Sabit cərəyan dövrələrində elektrik enerji parametrlərinin stabilizatorları yarımkeçirici cihazların əsasında yerinə yetirirlər və iş prinsipinə görə iki qrupa bölünürlər: parametrik (açıq) və əks əlaqəli (qapalı). Qapalı stabilizatorlar fasiləsiz təsirli və impuls (diskret) təsirli növlərə ayrılırlar.

İmpuls (və ya açar) tənzimləyicilərin əsasında tranzistorun periodik qapanma və açılmasında yüklə impuls gərginliyinin və həmdə impuls cərəyanının yaranma prinsipi mövcuddur. Əsas ideya ondadır ki, qapalı açarda cərəyan yüklə keçir, açıq açarda isə - cərəyan mövcud deyil, ona görə də yüklə döymə cərəyan yaranır. Yükdə cərəyanın orta qiyməti açıq və bağlı açarın zaman nisbətindən asılı olacaq. Açarın dəlikliyini idarə edərək, yüklə cərəyanın lazımı səviyyəsinə nail olmaq olar. Adətən yaxşı faydalı iş əmsalı üçün impuls cərəyan çeviricilərindən istifadə olunur. Onlar yüksək faydalı iş əmsalına malikdirlər. Diskret çeviricilərdən istifadə etdikdə, diskret texnika ilə işləmək imkanına nail olmaq olar.

İGBT tipli tranzistorların əsasında integral texnologiyası üzrə yerinə yetirilən tranzistor və diod – tranzistor modullarını xüsusi qeyd etmək lazımdır. Açar rejimlərində kiçik güc itgiləri, işçi gərginlik və cərəyanların böyük qiymətləri, bu modulların qoşulma və açılmasının az müddətliyi, və eləcə də onların paralel işdə istifadə olunma azalmasına imkan yaradır. İGBT modulları əksər hallarda tranzistorlar yarıkörpü sxemi üzrə birləşən inverterlarda istifadə olunurlar. İGBT modulların (şəkil 2) konstruksiya və parametrləri daima təkmilləşdirilir, dayanıqlıq və modulların istismarın sərt şəraitlərində və qəza rejimlərində xidmət müddəti artır [8-12]. İGBT-tranzistorun çevrilməsi verilən tezliklə aparılır- bu da yüklə cərəyanın tələb olunan səviyyəsinin saxlanılmasına imkan verir.

Texniki nəticəni əldə etmək məqsədilə impuls stabilizatorun idarəetmə sisteminin əsasını inverterlə idarə signalının tezlik-impuls modulyasiya istifadəsilə üsulu təşkil edir. Bu üsulun xüsusiyyəti stabilləşdirilmiş cərəyanın qiymətinin ölçülməsi bilavasitə yük dövrəsində aparılır, rəqəmləşdirilir və mikrokontrollerin yaddasında saxlanılır, sonra isə çıxış cərəyanı düzləndirilir və hamarlanır. Stabilləşdirilmiş cərəyanın ölçülən qiyməti gücləndirici vasitəsilə tələb olunan qiymətlə müqayisə olunur, və bu qiymət mikrokontrollerdə quraşdırılmış rəqəmsal-analoq çeviricinin köməkliyi ilə müəyyən edilir. İmpulsların tələb olunan ardıcıl tezliyi inverterin idarəsi üçün generator vasitəsilə müəyyən edirlər, o da öz növbəsində gücləndirici vasitəsilə idarə olunur və beləliklə yük cərəyanının cəld əks əlaqəsinin tənzimi, yükün dinamiki dəyişikliklərində və giriş qida gərginliyinin yüksək dəqiqliyi təmin edilir.



Şəkil.2 Çeviricinin yük cərəyanının faydalı iş əmsalından asılılığı : fasiləsiz keçirici rejimdə və kiçik istehlak rejimində

3. Məsələnin həlli


Məlum olduğu kimi LED-lərin parlaqlığı ondan axan cərəyandan asılıdır və LED-dən axan cərəyan gərginlikdən asılıdır. Gərginlik qeyri-sabit olanda LED-in parlaqlığında nəzərə çarpan dalğalar müşahidə olunur, lakin bu parlaq dalğalanmadan çox gərginlikdəki artım LED-lərdən axan cərəyanın artmasına səbəb olur, nəticədə LED-lər sıradan çıxır. Bu təhlükənin qarşısını almaq məqsilə LED-lər xüsusi dövrələr vasitəsilə, əsasəndə cərəyan stabilizatorları vasitəsilə gücləndirilir.

İmpuls stabilizatoru tənzimləyici cihazı olan impuls çeviricisindən ibarətdir: çeviriciyə nəzarət edən əsas cihaz, çıxış gərginliyinin dalğalanmasını azaldan hamarlaşdırıcı filtr, çıxış və giriş gərginliyi arasında fərq siqnalı yaradan müqayisə cihazı. Əsas bölmələrin əlaqəsi (şəkil 3) göstərilən impuls cərəyan stabilizatorunun blok diaqramında əks olunmuşdur.

Stabilizatorun çıxış gərginliyi nümunəvi gərginliyi olan müqayisə cihazına verilir və cihazın çıxışında bu gərginliklərin fərfinə mütənasib siqnal alınır. Fərq siqnalı dərhal çeviriciyə nəzarət edən əsas cihaza ötürülür və yaxud birbaşa cərəyan gücləndiricisi ilə artır. Əsas cihazdakı PW nəzarəti ilə fərq siqnalı sabit tezlikli və dəyişən müddətə sahib impulslara çevrilir. PW nəzarəti ilə impuls müddəti sabitdir və yaradılan impulsların tezliyi siqnal parametrlərindən asılı olaraq dəyişdirilir [6-10]. Əsas cihaz tərəfindən yaradılan idarəetmə impulsları tənzimləyici tranzistorun əsas rejimində işləyən konvertorun komponentlərinə verilir. Generatorun tezliyini və ya impuls genişliyini dəyişdirərək yük üzərindəki gərginliyi dəyişdirə bilərik. İdarəetmə impulslarının parametrlərindən asılı olaraq çevirici


çıxış gərginliyinin dəyərini sabitləşdirərək düzəldir. Nəzəri cəhətdən, PW və CHI tənzimləmələri olan stabilizatorlarda yüklə gərginlik dalğalanması tamamilə olmaya bilər.

Rele stabilizasiyası ilə gərginlik çeviricisini idarə edən signal əmələ gəlir, stabilizatorun girişinə sabit gərginlik tətbiq etdikdə çeviricinin tranzistoru açıqdır və çıxış gərginliyi yüksəlir. Müqayisə cihazı müəyyən bir yuxarı həddə çatdıqda trigger vəziyyətini dəyişdirərək bir fərq signalı yaradır və tənzimləyici tranzistoru bir kəsmə vəziyyətinə keçirir. Tənzimləyicinin çıxış gərginliyi azalmağa başlayır. Aşağı qiymət əldə edildikdə müqayisə cihazı triggeri yenidən dəyişdirəcək bir fərq signalı yaradır və tənzimləyici tranzistor doyma vəziyyətinə gəlir. Stabilizatorun yükündəki gərginlik artmağa başlayır. Beləliklə rele sabitləşməsi ilə çıxış gərginliyi davamlı olaraq dəyişir və orta qiymət nominal gərginliyə uyğun gəlir. Alınan qiymət müqayisə cihazının çıxışındakı gərginlik amplitudunun tənzimlənməsi ilə təyin olunur [2-4]. Rele stabilizatorları PW və CHI tənzimləmələri olan stabilizatorlarla müqayisədə üstünlüyü daha yüksək reaksiya sürətinə malikdir. Nəzəri olaraq, rele sabitləşməsi ilə çıxış gərginliyində həmişə çatışmazlıqlar sayılan dalğalar olacaqdır.



Şəkil 3. İmpuls cərəyan stabilizatorunun blok diaqramı


Şəkil 4-də stabilizatorun səmərəliliyinin asılılığı göstərilir. Müxtəlif hallar üçün qida gərginliyi: bir LED, cərəyan 0.5 A (1-ci əyri); bir LED, cərəyan 1 A (2-ci əyri); iki LED, cərəyan 0.5 A (3-cü əyri); üç LED, cərəyan 0.5 A (4-cü əyri). Effektivlik artan gərginlik ilə azalır və LED sayına görə artır; LED-in parlaqlığını daxiləki cərəyanı dəyişdirərək idarə etmək xüsusiyyəti (şəkil 4-də əyri 2 üçün) şəkil 5-də təqdim edilir.



Şəkil 4. Stabilizatorun səmərəliliyinin (η) gərginlikdən asılılığı


İdarəetmə gərginliyi dövrünün 5 və 6-cı sancaqlarına tətbiq olunur. 0.7 və 1.4 V-da asılılıq demək olar ki, xətti olan xarakteristikada xarakterik əyri kimi görünür. Təcrübədə tətbiqi tövsiyə olunan xüsusiyyətin bu hissəsidir, aşağı cərəyan bölgəsində xarakteristika kəskin şəkildə qeyri-xəttidir və nəzarət gərginliyinin 0.7 V-dan aşağı düşməsi dövrünün bağlanmasına səbəb olur. İdarəetmə

xarakteristikasının sıfırdan maksimum cərəyana yüksəlməsi tələb olunarsa, eyni terminallara tətbiq olunan düzbucaqlı impulsları idarə etmək tövsiyə olunur. Zərbələrin aşağı səviyyəsi, (şəkil 5-də (0.7 V)) xarakteristikanın sol qırılma nöqtəsinə, ən yüksək isə sağa (1.4 V) uyğun olmalıdır. İmpuls tezliyi 100-1000 Hz aralığında olmalıdır. LED vasitəsilə orta cərəyanın impulslarla dövrlərin doldurma faktorundan asılılığı demək olar ki, xəttidir (şəkil 6) [3-5].



Şəkil 5. LED parlaqlığının idarə olunmasının xarakterik xüsusiyyətləri (cərəyan dəyişərək

İmpuls idarəetmə gərginliyinin yüksək səviyyəsi 1.4 V-dan yüksək ola bilər və bu idarəetmə xarakteristikasına təsir göstərmir, lakin bu səviyyə buraxıla bilən maksimum gərginliyin 6 V-dan aşağı olması lazımdır və 2 V kifayətdir.



Şəkil 6. Orta cərəyanın (LED-dən keçən) iş dövründən asılılığı

4. Nəticə

Cərəyan stabilizatorları cərəyan xətlərini (müddət hissəsində olan) keçid cihazları üçün giriş signalına çevirir. Sinxron əlaqəli PI cərəyan stabilizatorları sabit halda olduğu üçün, sadəliyinə və yaxşı işləsinə görə, dəyişən cərəyan sistemlərində idarəetmədə geniş tətbiq olunur. Cərəyan kanallardakı artımla, ümumi cərəyan hər bir kanala bərabər şəkildə bölünür, ətraf kanallardan gələn cərəyan eyni miqdarda dəyişdirilir və kanal sayının artması ilə keçidlərin keyfiyyəti daha yaxşılaşır. Zener diodlarının adi diodlarla əvəz olunan tranzistorlarda LED-lərin iş rejimi normallaşır, yüksək gərginliklərdən mühafizə edilir və LED-lərin istifadə müddəti artır.

Ədəbiyyat

- [1] G.S. Kerimzade, "Determination of the optimal geometric dimensions of the peremonial current stabilizer, taking into account the temperature of the overflow of windings". Moscow. "Electrical engineering", № 9, pp.40-43, 2013.
- [2] G.S. Kerimzade, "Analytical connections of the parameters and sizes of the presizion stabilizer of alternating current using the effect of inducial levitation", International Journal on technical and Physical Problems of Engineering" (IJTPE).September.2022. Number 3.
- [3] G.S.Kərimzadə, M.F.Mütəllibov "Cərayan stabilizatorun idarə sisteminin işlənməsi".// Elmi-texniki jurnal "Energetikanın Problemləri".Bakı. № 3.2020.s.59-64.
- [4] Стабилизаторы тока. Виды и устройство. Работа и применение. <https://electrosam.ru / glavnaja/jelektrooborudovanie/jelektropitanie/stabilizatory-2018>
- [6] Кондаков Е.В. "Импульсные преобразователи и стабилизаторы напряжения", учебно-методическое пособие, Ростов-на-Дону, 2014.
- [7]"Биполярные транзисторы". - <https://geektimes.com/post/253730>. 2018
- [8]"Диод—полупроводниковый элемент". Принцип работы, устройство, разновидности.- <http://www.xtechx.ru/c40-visokotehnologichnispravochnik-hitech-book/diode-razznovidnosti-primenenie> - 2018
- [9]M. Khan, M. H. Chowdhury, "Capacitor-less low-dropout regulator (ldo) with improved psrr and enhanced slew-rate", in IEEE Int. Symp. Circuits and Systems (ISCAS), 2018, pp. 4.
- [10]Xi Q., Zhou Z.K. and Li Z.J. (2012) An Ultralow-"Power Fast-Transient Capacitor-Free Low-Dropout Regulator With Assistant Push-Pull Output Stage". IEEE Transactions on Circuits and Systems II: Express Briefs, Vol. 60, Issue 2 February 2013, pp. 96-100.

LEVİTASIYA ELEMENTLİ ELEKTROMEXANİKİ ÇEVİRİCİLƏRİN HESABINDA NƏZƏRƏ ALINAN FAKTORLAR

Gülayə Məmmədova 

Energetika fakültəsi, Azərbaycan Dövlət Neft və Sənaye Universiteti, Bakı, Azərbaycan

(gulaya68@mail.ru)


Annotasiya—Təqdim edilən məqalədə Levitasiya Elementli Elektromexaniki Çeviricilərin (LEEÇ) hesablanması zamanı əsas faktorların nəzərə alınmasına baxılmışdır. Tədqiqat üsulu elmi-texniki ədəbiyyatlarda istifadə edilən tədqiqat metodlarına və hesablamalara əsaslanır. Texnoloji proseslərin avtomatik idarəetmə sistemlərində LEEÇ-in tətbiqi əlavə qurğuların sayının azalmasına və konstruksiyalarının sadələşdirilməsinə səbəb olur. Bu çeviricilərdə levitasiya elementi hərəkət edən hissəsinin funksiyasını yerinə yetirərək sürtünməsiz şaquli istiqamətdə işçi orqanı hərəkətə gətirir və həm də hərəkətin parametrlərini elektrik signalına çevirir, bu zaman heç bir əlavə detallar tələb olunmur. **Açar sözlər:** *elektromexaniki çevirici, levitasiya elementi, təsirlənmə dolağı, maqnitkeçirici, istilikkeçirmə, sıxışdırılma effekti, uyğunluq prinsipi.*

Abstract— The presented article considers the main factors in the calculation of electromechanical converters with levitation elements. The research method is based on research methods and calculations used in the scientific and technical literature. The introduction of electromechanical converters with levitation elements in automatic control systems of technological processes leads to a reduction in the number of additional devices and a simplification of their construction. In these converters, the levitation element moves the working body in the vertical direction without friction, performing the function of its moving part, and also converts the parameters of the movement into an electrical signal, in which no additional details are required.

Keywords: electromechanical converter, levitation element, impaction coil, magnetic conductivity, thermal conductivity, compression effect, compatibility principle.

1. Giriş

Levitasiya ekranlı elektromexaniki çeviricilər konstruktiv olaraq əsas 3 hissədən maqnitkeçiricindən, levitasiya elementindən (LE) və təsirlənmə dolağından (TD) ibarətdir. Maqnitkeçirici hissə düz və pilləvari maqnit sistemindən ibarət olur. Şəkil 1-də düz və pilləvari maqnit sistemindən ibarət çeviricinin prinsipial sadələşdirilmiş sxemi verilib. Təsirlənmə dolaqları 2 (TD) bir və ya bir neçə seksiyadan ibarət olur və mis naqillərdən karkasa sarınmaqla hazırlanırlar, TD tezliyi 50 Hz olan dəyişən cərəyan mənbəyinə qoşulurlar. Levitasiya elementi 3 (LE) dolaq olduqda mis naqıldən, ekran olduqda isə alüminiumdan hazırlanır və qısa qapanırlar. LE ilə TD arasındakı elektromaqnit əlaqəsi LE-nin hərəkəti zamanı dəyişilir və nəticədə çeviricinin parametrləri levitasiya koordinatından asılı olurlar. Bu asılılıqlar çeviricinin maqnit, elektrik, mexaniki və istilik dövrələrinin tənlikləri əsasında tapıla bilər [1].



Şəkil 1. Levitasiya elementli elektromexaniki çeviriçilərin düz (a) və pilləvari (b) maqnit sistemləri 1-maqnitkeçirici, 2-təsirlənmə dolağı, 3- levitasiya elementi

2. Məsələnin qoyuluşu

LE olan çeviricilərin bir qisminə (qüvvə və yerdəyişmə) giriş signalının dəyişməsilə dolaqların cərəyanları və qızma temperaturları geniş hədlərdə dəyişirlər. Digər çeviricilərdə isə (sabitləşdiricilərdə və izləyiçilərdə) giriş signalı TD-na verilən gərginlik olduğundan və o, dəyişdiyindən maqnit induksiyası dəyişilir, lakin cərəyanlar sabit qalır. Hər iki rejimə uyğun ümumiləşdirilmiş yanaşmadan istifadə etməklə müxtəlif konstruksiyalı və vəzifəli LE-li çeviriçilərin hesabında bəzi faktorlar-Furye və Videman-Frans qanunlarının tətbiqi, maqnit sahəsinin sıxışdırılmasının və zərbə qüvvəsinin təsiri nəzərə alınmalıdır.

3. Məsələnin həlli

Furye və Videman-Frans qanunlarının tətbiqi

İstilikkeçirmə üçün Furye qanunundan məlumdur ki, istilikkeçirmə əmsalı λ materialın istilikötürmə qabiliyyətini xarakterizə edir.

$$q = -\lambda(d\theta/dx) = -\lambda q_{rad} \quad (1)$$

Bu əmsal materialın sıxlığından və onun strukturasından, temperaturundan, təzyiqindən və s. asılıdır. İstilikkeçirmə əmsalının elektron istilikkeçirməsindən λ_e və istilik rəqsləri keçiriciliyindən λ_s ibarət olması məlumdur [2]:

$$\lambda = \lambda_e + \lambda_s \quad (2)$$

Metallar üçün $\lambda_e \geq \lambda_s$. Videman – Fransın nəzəriyyəsinə görə təmiz metallar üçün $\lambda_e \sim \gamma$, yəni elektrik keçiriciliyi γ yaxşı olan materiallar həm də istiliyi də yaxşı keçirirlər. Qeyri-metallar üçün $\lambda_e \gg \lambda_s$ və onlar istiliyi pis keçirirlər, həm də λ və γ bir-birindən asılı olmurlar. Bu xüsusiyyətləri levitasiya ekranının mis və aluminium materiallarından hazırlanması üçün seçilməsində nəzərə alınması vacibdir.

Aluminium üçün $\lambda \approx 210 \text{ Wt/m}^0\text{C}$, $c=0,92 \text{ Dj/q}^0\text{C}$, mis üçün isə $\lambda \approx 400 \text{ Wt/m}^0\text{C}$, $c=0,39 \text{ Dj/q}^0\text{C}$ təşkil edir. Göründüyü kimi mis üçün xüsusi elektrik tutumu c aluminiumdakından təqribən 2,5 dəfə azdır. Mis ekran aluminium ekrandan fərqli olaraq tez qızır və tez də soyuyur, yəni mis

ekranın istilik zaman sabiti azdır. Odur ondan qısa fasilələrlə işləyən çeviricilərdə istifadə etmək zərurəti yaranır. Aliminium ekrandan isə uzunmüddətli iş rejimində işləyən çeviricilərdə istifadə olunması daha sərfəli olur. Bundan başqa aliminium ekran üçün xüsusi maqnit müqavimətinin ρ materialın sıxlığına σ hasili $(\rho \cdot \sigma) \cdot 7,55 \cdot 10^{-5}$ kqOm/m² təşkil edir, mis ekran üçün isə $-15,2 \cdot 10^{-5}$ kqOm/m² olduğundan çeviricilər üçün əksər hallarda aliminium ekranın istifadəsi daha sərfəli olur. Aliminium ekranlı çeviricinin tələb etdiyi güc az, levitasiya koordinatı isə böyük olur [3].

Yuxarıda deyilənlərə əsaslanaraq aşağıdakı nəticələrə gəlmək olar:

1. Qüvvə və yerdəyişmə çeviricilərində levitasiya elementi qısa qapanmış çərçivə şəklində aliminiumdan hazırlanmalıdır. Bu halda çevirici təkrar-qısamüddətli və uzun müddətli rejimdə daha dəqiq işləyə bilər. Karkası olmayan levitasiya ekranının soyuma səthi böyük olduğundan onun həndəsi ölçülərini azaltmaq və tələb olunan temperatur artımını τ_2 almaq asan olur. Bundan başqa «temperatur dreyfi» xeyli zəifləşir.

2. $I = \text{const}$ rejimində işləyən çeviricilərdə levitasiya elementini qısa qapanmış dolaq şəklində mis naqillərdən hazırlanması daha yaxşıdır, beləki bu halda LE-nin aktiv müqaviməti r_2 xeyli azdır. Ona görə də $I = \text{const}$ şərti daha dəqiq yerinə yetirilir. Temperatur zaman sabiti qısa qapanmış mis dolaq üçün azdır, yəni tez qızır və tez də soyuyur. Odur «temperatur dreyfi» effektinin sona çatması tez başa gəlir və belə çeviricilər uzun müddətli iş rejimi üçün daha çox yararlıdır.

Maqnit sahəsinin sıxışdırılmasının və zərbə qüvvəsinin nəzərə alınması

LE-nə təsir edən xarici qüvvənin P_x təsirindən LE hərəkətə gələrək TD-na yaxınlaşır. TD ilə LE arasındakı məsafə X azaldıqca işçi hava aralığındakı maqnit induksiya artır və səpələnmə maqnit sellərinin tutduqları həcm V və onların qapandıqları yolların orta uzunluqlarını l_{or} artırır (şəkil 2). Nəticədə işçi hava aralığının maqnit sahəsinin eynicinsliliyi pozulur. İngilis alimi Rotersin məlum düsturundan istifadə edib çeviricinin hava aralığının maqnit keçiriciliyinin hesabını aparmaq üçün aşağıdakı düsturu təklif etmək olar [4,5]:

$$\Lambda(X) = \mu_0 \frac{V(X)}{l_{or}^2(X)} \quad (3)$$

Maqnit sahəsinin sıxılması nəticəsində induktivliyin L yerdəyişmədən X asılılığı qeyri-xətti alınır:

$$L(X) = W_1^2 \Lambda(X) = W_1^2 (X + \square_{12}) \cdot \lambda(X) \quad (4)$$


$L(X)$ asılılığının qeyri-xəttiliyi qüvvə və yerdəyişmə çeviricilərində əlavə xətlər yaradır. Bu nöqsanı aradan qaldırmaq üçün TD və LE arasında $P_x = P_{\max}$ qiymətinə uyğun müəyyən $X_{\min}$ məsafəsinə nəzərdə tutmaq lazımdır. Aparılan tədqiqatlar göstərir ki, maqnit sisteminin ölçülərindən asılı olaraq bu məsafə $(5 \div 10) \cdot 10^{-3}$ m ola bilər.

LE-ni olan çeviriciləri qida gərginliyi U_1 mənbəyinə qoşduqda ilk saniyə ərzində yaranan elektrodinamik qüvvə $F_e(t)$ LE-ni sürətlə yuxarı itələyərək maqnitkeçiricisinin yuxarı yarmasına zərbə ilə vura bilər. Bu qüvvənin amplitud qiyməti $F_{\max}$ qida gərginliyinin U_1 ilk fazasından asılıdır və ağırlıq qüvvəsindən P_a bir neçə dəfə böyük ola bilər.

Zərbə qüvvəsi $F_{\max}$ levitasiya ekranının qüvvə ötürücüsünü deformasiyaya uğrada bilər və levitasiya dolağının karkasını dağıda bilər. Bəzi hallarda isə levitasiya elementinin ilkin vəziyyətini dəyişdirə bilər. Zərbə qüvvəsini aradan qaldırmaq üçün yuxarı yarmada bir neçə sarğıdan ibarət olan sarğac yerləşdirmək və onu çeviricinin TD ilə ardıcıl-əks qoşmaq lazımdır. Bu sarğacın yaratdığı əks təsir qüvvəsi zərbə qüvvəsini kompensasiya edir. Sarğac çevirici mənbəyə qoşulduqdan sonra mənbədən açılır. Sarğacın hündürlüyünü Δ_0 ilə işarə etsək onda orta çubuğun hündürlüyü belə təyin olunur:

$$\square = \square_1 + \square_2 + X_{is0_{\min}} \quad (5)$$

Burada $X_{\min}$ – LE ilə TD arasında nəzərdə tutulan minimal məsafə; X_{is} – LE-nin işçi gedışı; h_1 və h_2 – TD və LE-nin hündürlükləridir.



Şəkil 2. Maqnit sahəsinin sıxışdırılmasını və zərbə qüvvəsinin nəzərə alınmasına dair illyustrasiyalar

Ceviricinin iş rejiminin $B(H)$ maqnitlənmə xarakteristikası ilə uyğunlaşdırılması

Bir sıra LE olan çeviricilərdə TD-na verilən gərginlik U_1 dəyişdiyindən nüvədəki induksiya B_p dəyişir. İnduksiyanın dəyişmə diapazonu belə tapılır:

$$\Delta B = B_{max} - B_{min} = \frac{\Delta U_1}{\omega W_1 k_{pd} S_n} \quad (5)$$


Burada

$$B_{max} = \frac{U_{1max}}{\omega W_1 k_{pd} S_n}; \quad B_{min} = \frac{U_{1min}}{\omega W_1 k_{pd} S_n}; \quad \Delta U_1 = U_{1max} - U_{1min}. \quad (6)$$

Nüvədəki polad itgilərini azaltmaq üçün induksiyanın dəyişmə diapazonu $B(H)$ maqnitlənmə əyrisinin düz xətt hissəsindən kənara çıxmamalıdır. Verilmiş növ polad üçün $\Delta B = B_2 - B_1$ diapazonu məlum olduğundan TD-nın uclarındakı gərginliyin dəyişmə diapazonunu təyin etmək mümkündür:

$$\Delta U_1 = (\Delta B) \omega W_1 k_{pd} S_n \quad (7)$$

ΔB diapazonu $\rho_R(B)$ və $\rho_X(B)$ əyrilərindən tapılır, beləki poladın xüsusi maqnit müqavimətlərinin (ρ_R və ρ_X) minimal qiymətləri bu əyrlərdən aşkar görünür (şəkil 3).



Şəkil 3. Elektrotexniki polad üçün $\rho_R(B)$ və $\rho_X(B)$ funksional asılılıqları.

Temperatur artımlarının maksimal qiymətlərinə qoyulan məhudiyyətlər

LE olan çeviricilərin ölçüləri və istismardakı etibarlılıq onların layihəsində qızma və soyuma məsələlərinin düzgün həllindən asılıdır.

TD və LE hesabı onlar üçün tapşırıqda verilmiş buraxıla bilən (maksimal) qızma temperaturları və temperatur artımlarını nəzərə almaqla aparılır:

$$\tau_{b1} = \theta_{b1} - \theta_0; \quad \tau_{b2} = \theta_{b2} - \theta_0, \quad (8)$$

Burada τ_{b1} və τ_{b2} –TD və LE üçün verilmiş temperatur artımları; θ_{b1} və θ_{b2} –buraxıla bilən qızma temperaturları; $\theta_0 = -35^\circ \text{S}$ –ətraf mühit üçün qəbul olunmuş temperaturdur. Adətən hesabatlarda B, F, H və C sinifli izolyasiyalar üçün buraxıla bilən temperatura $\tau_b = 85^\circ \text{S}$ və $\theta_b = 120^\circ \text{S}$ qəbul olunur [6,7].

Lakin, LE olan çeviricilərdə gedişin X dəyişməsi ilə I_1 və I_2 cərəyanları dəyişir və nəticədə $X = X_{\max}$ və yaxud $P_x = P_{\max}$ olanda $\tau_1 = \tau_{1\max} > \tau_b$ və $\tau_2 = \tau_{2\max} > \tau_b$ olur. Ona görə də belə çeviricilərin layihəsi və hesabında qızma temperaturunun maksimal qiymətinə məhtudiyyətin qoyulması vacibdir.

TD və LE-nin temperatur artımları onlardan axan cərəyanların kvadratı ilə düz, soyuma səthləri S_s ilə tərs mütənəsbətdir $\tau_1 = \tau_{b1}$ və $\tau_2 = \tau_b$ şərtlərini təmin etmək üçün ilk növbədə soyuma səthlərinin S_{s1} və S_{s2} optimal qiymətlərini tapmaq lazımdır.

Bu məqsədlə qüvvə çeviricilərinin TD və LE üçün yazmaq olar:

$$\frac{S_{s1}}{r_1 + b_2^2 k^2 r_2} = \frac{I_{1\max}^2}{k_i \tau_{b1} \frac{2(P_a + P_{x\max})}{k_i \tau_{b1} \lambda W_1^2}} \quad (9)$$

$$\frac{S_{s2}}{r_2} = \frac{I_{2\max}^2}{k_i \tau_{b2}} = (b_2 k)^2 \cdot \frac{2(P_a + P_{x\max})}{k_i \tau_{b2} \lambda W_1^2}. \quad (10)$$

Buradan

$$\frac{S_{s2}}{S_{s1}} = \left(k^2 b_2^2 + \frac{r_1}{r_2} \right) \left(\frac{\tau_{b2}}{\tau_{b1}} \right) \quad (11)$$

$$P_a + P_x = \tau_{b1} \frac{k_i S_{s1} \lambda W_1^2}{2(r_1 + b_2^2 k^2 r_2)} \quad (12)$$

Alınan (11) ifadəsindən görünür ki, TD və LE-nin ölçülərinin nisbəti əsasən temperaturların (τ_{b2}/τ_{b1}) və müqavimətlərin (r_1/r_2) nisbətlərindən asılıdır. Çeviricinin girişinə təsir edən xarici qüvvənin P_x maksimal qiyməti (12) ifadəsindən göründüyü kimi əsasən τ_{b1} , S_{s1} və λ parametrlərindən asılıdır. P_x -in maksimal qiymətinə qoyulacaq məhtudiyyəti tapmaq üçün bu parametrlərin optimal qiymətlərini təyin etmək lazımdır.

4. Nəticə

LD və LE-nin hazırlanması üçün istifadə olunan elektrik keçirici materialların seçilməsi üçün qızma üçün məlum olan Furiye və Videman-Frans qanunundan istifadə etməklə levitasiya dolağının mis naqillərdən, levitasiya ekranının isə alüminiumdan hazırlanması əsaslandırılmışdır. Zərbə qüvvələrinin aradan qaldırılması üçün bir necə sarğıdan ibarət olan kompensasiya dolağından istifadə edilməsinə, maqnit sahəsinin sıxışdırılmasının təsirinin azaldılması TD ilə LE arasında minimal məsafənin nəzərdə tutulmasına, LE-nin maqnit keçiricisinin cubuqlarına toxunmaması üçün eninə elektromexaniki sərtliyin artırılmasına və «istilik dreyfinin» azaldılması şaquli dayanıqlığın artırılmasına əsaslandırılmışdır.

Ədəbiyyat

- [1] Абдуллаев Я.Р., Мамедова Г.В., Керимзаде Г.С., Пириева Н.М. “Обобщенные показатели электромагнитных устройств с левитационными элементами”. Известия ВУЗов” Приборостроение”. Т.60, № 5. с.173 – 178. Санкт-Петербург 2017.
- [2] Мамедова Г.В., Керимзаде Г.С. “Показатели анализа параметров проектирования электромагнитных устройств с левитационными элементами” Известия высших учебных заведений «Электромеханика». Научно-технический журнал, 2017, том 60, № 3, с.28 – 33.
- [3] Məmmədova G.V., Məcidov M. “Levitasiya elementli idarə olunan elektromexaniki qüvvə çeviricisinin əsas xüsusiyyətlərinin araşdırılması” Journal “Scientific discussion” (Praha, Czech Republic) ISSN 3041-4245, №54, 2021, səh. 32-35
- [4] Керимзаде Г.С., Мамедова Г.В., “Анализ параметров электрических аппаратов с левитационными элементами” Известия ВУЗов” Приборостроение”. Том 61, № 12, с.67 – 71. Санкт-Петербург. 2018.
- [5] Анализ эталонной задачи на электродинамическую левитацию. <https://www.comsol.ru/blogs/how-to-model-electrodynamic-magnetic-levitation-devices/>. 2016.
- [6] Модель тепловой подсистемы https://studopedia.ru/15_104190_model-teplovoy-podsistemi.html 2014.

[7] Kaplan B.Z., Horen Y., Cohen G.,Hellerman Y.Magnetic levitation by cha-otic oscillation: a new method // IEEE Trans. Magnetics. 2002. 38. 5. p. 3475-3481.

DƏRİN QUYULARIN QAZILMASINDA TƏTBİQ OLUNAN QAZMA QURĞUSU BUCURQADININ KINEMATİK SXEMİNİN TƏRTİBİ

Sevda Yaqub qızı Əliyeva

Dosent, "Mexanika" kafedrası, Azərbaycan Dövlət Neft və Sənaye Universiteti, Azərbaycan.
(sevda.aliyeva.66@bk.ru)

XÜLASƏ:

Ağır yüklənmiş maşınlarda zəncir ötürmələrinin başqa mexaniki ötürmələrə nisbətən geniş tətbiqi bu ötürmələrin spesifik üstünlükləri ilə izah edilir. Belə üstünlüklərin sayına, birinci növbədə valların yüksək sürətlərində və nisbətən böyük mərkəzlərarası məsafələrində böyük güclərin ötürülməsi imkanını, həm də çöl şəraitlərində montaj və demontajın nisbətən yüngüllüyünü aid etmək olar.

Ağır yüklənmiş maşınların nümayəndələri qazma qurğularıdır ki, bu qurğularda güc bir neçə yüz kilovata çatı bilər.

Müasir qazma qurğuları yerüstü avadanlıq kompleksidir, çöl və dəniz şəraitlərində neft və qaz quyularının qazılması işlərinin yerinə yetirilməsi üçün təyin edilmişdir. Bu zaman komplektləşmiş avadanlığın intiqal gücü və xarakteristikası rotorun, həm də quyudibi hidravlik və elektrik mühərriklərinin köməyi ilə qazmanı təmin edir.

Qazma qurğularının qarmaqdakı yükə uyğun gələn nominal yükqaldırma qabiliyyəti quyuların qazılma dərinliyini təyin edərək, qurğuların qaldırma sisteminin düyün və detallarının uzunömürlüyə hesabında yükü xarakterizə edir.

Açar sözlər: *montaj, transmissiya, kompleks, düyün, kinematik sxem, blok, bucurqad*

ABSTRACT

The widespread use of chain drives on heavy-duty machines in comparison with other mechanical transmissions is explained by the specific advantages of these transmissions. These advantages include, first of all, the possibility of transferring large capacities at high speeds of shaft movement and relatively large center-to-center distances, as well as the relative ease of assembly and disassembly in steppe conditions.

Representatives of heavy machines are drilling rigs, the power of which in these installations can reach several hundred kilowatts.

Modern drilling rigs are a complex of ground-based equipment designed for drilling oil and gas wells in field and offshore conditions. At the same time, the total power and characteristics of the completed equipment ensure drilling of both the rotor and the well using hydraulic and electric motors.

The nominal lifting capacity of drilling rigs corresponding to the load on the hook characterizes the load in the report on the durability of the components and parts of the lifting system of the rigs, determining the depth of drilling wells.

Keywords: *montage, transmission, complex, assembling, kinematic schemes, block, winch.*

Mövzunun aktuallığı: Maşınqayırma sənayesində istifadə olunan qazma qurğularının zəncir reduktorları gücötürmə qabiliyyətinə görə daha yüksək hesab edilənlərdəndir. Hazırda məhsuldarlığın artırılmasında bu tip reduktorların tətbiqi daha məqsədəuyğundur. Bu baxımdan tərtib edilən məqalə aktual mövzunu əhatə edir.

İşin məqsədi: Ötürülən böyük güclə əlaqədar olaraq bucurqadın ötürmə sistemində baraban valının (1249 kv-a qədər) transmissiyası və aralıq valları arasındakı zəncir ötürmələrində (12,16 və 17) daha səmərəli ölçüdə addıma malik olan zəncirlərdən istifadə etmək.

Maşınqayırma sənayesində tətbiq edilən qazma qurğularının zəncir reduktorları və ötürmə qutuları qüvvə aqreqlarlarının icraedici mexanizmlərinə gücün ötürülməsi üçün, bucurqada və rotora baraban valının və rotor masasının (zəncir ötürmələr qutuları) fırlanma sürətlərinin dəyişməsilə gücün ötürülməsi üçün təyin edilmişdir [1].

Müxtəlif markalı qazma qurğularının zəncir reduktorlarının əsas parametrləri cədvəl 1-də və cədvəl 2-də verilmişdir.

Cədvəl 1

BU-50, BU-75 və BU-80 qazma qurğularının zəncir reduktorun texniki xarakteristikası

Zəncir reduktorunun parametrləri	Qazma qurğuları			
	BU75Br	BU75BrG	BU50BrD	BU80BrD
Ötürülən maksimal güc, <i>a.g.</i>	800	410	640	1020
Ötürmə ədədi:				
Bucurqadın və rotorun transmissiyasına	2,44	1,70	1,48	1,48
Qazma nasosunun transmissiyasına	1,70	-	1,48	1,48
Transmissiya vallarının sayı	4	2	4	5
Çəki, <i>kq</i>	4970	2120	3740	6697

Cədvəl 1.2.

BU-50, BU-75 və BU-80 qazma qurğularının ötürmələr qutularının texniki xarakteristikası

Ötürmələr qutularının parametrləri	Qazma qurğuları	
	BU50BrD	BU80BrD
Ötürülən maksimal güc, <i>a.g.</i>	520	820
Bucurgadda və rotorda ötürmələrin sayı:		
düzünə	2	3
əksinə	1	1
Aparılan valın burucu momenti, <i>N-m</i> :		
nominal	13200	21100
maksimal (ən kiçik ötürmədə)	18100	27450
Aparan valın fırlanma sürəti, <i>dövr/dəq</i>	220...635	255...640
Bucurqadın ötürmə ədədi:		
I ötürmə	2,24	3,09
II ötürmə	0,77	1,47
III ötürmə	-	0,77
revers	2,09	2,10
Rotorun ötürmə ədədi:		
I ötürmə	2,68	3,22
II ötürmə	0,92	1,53
III ötürmə	-	0,80
revers	2,51	2,18

Zəncir reduktorları qüvvə aqreqlarının sayı üzrə aparıcı və gücgötürmə valları ilə bütöv gövdədə qaynaq edilir və yüksəksürətli ötürmələrlə əlaqələndirilir. Güc zəncir reduktorlarından bucurqadın və rotorun ötürmələr qutusunda, qazıma nasoslarına və kompressora verilir.

Zəncir reduktorunun sürət qutuları valların fırlanma sürətinin pilləli dəyişdirilməsi üçün təyin edilmişdir və mühərriklərin müəyyən edilmiş gücündən səmərəli istifadə etməyə imkan verir.

BU-50BrD markalı qazıma qurğusunun zəncir reduktorunun konstruksiyası şəkil 1-də təqdim edilmişdir. Belə reduktorlar bütövqaynaqlı gövdədən, dörd transmissiya vallarından və yağlama sistemindən ibarətdir. Bucurqadın qaldırıcı valına burucu momentin ötürülməsi altıcərgəli diyircəkli zəncirlərlə, qazma nasoslarının transmissiyasına isə üçcərgəli diyircəkli zəncirlərlə həyata keçirilir. İntiqal zəncirlərinin addımı $t = 31,75mm$ -dir. İntiqal zəncirlərinin və yastıq dayaqlarının yağlanması iki yağ nasosu ilə həyata keçirilir [2].

Neft mədənlərində mövcud proseslərin aparılması üçün neft-mədən maşın və avadanlıqlarına ehtiyac çox böyükdür. Bu avadanlıqların yararlı hazırlanması və bu maşınların təbii ağır mühitdə işlədilməsi istehsalçıların və istehlakçıların qarşısında böyük tələblər qoyur. İstehsalçılar maşınların konstruktiv və konstruktiv olmayan elementlərinin tələb olunan materialdan texniki dəqiqliklə hazırlanmasını təmin etməli, istehlakçılar isə maşınların səmərəli istismarına, cari və əsaslı təmirlərinə nail olmalıdırlar.


Dərinliyi 3000...6000 m olan quyuların qazılması üçün təyin edilmiş qazıma qurğularını dərin qazma üçün qazma qurğuları adlandırmaq qəbul edilmişdir, dərinliyi 6000 m-dən çox olan quyuların qazılması üçün təyin edilmiş qazma qurğuları isə çox dərin qazma üçün qazma qurğuları adlanırlar [3].

Həm dərin və həm də çox dərin qazma üçün qazma qurğuları avadanlıqlarının bütün kompleksi kəskin fərqli xarakteristikaları ilə iki qrupa bölünür:

1. Quyuların qazılması üçün təyin edilmiş avadanlıqlar.
2. Qazma prosesində endirmə-qaldırma əməliyyatlarının aparılması üçün avadanlıqlar.

Bu iki qrupun istismar imkanları və xarakteristikaları polad qazma borularının şəraitlərində Uralmaşzavodun bütün qazma qurğularında razılaşdırılmış və saxlanılmışdır.

Uralmaş 3000BD və Uralmaş 3000BG qazıma qurğuları elektriklişdirilməmiş (Uralmaş 3000BD) və elektriklişdirilmiş (Uralmaş 3000BG) rayonlarda dərinliyi 3000 m olan neft və qaz quyularının turbin və rotor qazması üçün təyin edilmişdir. Qurğuların intiqalları beşdizelli (Uralmaş 3000BD) və iki elektritmühərriklidirlər (Uralmaş 3000BG).



Şəkil 1. İkivallı U2-2-11 bucurqadının kinematik sxemi

1- mühərrik, 2, 7 və 11 – yastıqlar, 3, 4, 6, 8, 12, 15 və 16 – zənzir ötürməsi, 5 və 13 – vallar, 9 və 14 – muftalar, 10 – hidrodinamiki əyləc.

Uralmaş 3000BD və Uralmaş 3000BG qazma qurğularının kinematik sxemləri U2-2-11 bucurqadının kinematik sxemindən və bucurqadın intiqalı üçün təyin edilmiş zəncir sürətlər qutusu olan üçdizelli blokdan ibarət olan intiqaldan, rotordan bir qazma nasosundan və yalnız bir qazma nasosunun intiqalı üçün ikidizelli blokdan ibarətdir [4].

U2-2-11 bucurqadının kinematik sxemi şəkil 1-də təqdim edilmişdir.


U2-2-11 bucurqadı zəncir ötürmə qutusu intiqalından ibarət olan altısürətli zəncirlidir. U-2-2-11 bucurqadının kinematik sxemi imkan verir ki, barabanı fırlatmaq üçün altı sürət və ötürmələr qutusunun köməyiylə rotor üçün üç sürət alınsın.

U2-2-11 bucurqadının bütün zəncir ötürmələrində addımı 50,8mm və 44,45 mm olan diyircəkli zəncirlər tətbiq edilir, bu zaman baraban valına burucu momenti ötürən zəncir ötürmələri üçcərgəli 50,8 mm addımlı, burucu momenti rotorun transmissiyasına ötürən zəncir ötürmələri ikicərgəli 50,8 mm addımlı, sürətlər qutusunun və cəmləyici reduktorun zəncir ötürmələri isə dördcərgəli 44,45 mm addımlı olur.

Uralmaş 3D-76 və Uralmaş 4G-76 qazıma qurğuları dərinliyi 5000 metrə qədər olan neft və qaz quyularının turbin və rotor qazıması üçün təyin edilmişdirlər. Uralmaş 3D-76 qazıma qurğusunun intiqalı iki bloka bölünmüş beşdizellidir, 4G-76 qazıma qurğusunun intiqalı isə dəyişən cərəyan elektrikliidir.


Uralmaş 3D-76 ikibloklı dizel intiqalının birinci bloku bucurqadın, rotorun və bir qazma nasosunun və kompressorun intiqalı üçün təyin edilmişdir. İkinci blok-ikinci qazma nasosunun intiqalı üçündür.

Uralmaş 3D-76 və Uralmaş 4G-76 qazma qurğularının kinematik sxemləri U2-5-5 bucurqadının kinematik sxemlərindən, rotordan, bucurqaddan, üçdizelli blokdan və ikidizelli (Uralmaş 3D-76) dəyişən cərəyan elektrik intiqalından (Uralmaş 4G-76), qazma nasoslarından və kompressordan ibarətdir [5].



Şəkil 2. U2-5-5 bucurqadının kinematik sxemi.

1 və 14 - yastıqlar, 2 və 13 – dişli muftalar, 3, 5, 9 və 15 – vallar, 4 – ulduzcuq, 6 və 8 – kardan valları, 7, 10 – şinli-pnevmatik muftalar, 11 – konus dişli ötürmə, 12 - hidrodinamiki əyləc, 16 – pnevmokamer muftası.



Şəkil 3. LBU-1100M1 qazıma bucurqadı

1, 9 və 20 – mühərriklər, 2 – idarəmə qutusu, 3 və 14 – muftalar, 4 və 10 – əsas, 5 – dişli mufta, 6 – soyutma borusu, 7 – baraban, 8 – yiv birləşməsi, 11 – aparıcı ulduzcuq, 12 – kranşteyn, 13 – dayaq, 14 – zəncir tənzimləyicisi, 15 və 19 – ulduzcuqlar, 16 və 18 – zəncirlər

U2-5-5 bucurqadının kinematik sxemi şəkil 2-də təqdim edilib.

U2-5-5 bucurqadının kinematik sxemində gücün sayğac valına ötürülməsi üçün zəncir ötürmələrindən istifadə edilir. Bütün zəncir ötürmələrində ikicərgəli diyircəkli 50,8 mm addımlı zəncirlər tətbiq edilir.

Dizelhidravlik inteqrallı Uralmaş 4000 DQU və Uralmaş 5000 DQU qazma qurğuları 4000 m dərinliyə və elektriklişdirilmiş rayonlarda-5000m dərinliyə (Uralmaş 5000 DQU) turbin və rotorla quyuların qazılması üçün təklif edilir.

LBU-1100M1 qazma bucurqadının kinematik sxemi şəkil 3-də təqdim edilib.

LBU-1100M1 endirmə-qaldırma aqreqatının kinematik sxemi III bucurqadın kinematik sxemindən, II zəncir ötürmələri qutusunda, I balta verimi tənzimləyicisindən və IV rotor inteqrallı transmissiyasından ibarətdir [6].

LBU 1100M endirmə-qaldırma aqreqatının bütün zəncir ötürmələrində üçcərgəli diyircəkli 50,8 mm addımlı zəncirlər tətbiq edilir.

Uralmaş 4000GU və Uralmaş 5000GU qazma qurğuları 4000 m dərinliyə turbin və rotor qazması üçün (Uralmaş 4000GU) və elektriklişdirilmiş rayonlarda 5000 m-ə qədər (Uralmaş 5000GU) təyin edilmişdir.

Hər iki qazma qurğularının kinematik sxemləri LBU-1100M endirmə-qaldırma aqreqatının kinematik sxemlərindən, bucurqadın və rotorun bucurqadından, həm də qazma nasoslarının inteqrallının kinematik sxemlərindən ibarətdir.

Zəncir ötürmələrinin tipölçüləri Uralmaş 4000 DQU və Uralmaş 5000 DQU qazma qurğularında olduğu kimidirlər.

Uralmaş 200DQ-IV və Uralmaş 200G-IV qazma qurğuları 6500 dərinliyə quyuların turbin və rotor qazması üçün təyin edilmişdir, özü də elektriklişdirilməmiş (Uralmaş 200DQ-IV) və elektriklişdirilmiş (Uralmaş 200G-IV) rayonlarda.

Bu qazma qurğularının kinematik sxemləri LBU-1700 endirmə-qaldırma aqreqatının

kinematik sxemindən, bucurqadın və rotorun bucurqadından, həm də qazıma nasoslarının intiqalının kinematik sxemlərindən ibarətdir.

Məxsusi bucurqadın, zəncirli sürətlər qutusunun və baltanın quyu dibinə verilməsi tənzimləyicisinin kinematik sxemlərindən ibarət olan LBU-1700 bucurqadının kinematik sxemi, intiqal zəncirlərinin tipölçüləri müstəsna olmaqla LBU-1100 bucurqadının kinematik sxeminə analojidir:

• NƏTİCƏ

✓ ötürülən böyük güclə əlaqədar olaraq bucurqadın ötürmə sistemində baraban valının (1249 kvт-a qədər) transmissiya və aralıq valları arasındakı (şəkil 1 - 12,16 və 17) zəncir ötürmələrində altıcərgəli diyircəkli, 44,45 mm addımlı zəncirlərdən istifadə edilmişdir;

✓ üçcərgəli köynəkli 50,8 mm addımlı zəncir aralıq valından baraban valına ötürülən zəncir ötürməsi I, II, III sürətlər üçün (şəkil 3) üçcərgəli diyircəkli, 63,5 mm addımlı zəncirlə əvəz edilmişdir.

• ƏDƏBİYYAT

1. Abdullayev A.H., Məmmədov R.K., Güməyev M.H. Maşın detalları və konstruksiyaetmənin əsasları. Bakı, Elm, 2002. - 462 s.
2. Kərimov Z.H. Maşın hissələri və yükqaldırıcı və nəqlədiç mışınlar. Bakı. Maarif. 2002 – 485s.
3. Fətəliyev V.M. Sınaq stendlərinin konstruksiyaları. Bakı. ADNA. 2002-45 s.
4. Решетов Д.Н. Испытательные стенды.М., Машиностроение, 1986 – 393s.
5. Damirova C.R., Abbasova S. Research of the problem of optimization and development of a calculation method for two-stage chain drives used in heavy industrial vehicles in conditions of economic efficiency, “EUREKA: Physics and Engineering” №4. -2021
6. www.bmstu.ru. Основы конструирования и детали машин. Курс ОКДМ. Цепные передачи.

Həll olmuş qazların analizi metodu əsasında güc transformatorlarındakı nasazlıqların qeyri-səlis məntiq nəzəriyyəsi ilə diaqnostikası

Diagnostics of faults in power transformers by fuzzy logic theory based on the method of dissolved gas analysis

Tural Aliyev^{*1} 

¹ Energetika fakültəsi, ADNSU, Bakı, Azərbaycan
(aliyev.tural@asoiu.edu.az)

Referat - Güc transformatorunun qalıq ömrünün diaqnostikası və monitorinqi üçün mövcud üsullar öyrənilmişdir. Transformatorlar üçün avtomatlaşdırılmış monitorinq və idarəetmə sisteminin ağac strukturuna daxil edilmiş və qeyri-səlis məntiq əsasında bu səhvlərin təhlili yolu ilə həyata keçirilən yeni diaqnostika sisteminin işlənilib hazırlanmasının nəticələri təqdim olunmuşdur. Qeyri-səlis çoxluqlarla işləmək və lingvistik dəyişənləri təqdim etməklə, proqram koduna çevrilən ağac strukturundan istifadə edərək alqoritm yaradılmışdır. Sistemin işləmə prinsipi yağlı güc transformatorunun seçilmiş diaqnostik parametrlərindən istifadə etməklə göstərilir.

Açar sözlər: güc transformatoru, qeyri-səlis məntiq, diaqnostika, monitorinq

Abstract - The available methods for diagnosing and monitoring the residual life of the power transformer have been studied. The results of the development of a new diagnostic system, which is included in the tree structure of the automated monitoring and control system for transformers and is implemented through the analysis of these errors based on fuzzy logic, are presented. By working with fuzzy sets and introducing linguistic variables, an algorithm was created using a tree structure that was converted into program code. The principle of operation of the system is shown in the selected diagnostic parameters of the power oil transformer.

Keywords : power transformer, fuzzy logic, diagnostic, monitoring

1.Giriş

Elektrik şəbəkələrinin, elektrik stansiyalarının və enerji təchizatı sistemlərinin iqtisadi məqsədəuyğunluğu və səmərəliliyi daha çox güc transformatorlarının işindən asılıdır [1, 2]. Güc transformatorlarının istismarı zamanı qəzalar, fəvqəladə açılmalar, həm transformatorun bərpası zərurəti, həm də istehlakçıların enerji təchizatının kəsilməsi ilə əlaqədar maliyyə itkilərinə səbəb olur [3-5]. Hal-hazırda transformatorların aqreqlərinin sınaqlarının aparıldığı aparat və proqram kompleksləri mövcuddur ki, bununla da müntəzəm yoxlama cədvəlini tənzimləmək mümkündür [6, 7].

Struktur baxımdan komplekslər aşağıdakı səviyyələrlə təmsil olunur:


- 1-ci səviyyə (məlumat toplama səviyyəsi) – icraçılar, müxtəlif növ interfeys və protokollara malik transformator avadanlıqlarında yerləşən ilkin sensorlar və ölçü sistemləridir;
- 2-ci səviyyə (ilkin məlumatların işlənməsi səviyyəsi) – soyutma sisteminin idarəetmə əmrlərinin formalaşdırılması, PLC-dən istifadə etməklə daha yüksək saxlama səviyyələrində məlumat mübadiləsi;
- 3-cü səviyyə (məlumatların konsolidasiyası, saxlanması və vizual təftişi) operatorun aşağıdakı funksiyaların həyata keçirilməsini təmin edən avtomatlaşdırılmış iş yeridir: enerji qurğusunun digər avtomatlaşdırılmış idarəetmə sistemlərinə informasiyanın riyazi çevrilməsi və kompleks şəkildə ötürülməsi, obyektin məsafədən idarə edilməsi, transformator sisteminin hesablanmış və müşahidə olunan parametrlərinin vizual yoxlanılması, jurnallarda və arxivlərdə toplanmış məlumatlarla işlərə nəzarət.

Hazırda güc transformatorlarının nasazlığının iki əsas növü müəyyən edilə bilər: elektrik zədələnməsi və mexaniki qüsurlar [8, 9]. Birinci növ nasazlıqlara dolaqlararası nasazlıqlar, kağız izolyasiyasının pozulması, transformator nüvəsi dövrəsinin zədələnməsi və s. Mexanik qüsurlara aşağıdakılar aid edilə bilər: korpusun zədələnməsi, mexaniki aşınma, köhnəlmə prosesləri, boltlu birləşmələrdə qövs boşalmaları, soyutma sisteminin plomunun sıradan çıxması, ventilyatorun və ya soyuducu nasosun sıradan çıxması, genişlənmə çətinində lilin əmələ gəlməsi, yağın çirklənməsi və s.

[10]-da avadanlığın diaqnostika edilmədiyi halda, nasazlıqların sayının artma ehtimalının 1% əvəzinə 20%-ə qədər olduğu və bu günə qədər bildirildiyi qədər daha az olduğu müzakirə edilir. Avadanlıqların texniki vəziyyətinin diaqnostikasının məqsədi üç növ vəzifəyə bölünə bilər. Ən çox istifadə edilən tapşırıq növü sistemin texniki vəziyyətinin müəyyən bir zaman anında aşkar edilməsidir. İkinci növ tapşırıq proqnozlaşdırma, gələcək üçün texniki vəziyyətin hesablanmasıdır. Üçüncü növ (genesis) keçmişdəki vaxt intervalına əsasən texniki vəziyyəti müəyyən etməyi nəzərdə tutur.

2.Qeyri-səlis məntiqə əsaslanan transformator diaqnostika sisteminin algoritmi

Məqalədə TDTN-63000/110 transformatorunun sensorlarından gələn siqnalların işlənməsi algoritmini nəzərdən keçirilmişdir. Güc transformatorunun vəziyyəti 16 parametərə görə idarə olunur (Cədvəl 1). Şəkil 1 qüsuru aşkar etmək üçün diaqnostik algoritmin diaqramını göstərir. Bloklar daxilində şərtlərdən istifadə bu və ya digər parametrlərin dəyərinin hansı diapazona aid olduğunu müəyyən etməyə imkan verir. Diaqramda görə, parametrlin ölçülməsi başa çatdıqdan sonra əməliyyat vəziyyəti diapazonuna uyğunluq testi başlayır. Uyğunsuzluq halında, bu parametrlin sonrakı sınaqları zamanı qüsurlar müəyyən edilir. Parametrlərin istismar texniki vəziyyətinin diapazonuna uyğun olduqda, növbəti parametr emal edilir.



Şəkil 1. Məlumatların işlənməsi algoritmi

Təklif olunan diaqnostika sistemi qeyri-səlis məntiqin qayda bazasından istifadə edərək transformatorun diaqnostikası zamanı səhvlərin verilənlərin öyrənilməsi ilə həyata keçirilir. Bu tip alqoritm gizli çoxluqların operandlarını əhatə edir, lingvistik dəyişənləri təqdim edir və bundan sonra verilənlərin təqdimatı daxil olan məlumatların işlənməsi üçün proqram koduna çevrilir.

Gizli çoxluq A öz tərkib sahəsinin gizli sərhədlərinə malikdir. X bir çoxluqdan digərinə keçəndə tərkibi düzgün bir şəkildə dəyişir.

Gizli çoxluq uyğun toplananlar vasitəsilə müəyyən edilir və aşağıdakı düsturla müəyyən edilir:

$$A = \frac{\mu_A \cdot x}{x}$$

R xarakteristikası x -ə aid olduqda, xarakterik funksiya 1-ə bərabərdir, yox əgər x bu xassəni təmin etmirsə sıfırdır. Üzvlük funksiyası x elementinin A alt çoxluğuna nə dərəcədə aid olduğunu (0-dan 1-ə qədər) ifadə edir.

Gizli alqoritmə həyata keçirmək üçün qrafik qurarkən aşağıdakı qaydalar müəyyən edilmişdir. Xətlər qeyri-səlis alqoritmə şərti gizli operatorları olmayan hissələrini, qövsələrin qoşulduğu alqoritmədəki qovşaqlar isə şərti gizli operatorları ifadə edir. Hər bir alqoritmənin başlanğıcı qövsün yaranmasına səbəb olan bir qovşaqlardan ibarətdir, burada digər qövsələr daxil deyil.


Düydən çıxan hər bir budaq əvvəlki budaq operatoru və ya yeni şərti operator tərəfindən alqoritmənin sonuna qədər məhdudlaşdırılır. Belə gizli operator əvvəlki gələnləri emal etdikdən sonra yeni budaq yaradır. Budaqlar birinci qovşaqlardan çıxır, ikinci qovşağa daxil olanda funksiyaları yerinə yetirən, yeni budaq yaradan və ya alqoritməni bitirən növbəti şərti operator tərəfindən məhdudlaşdırılır [11-13].

3. Matlab proqram təminatından istifadə və qeyri-səlis nəticənin emalı

Məqalədə TDTN-63000/110 transformatorunun vəziyyətinə nəzarət etmək və güc transformatorunun quruluşunu qurmaq üçün 16 sensor parametrləri təyin edirlər. Giriş üçün diaqnostik xüsusiyyətlərin x vektorunu aşağıdakı kimi ifadə edək:

$$x = [x_1, x_2, \dots, x_n]$$

X vektoru üçün təyinatlar, diaqnostik parametrlər və ölçmə diapazonları cədvəl 1-də verilmişdir.



Şəkil 2. Güc transformatoru üçün qeyri-səlis nəticənin struktur iyerarxiya diaqramı; x_1 - x_{16} - sistemin giriş diaqnostik amilləri; y_i - ara parametrlər; Q - sistem çıxışı


Cədvəl 1. Güc transformatorunun qalan ömrünün hesablanması üçün parametrlərin seçilməsi

Təyinat	Diagnostik parametrlər	Ölçmə diapazonları giriş dəyərləri
x_1	İzolyasiya yüksüz cərəyanı, % faiz dərəcəsi	0 - 0.3
x_2	Yüksüz vəziyyətdə itkilər, kVt	0 - 0.15
x_3	Dolaq izolyasiyasının aşınma əmsalı	0 - 1
x_4	Dolaq izolyasiyasının ümumiləşdirilmiş diaqnostik parametri	0 - 0,1
x_5	Dolaq izolyasiyasının yüksüz işləmə itkiləri, kVt	0 - 0,5
x_6	Gövdəyə nisbətən dolağın izolyasiya müqaviməti, MOhm	0 - 1
x_7	Dolaq izolyasiyasının ən çox qızan nöqtəsinin temperaturu, °C	0 - 140
x_8	Yağın temperaturu, °C	0 - 140
x_9	Yağın təzyiqi, kPa	1 - 1,2
x_{10}	Kontaktların omik müqaviməti, MOm	0 - 0,025
x_{11}	Kontakt təzyiqi, kgf	4 - 7,5
x_{12}	Çəndə qüsurların və zədələrin varlığı	0 - 1
x_{13}	Kapasitiv giriş cərəyanı, A	0 - 1
x_{14}	Giriş izolyasiya müqaviməti, MOm	0 - 500 (500 aşağı zərər səviyyəsi)
x_{15}	Giriş temperaturu, °C	95 - 140
x_{16}	Giriş temperaturu, °C	60 - 95
$y_1, y_2, y_3, y_4, y_5,$ $y_6, y_7, y_8, q_1, q_2,$ q_3, q_4, q_5, q_6 Q	Genişlənmiş təsir edən amillər Ağac kökü	(95 aşağı zərər səviyyəsi)


Qeyri-səlis məntiqdən istifadə edərək güc transformatorunun qalan ömrünü təyin etmək üçün MatLab Fuzzy Logic Toolbox proqram mühitini tətbiq edək. İyerarxiyaya görə bağlanmış ağac budaqları sayəsində nəticənin gizli çıxışı həyata keçirilir. Funksiya diskret dəyərləri olan 16 girişi çağırmaqla başlayır, x_1 - x_{16} parametrləri göstərilən dəyərləri alır. x_1 -dən x_{16} -a qədər olan amillərin qiymətləri termin kimi təqdim edilə bilər: 'H' - aşağı; 'HC' - orta səviyyədən aşağı; 'C' - orta; 'BC' - orta səviyyədən yuxarı; 'B' - yüksək. Qrafik qovşağındakı əməliyyat gizli giriş məlumatları ilə məntiqi nəticə çıxardıqda Qauss üzvlük funksiyası tərəfindən yerinə yetirilir. Sonra, bir gizli alt çoxluğun digərlərinə üzvlüyünün qiymətləndirilməsi müəyyən edilir.

Şəkil 3 qeyri-səlis məntiq alətlər qutusunda istifadə etməklə bilik bazası kompilyasiyasının iş pəncərəsinin nümunəsini təqdim edir.

Yaradılmış proqramda güc transformatorunun qalıq ömrünü təyin etmək üçün istənilən sayda giriş faktorlarını nəzərə almaq mümkündür. Şəkil 4 zamanla təsir edən amillərdən asılı olaraq güc transformatorunun qalıq ömrünün qeyri-səlis simulyasiya sisteminin işinin ilkin nəticəsini təqdim edir.



Şəkil 3. y_8 üçün qeyri-səlis bilik bazası və y_8 üçün qeyri-səlis sistemin Rule Editor bilik bazası



Şəkil 4. Zamanla güc transformatorunun qalıq ömrünün dəyişməsi

4.Nəticə

İşin əsas nəticələri:

1. Üç fazlı güc transformatorları üçün əsas nasazlıq və nasazlıqların növləri nəzərdən keçirilmişdir.

2. Nasazlıqlar və nasazlıqların təhlili əsasında diaqnostik xüsusiyyətlər seçilmiş və monitoring edilən parametrlərin siyahısı hazırlanmışdır. Qüsurların səbəb-nəticə əlaqələrinin sxemləri, diaqnostik xüsusiyyətləri və parametrləri qurulmuşdur.

3. Güc transformatorunun vəziyyətini təyin etmək üçün qrafik modelinin qurulması prinsipi işlənilib hazırlanmışdır.

4. Güc transformatorunun qalıq ömrünün qiymətləndirilməsi metodologiyası hazırlanmışdır.

5. Transformatorun vəziyyətinin qiymətləndirilməsi metodologiyasının praktiki tətbiqi nümunələri təqdim edilmişdir. Nəticə qalıq ömrünün dəyişməsinin seçilmiş parametrlərdən asılılığı şəklində təqdim olunur.

Qeyri-səlis məntiqə əsaslanan alqoritm müəyyən müddət ərzində transformatorun işləməsi haqqında məlumatların sql faylından verilənləri emal etməyə imkan verir [14]. Güc transformatorunun qeyri-sabit işləməsinin vaxt intervalı ayrılır; dövrün məlumatları Matlab proqram təminatından istifadə edərək süni neyron şəbəkəsinin modelini qurmaq üçün istifadə olunur: məlumatların toplanması, ilkin emal (normallaşdırma və təsadüfiləşdirmə), şəbəkənin qurulması, onun təlimi və performans testi. Bu şəbəkə diaqnostika və transformatorun parametrlərinin qiymətlərinin və texniki vəziyyətinin proqnozlaşdırılması üçün tətbiq edilir.

Diaqnostika vasitələrinin təhlili və güc transformatorunun qalıq saatlarının müəyyən edilməsi, mövcud texnikanın artıq yaranmış qüsuru müəyyən etməyə yönəldiyi qənaətinə gəlməyə imkan verir. Təklif olunan metodologiya gələcəkdə güc transformatorunun nasazlığının və nasazlığının baş verməsini proqnozlaşdırmaq üçün avtomatlaşdırılmış sistemin tətbiqinə imkan verir.

Ədəbiyyat

1. Abramovich B N 2018 J. of Mining Institute 229 31–40
2. Kolesnichenko S V and Afanaseva O V 2018 J. of Mining Institute 230 167–75
3. Abramovich B N, Sychev Y A, Kuznetsov P A and Zimin R Yu 2018 IOP Conf. ser. Earth and Environmental Sci. 194 052001
4. Skamyin A N and Kovalchuk M S 2018 IEEE Conf. of Russian Young Researchers in Electrical and Electronic Engineering ElConRus 1 780–3
5. Andreev K A 2012 Proc. of Tula State University Technical sci. 1 389–94
6. Kostinsky S S 2018 News of higher educational institutions Energy problems 20 1–2
7. Lila V B and Kostyukov A V 2013 Engineer. Bull. of the Don 24 22
8. Popov G V 2012 Issues of diagnostics of power transformers (Ivanovo: State Power University named after V I Lenin)
9. Nikolaev A A, Khrumshina E A and Nikolaev A A 2018 Electrotechnical systems and complexes 1 48–54
10. Vdoviko V P 2009 Power industry 4 76–83
11. Kosach A A and Kovshov E E 2018 Cloud of science 5(3) 524–31
12. Yachikov I M, Larina T P and Khrumshina E A 2018 Herald of the South Ural State University Ser. Computer technology management electronics 18(2) 81–92

13. Fedorov V L 2018 Omsk Scientific Herald 5 82–9

14. Ivanova T S and Malarev V I 2018 Certificate of state registration of the program no. RU 2018663074 of 10.19.2018

Multifractal Analysis and Ensemble Learning Approach for Diagnosing Developmental Coordination Disorder from EEG Signals

EEG Sinyallerinden Gelişimsel Koordinasyon Bozukluğu Teşhisi için Multifraktal Analiz ve Topluluk Öğrenme Yaklaşımı

Hanife GÖKER *¹ 

¹ Department of Electrical Electronics Engineering, Kutahya Dumlupınar University, Kutahya, Turkey

(hanife.goker@dpu.edu.tr)

Abstract— Developmental coordination disorder is a neurodevelopmental disorder characterized by motor coordination problems that affect activities of daily living and academic achievement. Although common, it is less well defined by experts. In this study is aimed to diagnose of developmental coordination disorder from electroencephalography (EEG) signals using the multifractal analysis and ensemble learning approach. The dataset consists of EEG signals recorded from 16 developmental coordination disorder patients and 16 healthy controls. Feature vectors were extracted by calculating multifractal 1-D wavelet leader estimates. The performances of Bagging, Total Boost, Robust Boost, Logit Boost, AdaboostM1, and Gentle Boost ensemble learning methods were compared by using the created feature vectors. As a result of experiments, the Gentle Boost ensemble learning method had the highest performance. The ensemble learning method had achieved 94.06% sensitivity, 98.96% precision, 99.01% specificity, 93.18% MCC%, 96.45% f1-score, and 96.53% accuracy.

Keywords : Signal processing, electroencephalography, ensemble learning, multifractal analysis, developmental coordination disorder.

Özetçe— Gelişimsel koordinasyon bozukluğu, günlük yaşam aktivitelerini ve akademik başarıyı etkileyen motor koordinasyon sorunları ile karakterize nöro-gelişimsel bir bozukluktur. Yaygın olmasına rağmen, uzmanlar tarafından daha az tanımlanmaktadır. Bu çalışmada, multifraktal analiz ve topluluk öğrenme yaklaşımı kullanılarak elektroensefalografi (EEG) sinyallerinden gelişimsel koordinasyon bozukluğu tanısının konulması amaçlanmaktadır. Veri seti, 16 gelişimsel koordinasyon bozukluğu hastası ve 16 sağlıklı kontrolden kaydedilen EEG sinyallerinden oluşmaktadır. Özellik vektörleri, multifraktal 1-D dalgacık lideri tahminleri hesaplanarak çıkarıldı. Oluşturulan öznelik vektörleri kullanılarak Bagging, Total Boost, Robust Boost, Logit Boost, AdaboostM1 ve Gentle Boost topluluk öğrenme yöntemlerinin performansları karşılaştırılmıştır. Deneyler sonucunda, Gentle Boost topluluk öğrenme yöntemi en yüksek performansa sahiptir. Gentle Boost topluluk öğrenme yöntemi %94.06 duyarlılık, %98.96 kesinlik, %99.01 özgüllük, %93.18 MCC, %96.45 f1-skoru ve %96.53 doğruluk elde etmiştir.

Anahtar Kelimeler : Sinyal işleme, elektroensefalografi, topluluk öğrenme, multifraktal analiz, gelişimsel koordinasyon bozukluğu.

1. Introduction

Developmental coordination disorder (DCD) is a neuro-developmental condition marked by impairments in the development of motor coordination. The uncoordinated movements of children with DCD lead to performance difficulties in academic settings and in activities of daily living (Caçola & Lage, 2019). Children with DCD show characteristic difficulties in performing gross and/or fine motor skills relative to their peers' level (American Psychiatric Association, 2013). Although the exact cause of DCD is unknown, it affects about 5 out of every 100 people worldwide (Biotteau et al., 2019). It directly affects many areas of quality of life, including psychological, physical, and social functioning. Therefore, children with DCD participate less in school and community settings than their peers (Izadi-Najafabadi et al., 2019).

DCD usually begins to show symptoms in the child's early years (Blank, 2012). Early detection of DCD can provide access to educational strategies. If the family and school environments are modified in accordance with the child's diagnosis, they are more likely to succeed. The secondary consequences of DCD (depression, anxiety, social withdrawal, self-esteem or loss of confidence) are therefore preventable (Biotteau et al., 2019). DCD is recognized in the early stages by retardation in motor developmental stages. Generally, parents apply to the clinic because of the child's frequent falls and clumsy behaviors. In addition to these symptoms; sensory sensitivities such as not being able to touch furry fabrics and fruits are also sensory symptoms in infancy. The diagnosis of DCD is made by a multidisciplinary team consisting of experienced physicians (child and adolescent psychiatrist, child neurologist, developmental pediatrician), occupational therapists and physiotherapists using DSM-5 criteria. Accurate diagnosis of DCD requires the active collaboration of different disciplines (Blank, 2012). Computed tomography, magnetic resonance imaging (MRI), and EEG are used to support expert in the detection of many neurological diseases (Tosun & Çetin, 2022). EEG characterizes brain activity by recording the changes and distribution of electrical potential on the scalp. EEG, which is the most common non-invasive brain neuro-electrical signal detection method, is widely used in the clinical evaluation of attention deficit and hyperactivity disorder, Alzheimer's, schizophrenia, epilepsy and some other neurological diseases (Qin & Gao, 2021). EEG is preferred more than neuroimaging techniques for diagnosis of diseases because it is portable, noninvasive, cheaper, and requires less equipment. In addition, findings obtained using EEG can be easily exported for daily use in the clinic (Gomez-Pilar et.al, 2020). Early diagnosis of diseases provides an opportunity for early treatment. Therefore, EEG is particularly promising.

In the relevant literature, studies investigating the link between DCD and EEG signals are limited. Tsai et al. (2012) states that children with DCD have longer reaction times and lower EEG values than their peers. Children with DCD spend less effort in responding and evaluating, and correcting mistakes also uses less neural resources. Martinez-Manzanera et al. (2018) classified DCD patients, healthy controls, and ataxia (not being able to coordinate movement due to damage to the cerebellum) patients. They used the Hidden Markov model and the Support Vector Machine (SVM) algorithm. The motoric movement data of the participants were recorded with the help of sensors. They detected 80%, 85.7% and 70% accuracy in the classification of control, DCD and ataxia, respectively (Martinez-Manzanera et al., 2018). Although its interest in EEG analysis has increased in recent years with the introduction of ML and deep learning techniques, studies investigating the early diagnosis of DCD from EEG signals are extremely limited. There is a need to conduct new studies and compare the results. Because, the use of EEG in examining PD has not been fully confirmed and the number of studies has been limited.

We proposed a classification model that effectively combines multifractal analysis and ensemble learning approach for diagnosing DCD from EEG signals. The main contributions of this study were as follows:

- a) An automatic ensemble learning model, which efficiently combines multifractal analysis and Gentle Boost ensemble learning method, was used for early diagnose of DCD from EEG signals.
- b) Features were extracted from raw EEG signals by multifractal 1-D wavelet leader estimates. Wavelet leaders are effective in improving classification performance.

- c) The performances of Bagging, Total Boost, Robust Boost, Logit Boost, AdaboostM1, and Gentle Boost ensemble learning methods were compared to determine the best classification performance using extracted feature vectors.

2. Material and Method

2.1. Proposed Method:

The proposed model presents the use of multifractal analysis and ensemble learning approach to auto-diagnose DCD from EEG signals. Features were extracted from raw EEG signals by multifractal 1-D wavelet leader estimates method. The performances of ensemble learning methods were compared using extracted feature vectors, in the classification of EEG-based DCD. The application steps of the proposed model are given in Figure 1.




Figure 1. The application steps of the proposed model

2.2. Dataset:

The dataset containing EEG signals from DCD patients and healthy controls (HC) was used in this study. EEG signals were recorded from 32 subjects (16 DCD and 16 HC) by Vařeka et al. (2017). EEG signals were recorded with a 19-channel BrainAmp DC device labeled in accordance with an international 10-20 system at 1 kHz sampling frequency. The electrodes placed in Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 and O2 (Vařeka et al., 2017). Figure 2 shows the 10-20 electrode layout.




Figure 2. Electrodes positioning for the international 10-20 system (Vařeka et al., 2017)

Also, in the original dataset, the raw EEG signals were filtered using an analog band pass filter with cutoff frequencies of 0.1 and 250 Hz (Vařeka et al., 2017).

2.3. Feature Extraction with Multifractal Analysis:

Feature extraction is the process of selecting a small subset of the most suitable features from generating the first features from the raw signals. Feature extraction reduces the variability and high dimensionality found in raw data and identifies variables that capture distinctive and salient parts of the input signal. It not only reduces the search space by reducing the size, but also improves the classification quality by reducing the processing complexity.

In the study, multifractal 1-D wavelet leader method (dwtleader) was used for feature extraction. Wavelet transform is widely used in machine and deep learning models to reduce size and extract distinctive features from signals or images (Al-Qerem et.al, 2020). Wavelet transform is used to decompose signals into sub-signals by gradually breaking them into high and low frequency components. The main purpose of the conversion process is to obtain the signal coefficients and recombine the obtained coefficients to obtain the linear combination of the signal. By means of these wavelet coefficients, the signal can be analyzed at different resolutions and frequency ranges (Foroumandi et. al, 2021). Wavelet leaders are derived from critically sampled discrete wavelet transform (DWT) coefficients. Wavelet leaders are more effective in improving classification performance than wavelet coefficients in multifractal formalism (Gadhoumi et. al, 2018).

2.4. Classification with Ensemble Learning

Ensemble learning methods use multiple learning algorithms to produce better predictive performance than could be produced from any of the constituent learning algorithms alone. Ensemble learning is good at reducing high variance and improves performance by reducing bias (Dong et al., 2020). The basis of community learning methods is based on the principle that decisions taken from many points will contain healthier results than a decision taken from a single point. The risk that a classifier's decision will be incorrect is higher than the risk that the joint decision of more than one classifier will be incorrect. In this context, the joint decision of multiple classifiers is more reliable and has higher accuracy than the decision of a classifier. Bagging and boosting ensemble learning methods are widely used.

2.4.1. Boosting

Boosting involves gradually constructing an ensemble by training each new model instance to emphasize the training instances that previous models misclassified (Chutia et al., 2017). Iterative operations are applied in the boosting method. A powerful classifier is obtained with the boosting method in order to prevent the same errors from occurring by taking into account the errors in the previous estimation in each iterative process (Zhou, 2012). The formula of the boosting method is given in equation 1 (Akcan and Sertbaş, 2021):

$$H_m(x) = \sum_{m=1}^M y_m h_m(x) \quad [m=1, \dots, M] \quad (1)$$

In equation 1, $h_m(x)$ represents the base classifier; y_m represents the target (m.) value and is chosen at each stage to minimize the loss function. Total Boost, Robust Boost, Logit Boost, AdaboostM1, and Gentle Boost methods are popular.

2.4.2. Bagging

The bagging ensemble learning method, which is an abbreviation of bootstrap aggregating, is based on the bootstrap sampling method. The bagging method consists of three steps (i) sub-sampling the training set randomly to generate the sub-training sets, (ii) utilizing these sub-training sets to train numerous weak models independently, and (iii) merging the outcome of these models by voting technique (Aouedi et al., 2022). The formula of the bagging method is given in equation 2 (Akcan and Sertbaş, 2021):

$$c_i = \operatorname{argmax}_i \left\{ \frac{1}{N} \sum_{T=1}^{MN} h_T(x, c_i) \right\} \quad [T=1, \dots, N] \quad (2)$$

In Equation 2, T represents the training subset and h_T represents the prediction model. Average class score; takes the class predicted with the highest mean score calculated in all $h_T(x, c_i)$ models.

2.5. Splitting Dataset into Training and Testing

The dataset was separated into the training and test dataset using the holdout method. The dataset consists of EEG recordings taken from 32 subjects using 19 channels. 1/3 of the dataset was divided as the test dataset (202) and 2/3 of the dataset as the training dataset (406). The distribution of each group in the training and test datasets is given in Table 1.

Table 1. Splitting dataset into training and testing

Dataset	Labels	Number of datasets	Total
Training	DCD	208	406
	HC	198	
Testing	DCD	96	202
	HC	106	

While the model was trained with the training dataset, the model was checked using the 1/3 dataset reserved for testing.

3. Experimental Results

In this study, the performances of ensemble learning methods were compared using the feature vectors extracted by the Multifractal Analysis method for automatic detection of DCD. 10-second raw EEG signals from the Fp1 channel of DCD and HC groups are given in Figure 3.




Figure 3. Raw EEG signals plot

EEG signals on other channels had similar characteristics. The results of the Bagging, Total Boost, Robust Boost, Logit Boost, AdaboostM1, and Gentle Boost ensemble learning methods were analyzed using the feature vectors extracted using the multifractal analysis method. Confusion matrix parameters of ensemble learning methods, number of incorrectly classified samples and correctly classified sample numbers are presented in Table 2.

Table 2. Confusion matrix parameters of ensemble learning methods


Ensemble learning methods	Confusion matrix parameters				Incorrectly classified (FP+FN)	Correctly classified (TP+TN)
	TP	FP	FN	TN		
Bagging	91	5	11	95	16	186
Total Boost	92	4	8	98	12	190
Robust Boost	94	2	10	96	12	190
Logit Boost	94	2	7	99	9	193
AdaboostM1	94	2	6	100	8	194
Gentle Boost	95	1	6	100	7	195

When the confusion matrix parameters of the ensemble learning methods in Table 2 are examined, the algorithm with the highest number of correctly classified data is Gentle Boost. The total number of correctly classified data in the confusion matrix parameters of the Gentle Boost algorithm is 195 and the total number of incorrectly classified data is 7. The performance of the proposed model was evaluated with sensitivity, precision, specificity, f1-score, MCC and accuracy. The results of the experiments are given in Table 3 according to the model evaluation criteria.

Table 3. Performance results of ensemble learning methods

Ensemble learning methods	Model evaluation metrics (%)					
	Sensitivity	Precision	Specificity	MCC	F1- score	Accuracy
Bagging	89.22	94.79	95.00	84.31	91.92	92.08
Total Boost	92.00	95.83	96.08	88.18	93.88	94.06
Robust Boost	90.38	97.92	97.96	88.41	94.00	94.06
Logit Boost	93.07	97.92	98.02	91.20	95.43	95.54
AdaboostM1	94.00	97.92	98.04	92.15	95.92	96.04
Gentle Boost	94.06	98.96	99.01	93.18	96.45	96.53

When the accuracy values in Table 3 are examined, the accuracy of Gentle Boost is 96.53%, the accuracy of AdaboostM1 is 96.04%, the accuracy of Logit Boost is 95.54%, the accuracy of Robust Boost is 94.06%, the accuracy of Total Boost is 94.06%, and the accuracy of Bagging is 92.08%. The highest performance belongs to Gentle Boost ensemble learning method. Gentle Boost method had achieved a promising performance of 94.06% sensitivity, 98.96% precision, 99.01% specificity, 93.18% MCC%, 96.45% f1-score, and 96.53% accuracy. Model evaluation metrics are required to be close to 1 (Göker & Tekedere, 2019). In the case of a stable dataset, the accuracy value produces reliable results, but if the intergroup distribution in the dataset is not balanced, the accuracy value can be misleading in evaluating the model performance. The f1 score is the harmonic mean of the precision and sensitivity values. Even if the distribution between the groups is not balanced, the f1 score can give reliable results. For this reason, accuracy and f1 scores should be evaluated together when interpreting model success. The accuracy and f1 scores of all ensemble learning methods are over 90%. These experimental results show that the proposed model does not have a random success. In Figure 4, accuracy values of ensemble learning methods are given.

**Figure 4.** Accuracy performance results of ensemble learning methods

4. Conclusion

Consequently, we proposed a model that effectively combines multifractal analysis and ensemble learning approach for diagnosing DCD from EEG signals. Firstly, features were extracted

from raw EEG signals by Multifractal 1-D wavelet leader estimates. Then, the performances of Bagging, Total Boost, Robust Boost, Logit Boost, AdaboostM1, and Gentle Boost ensemble learning methods were compared using extracted feature vectors, in the classification of EEG-based DCD. Experimental results showed that the Gentle Boost ensemble learning method had the highest performance. The Gentle Boost ensemble learning method had achieved 94.06% sensitivity, 98.96% precision, 99.01% specificity, 93.18% MCC%, 96.45% f1-score, and 96.53% accuracy. The fact that the performance evaluation criteria values of this model are quite high indicates that the model does not have a random success. The proposed model can be easily applied to different biomedical signals.

References

- Akcan, F., and Sertbaş, A. (2021) Topluluk öğrenmesi yöntemleri ile göğüs kanseri teşhisi. *Electronic Turkish Studies*, 16(2).512-527.
- Al-Qerem, A., Kharbat, F., Nashwan, S., Ashraf, S., & Blaou, K. (2020). General model for best feature extraction of EEG using discrete wavelet transform wavelet family and differential evolution. *International Journal of Distributed Sensor Networks*, 16(3), 1550147720911009.
- American Psychiatric Association. (2013). American Psychiatric Association: Diagnostic and Statistical Manual of Mental Disorders, Arlington.
- Aouedi, O., Piamrat, K., & Parrein, B. (2022). Ensemble-based deep learning model for network traffic classification. *IEEE Transactions on Network and Service Management*. hal-03736603. 1-12.
- Blank, R., Smits-Engelsman, B., Polatajko, H., & Wilson, P. (2012). European Academy for Childhood Disability (EACD): Recommendations on the definition, diagnosis and intervention of developmental coordination disorder. *Developmental Medicine and Child Neurology*, 54(1), 54-93
- Biotteau, M., Danna, J., Baudou, É., Puyjarinet, F., Velay, J. L., Albaret, J. M., & Chaix, Y. (2019). Developmental coordination disorder and dysgraphia: signs and symptoms, diagnosis, and rehabilitation. *Neuropsychiatric Disease and Treatment*, 15, 1873-1885.
- Chutia, D., Bhattacharyya, D. K., Sarma, J., & Raju, P. N. L. (2017). An effective ensemble classification framework using random forests and a correlation based feature selection technique. *Transactions in GIS*, 21(6), 1165-1178.
- Caçola, P., & Lage, G. (2019). Developmental Coordination Disorder (DCD): An overview of the condition and research evidence. *Motriz: Revista de Educação Física*, 25(2). 1-6.
- Dong, X., Yu, Z., Cao, W., Shi, Y., and Ma, Q. (2020) A survey on ensemble learning. *Frontiers of Computer Science*, 14(2), 241-258.
- Foroumandi, E., Nourani, V., & Sharghi, E. (2021). Climate change or regional human impacts? Remote sensing tools, artificial neural networks, and wavelet approaches aim to solve the problem. *Hydrology Research*, 52(1), 176-195.
- Gadhoumi, K., Do, D., Badilini, F., Pelter, M. M., & Hu, X. (2018). Wavelet leader multifractal analysis of heart rate variability in atrial fibrillation. *Journal of Electrocardiology*, 51(6), S83-S87.
- Gomez-Pilar, J., García-Azorín, D., Gomez-Lopez-de-San-Roman, C., Guerrero, Á. L., & Hornero, R. (2020). Exploring EEG spectral patterns in episodic and chronic migraine during the interictal state: determining frequencies of interest in the resting state. *Pain Medicine*, 21(12), 3530-3538.
- Göker, H., & Tekedere, H. (2019). Dynamic expert system design for the prediction of attention deficit and hyperactivity disorder in childhood. *Journal of Information Technologies*, 12(1), 33-41.
- Izadi-Najafabadi, S., Ryan, N., Ghafooripoor, G., Gill, K., & Zwicker, J. G. (2019). Participation of children with developmental coordination disorder. *Research in Developmental Disabilities*, 84, 75-84.
- Martinez-Manzanera, O., Lawerman, T. F., Blok, H. J., Lunsing, R. J., Brandsma, R., Sival, D. A., & Maurits, N. M. (2018). Instrumented finger-to-nose test classification in children with ataxia or developmental coordination disorder and controls. *Clinical Biomechanics*, 60, 51-59.

- Qin, L., & Gao, J. H. (2021). New avenues for functional neuroimaging: ultra-high field MRI and OPM-MEG. *Psychoradiology*, 1(4), 165-171.
- Tosun, M., & Çetin, O. (2022). A new phase-based feature extraction method for four-class motor imagery classification. *Signal, Image and Video Processing*, 16(1), 283-290.
- Tsai, C. L., Wang, C. H., Tseng, Y. T., (2012). Effects of exercise intervention on event-related potential and task performance indices of attention networks in children with developmental coordination disorder. *Brain and Cognition*, 79(1), 12-22.
- Vařeka, L., Brůha, P., Mouček, R., Mautner, P., Čepička, L., & Holečková, I. (2017). Developmental coordination disorder in children—experimental work and data annotation. *GigaScience*, 6(4), 1-6.
- Zhou Z. H. (2012). Ensemble methods: foundations and algorithms. Chapman and Hall/CRC.

Derin Öğrenme Yöntemleri İle Rüzgâr Hızı Tahmini Üzerine Bir Derleme

A Review on Wind Speed Prediction With Deep Learning Methods

Dursun Öztürk^{1*} , Kader Ozan² 

¹Elektrik Elektronik Mühendisliği Bölümü, Bingöl Üniversitesi, Bingöl, Türkiye

²Yenilenebilir Enerji Sitemleri Anabilim Dalı, Bingöl Üniversitesi, Bingöl, Türkiye

(dozturk@bingol.edu.tr, kaderozann@gmail.com)

Özet —Yenilenebilir enerji kaynakları arasında önemli bir yere sahip olan rüzgâr enerjisi, sürdürülebilir bir gezegen için vazgeçilmez hale gelmiştir. Enerji üretiminin tahmin edilebilmesi, güç santrallerinin işletilmesi, yönetilmesi, bakımı ve hatta yeni bir güç santralinin kurulumu konusunda büyük kolaylıklar sağlamaktadır. Bununla birlikte, rüzgâr enerjisinin asıl kaynağı olan rüzgâr hızını, değişken doğası nedeniyle tahmin etmek oldukça zordur. Rüzgâr hızı tahmin çalışmalarında yaşanan olumsuzluklarla baş edebilmek için fiziksel yöntemler, istatistiksel yöntemler, yapay zekâ teknikleri ve bunların hibrit olarak kullanıldığı modeller geliştirilmiştir. Bir makine öğrenmesi türü olan derin öğrenme yöntemi de rüzgâr hızı tahmininde kullanılan teknolojiler arasındadır. Rüzgâr hızı, rüzgâr gücü, sıcaklık, basınç ve nem gibi parametrelerin kullanıldığı veri setleri ile derin öğrenme yöntemleri eğitilerek geleceğe yönelik rüzgâr hızı tahminleri yapılabilmektedir. Bu alanda daha çok kullanılan derin öğrenme yöntemleri CNN ve LSTM başta olmak üzere, farklı yöntemler ile oluşturdukları hibrit yöntemler ile başarılı sonuçlar elde edilmektedir. Bu makalede, derin öğrenme yöntemleri konusu ve derin öğrenme yöntemleri kullanılarak rüzgâr hızı tahmininde bulunan çalışmalar ele alınmıştır.

Anahtar Kelimeler: Derin öğrenme, yenilenebilir enerji, rüzgâr enerjisi, rüzgâr hızı tahmini

Abstract — Wind energy, which has an important place among renewable energy sources, has become indispensable for a sustainable planet. The estimation of energy production provides great convenience in the operation, management, maintenance of power plants and even the installation of a new power plant. However, wind speed, which is the main source of wind energy, is quite difficult to predict due to its variable nature. In order to cope with the negativities experienced in wind speed estimation studies, physical methods, statistical methods, artificial intelligence techniques and models in which these are used as hybrids have been developed. Deep learning method, which is a type of machine learning, is also among the technologies used in wind speed estimation. Wind speed predictions for the future can be made by training deep learning methods with data sets containing parameters such as wind speed, wind power, temperature, pressure and humidity. Successful results are obtained with the hybrid methods they have created with different methods, especially the deep learning methods CNN and LSTM, which are mostly used in this field. In this article, the subject of deep learning methods and the studies on wind speed estimation using deep learning methods are discussed.

Keywords: Deep learning, renewable energy, wind energy, wind speed prediction

GİRİŞ

Doğası nedeniyle rüzgârın hızını tahmin etmek oldukça güçtür. Zaman, mevsim, sıcaklık, nem, hava durumu gibi birçok parametre rüzgâr hızını etkilemektedir. Kararsızdır ve rastgele eser. Bu yüzden rüzgâr hızının doğru bir şekilde tahmin edilmesi hem elektrik güç sistemlerinin maliyetini azaltır, hem de güç şebekesi dağıtımında ve kaynak tahsisinde kritik bir rol oynar. Rüzgâr santrallerinde kesinti ve belirsizlik büyük rüzgâr türbinlerinde güvenilir çalışmayı engelleyerek güç kalitesinde büyük bir kriz oluşturmakta ve dolayısıyla rüzgâr enerjisi üretim ekonomisini olumsuz etkilemektedir (Elyasichamazkoti ve Khajehpoor, 2021). Elektrik şebekesinin sorunsuz çalışmasının sağlanması da bir takım teknolojik zorluklara sebep olmaktadır (Tanveer ve Dongdong, 2022). Rüzgâr enerjisi tahmini için kurulan laboratuvar ekipmanlarının üretimi ve kullanımı oldukça maliyetlidir. Dolayısıyla tahmin için modellenen yöntemlerin doğruluk oranının yüksek olması daha iyi sonuçlara ulaşmak için önemlidir (Shamshirband ve ark., 2019).

Rüzgâr enerjisi entegrasyonu için rüzgâr hızı tahmini ve güç tahmininin sağlıklı bir şekilde yapılması gerekmektedir (Aly, 2020). Rüzgâr enerjisi tahmininde genellikle iki yöntem izlenmektedir. Kısa vadeli tahmin yapmak için istatistiksel yöntemler kullanılırken, uzun vadeli tahminlerde fiziksel yöntemler kullanılmaktadır. Kısa süre içinde rüzgâr gücünde fazla bir değişiklik olmayacağı için kısa vadeli tahminler daha tatmin edicidir.

Diğer yandan, rüzgâr çiftliklerinde kısa vadeli rüzgâr tahmini yapmak oldukça zordur. Çünkü kısa süreli tahminler 1 saatten az süreli tahminlerdir ve meteorolojik ölçümler günde sadece birkaç kez yapılmaktadır. Bu yüzden daha iyi tahminler yapabilmek için çoğu zaman, istatistiksel ve fiziksel yöntemler bir arada kullanılmıştır (Meka ve ark., 2021). Son yıllarda rüzgâr hızı tahminlerinde bu yöntemler yerine veya bu yöntemlerle birlikte, güçlü öğrenme ve modelleme yeteneğine sahip derin sinir ağları kullanılmaya başlandı. Derin öğrenme yöntemleri rüzgâr hızı verilerinin gizli özelliklerini daha iyi öğrenebileceği ve çıkartabileceği derin sinir ağlarına sahiptir (Liu ve ark., 2020).

Derin öğrenme sahip olduğu yöntemlerin zenginliği ve son yıllardaki başarıları ile birçok araştırmacının ilgi odağı olmuştur (Alkhayat ve Mehmood, 2021). Rüzgâr tahminlerinde önemli hale gelmeye başlayan derin öğrenme sinir ağlarında daha çok Oto Kodlayıcılar (AE), Uzun Kısa Süreli Hafıza Ağları (LSTM), Sınırlı Boltzmann Makineleri (RBM) ve Konvolüsyonel Sinir Ağları (CNN) gibi yöntemler kullanılmıştır. Derin öğrenme de fazladan denetimsiz ağlara ihtiyaç duyulmadığı için, geleneksel sinir ağlarından daha iyi performans gösterirler (Hong ve Rioflorido, 2019).

Tahmin çalışmalarında geliştirilen modellerin performansı büyük ölçüde veri olarak girilen değerlere bağlıdır. Veri seti olarak rüzgâr gücü, rüzgâr hızı, sıcaklık, nem gibi birçok değişken kullanılabilir (Feng ve ark., 2017). Makine öğrenmesinde verilerin öznelitliklerinin nasıl ve ne şekilde olması gerektiği bir insan tarafından öğrenme işleminden önce belirlenirken, derin öğrenme yöntemleri bu işlemi kendi gerçekleştirebilmektedir. Derin öğrenmenin, verilerin ayırt edici özelliklerinin dışarıdan bir müdahale olmadan kendi katmanları içerisinde öğrenebilmesi, büyük boyuttaki verilerin daha kısa sürede daha tatmin edici sonuçlara ulaşmasını sağlamaktadır. Bu özelliği sayesinde birçok farklı alanda araştırmacılar derin öğrenme yöntemlerini kullanmaya yönelmektedir.

Bu makale de, son yıllarda derin öğrenme yöntemleri ile yapılan rüzgâr hızı tahmin çalışmaları araştırılmış ve incelenmiştir.

1. Derin Öğrenme

Derin öğrenme, verilen bir veri seti ile çıktıları tahmin eden bir makine öğrenme yöntemidir. Temelde, insan beyni yapısından ilham alınarak oluşturulmuş birçok katmana sahip yapay sinir ağlarına dayanmaktadır. Dışarıdan bir müdahaleye gerek duymadan, bu sinir ağlarını kullanarak doğru kararlar verebilmektedir. Derin öğrenme, makine öğrenmesinden farklı olarak çok daha büyük verilerle çalışabilmekte ve sürekli olarak öğrenmeye devam etmektedir. Bunu da çok katmanlı yapay sinir ağları sayesinde yapabilmektedir.

Derin öğrenmenin geçmişi daha eskilere dayanmaktadır. Fakat geliştirilip kullanılmasına son yıllarda başlanmıştır. Bunun en önemli sebebi yeterli verinin olmamasıydı. Yeteri kadar kaynak sağlandığında derin öğrenmeden başarılı sonuçlar elde edilmeye başlanmıştır. Makine öğrenimi ve derin öğrenme için en iyi veri kaynağı "Big Data" adı verilen alandır. Günümüz dünyasında bilgiler hızlı bir şekilde bilgisayarlar arasında akmakta ve veri kümesi haline gelmektedir. Bu büyük veri yığını da derin öğrenmenin gelişmesinde en büyük etkindir (İnik ve Ülker, 2017).

Derin öğrenmede, öğrenmenin gerçekleşmesi için çok fazla veri girişinin olması gerekmektedir. Bu da çok fazla parametrenin oluşacağı ve birçok işlem yapılması gerektiği anlamına gelmektedir. İşlemlerin daha hızlı yapılabilmesi ve sonuçlanması için bir algoritma geliştirilmelidir. Derin öğrenme birçok katmandan oluşmaktadır. Her bir katman kendi görevini yaptıktan sonra veriyi bir alt katmana gönderir. En alt katmana inildikçe istenilen sonuca ulaşmayı sağlayacak olan sinir ağı yapısı oluşmaktadır (Doğan ve Türkoğlu, 2019).


Derin öğrenme mimarileri aşağıdaki şekilde sınıflandırılabilir;

- Konvolüsyonel Sinir Ağları (Convolutional Neural Network - CNN)
- Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN)
- Uzun Kısa Süreli Hafıza Ağları (Long-Short Term Memory - LSTM)
- Sınırlı Boltzmann Makineleri (Restricted Boltzmann Machine - RBM)
- Derin İnanç Ağları (Deep Belief Network - DBN)
- Oto Kodlayıcılar (Autoencoders - AE) (Tüfekçi ve Karpat, 2019).

1.1. Konvolüsyonel Sinir Ağları (CNN)

Konvolüsyonel (evrişimli) sinir ağında (CNN) diğer katmanlarla birlikte giriş katmanına birde konvolüsyon uygulanır. Bu, giriş katmanındaki her elemanın, bir sonraki katmanda bulunan nöronlarla arasında bir bağlantı oluşturur. Böylece her katman için farklı filtreler uygulanmış olur. Konvolüsyonel sinir ağı, canlıların görme sisteminden esinlenilerek geliştirilmiştir. Bir görüntüdeki köşe, kenar, kıvrım gibi her bir ayrıntı okunur, özellikleri çıkartılır, işlenir ve bir sonraki katmana bu bilgileri aktarır. Sonraki katmanlarda da bu işlem devam eder ve sinir ağı eğitilmiş olur (Işık ve Artuner, 2016; Doğan ve Türkoğlu, 2019). Evrişimli (konvolüsyonel) sinir ağlarının en büyük avantajı, özellik çıkarma işlemini aktivasyon fonksiyonlarını kullanarak gerçekleştirmesidir (Cömert ve ark., 2020).


CNN, birçok eğitilebilir katman içeren evrişim, aktivasyon, havuzlama ve tam bağlı katmanlarından oluşur. Evrişim katmanı, verilerden özelliklerin çıkarıldığı ilk katmandır. Birden fazla filtreden oluşur. Aktivasyon katmanı, girdilere bağlı olarak bir çıkış veren, sinir ağını eğitecek fonksiyonun olduğu katmandır. Havuzlama katmanı, işlem yükünü ve boyutsallığı azaltmak için kullanılır. Tam bağlı katman ise, kendinden önceki evrişim ve havuzlama katmanlarından elde edilen özellikleri tek boyutlu hale getirir (İnik ve Ülker, 2017; Zhu ve ark., 2018; Aslan, 2021).



Şekil 1. Konvolüsyonel sinir ağları (Sönmez, 2018)

1.2. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan sinir ağlarında girilen veriler ile birlikte, katman çıkışında ki veriler de tekrar aynı katmana giriş olarak gönderilir. Katmana daha önceden girilen veriler, sonraki girdiler işlenirken kullanılır. Her katman çıkışında ki veri, bir önceki hesaplamaa bağlıdır. Algoritma bu şekilde kendini sürekli olarak yenilemiş olur. Böylece daha sağlıklı bir döngü oluşmakta ve en iyi hesaplamayı yapabilmektedir (Wu ve ark., 2016; Kayaalp ve Süzen, 2018; Doğan ve Tüfekçi, 2019).



Şekil


2. Tekrarlayan sinir ağları (Feng ve ark., 2017)

Ancak RNN’de uzun süreli işlemlerde hata verebilmektedir. Veri girişlerinin hangilerini hatırlaması gerektiğini, ne kadar süre hatırlanması gerektiğini bilmemektedir. Bu sorunu çözmek için 1997 yılında Hochreiter ve Schmidhuber RNN’yi geliştirerek yeni bir mimari olan LSTM’ yi oluşturmuşlardır (Hochreiter ve Schmidhuber, 1997).

1.3. Uzun Kısa Süreli Hafıza Ağları (LSTM)

LSTM mimarisi, RNN ile benzer bir mimaridir. Farklı olarak hatırlama için tekrarlayan beş farklı katman bulunmaktadır. Bu katmanlar önceki hesaplamalar ile yeni verileri hafızasında tutar ve hangi bilgilerin işleneceğine hangi bilgilerin silineceğine karar verir. LSTM’nin dörtlü katmanı;

- Girdi kapısı, giriş verileri okutulur.
- Sigmoid kapısı, bilginin ne kadarının geçip, ne kadarının geçmeyeceğine karar verir.
- Unutma kapısı, bilginin saklanıp saklanmayacağına karar verir.
- Çıktı kapısı, çıkış verilerini aktarır (Kayaalp ve Süzen, 2018; Doğan ve Türkoğlu, 2019).




Şekil 3. Uzun-kısa

(Yan, 2018)

vadeli hafıza ağları

1.4. Sınırlı Boltzmann Makineleri (RBMs)


Sınırlı Boltzmann Makineleri, girilen veriler üzerinde olasılıksal bir tahmin yapabilen derin öğrenme algoritmasıdır. Görünür ve gizli olmak üzere iki katmandan oluşmaktadır. Katman içindeki düğümler arasında bağlantı bulunmaz. Her düğüm diğer katmandaki düğümler ile bağlantılıdır. Veriler, katmanlar arasında gönderilirken rastgele seçilir (Sertkaya, 2018; Doğan ve Türkoğlu, 2019).



Şekil 4. Sınırlı Boltzmann makineleri (Hinton ve ark., 2006)

1.5. Derin İnanç Ağları (DBN)


Derin inanç ağı, kısıtlamalı Boltzmann makinelerinin veya oto-kodlayıcıların yığılmış hali olan bir yapay sinir ağıdır. Bir katman içerisindeki düğümler arasında bağlantı bulunmazken, her düğümün kendinden önceki ve sonraki katmanlara ait düğümler ile bağlantısı vardır (Keleş, 2018).



Şekil 5. Derin inanç ağı (Doğan ve Türkoğlu, 2019)

1.6. Oto Kodlayıcılar (AE)

Oto kodlayıcı, giriş olarak verilen değerlere en çok benzeyen çıktıyı üretmeye çalışan bir yapay sinir ağıdır. Temelde, kodlayıcı, gizli katman (kod) ve kod çözücü olmak üzere üç katmandan oluşur. Mimaride, girilen veri kodlanarak daha az sayıda düğüm içeren bir katman haline getirilir. Kod çözücü katman ise, gizli katmanda kodlanmış veri ile girdi verisine benzeyen bir çıktı üretmeye çalışır (Kaynar ve ark., 2016; Kayaalp ve Süzen, 2018).



Şekil 6. Oto-kodlayıcılar (Kaynar ve

ark., 2016)

2. Derin Öğrenmenin Kullanıldığı Bazı Alanlar

Derin öğrenme, teknolojiye her alanda dokunabilmekte, hatta şekillendirebilmektedir. Araştırmacılar derin öğrenme yöntemlerini kullanarak birçok alanda çalışmalar yapmıştır. Sağlık (Keleş, 2018), otonom araçlar (Zhu ve ark., 2022), doğal dil işleme (Küçük ve Arıcı, 2018), ses (Dokuz ve Tüfekçi, 2020) ve görüntü işleme (Daş ve ark., 2019), el yazısı karakter tanıma (Koyun ve Afşin, 2017), savunma ve uzay (Toraman 2018), endüstriyel robot (Aksoy, 2019), ev aletleri (Yu ve ark., 2022), kullanıcı deneyimi (Bisogni ve ark., 2021) gibi birçok alanda derin öğrenme kullanılmaktadır (Yapıcı ve ark., 2019).

Bingöl ve arkadaşlarının yaptığı çalışmada, binaların depreme dayanıklılığını, derin öğrenme ve görüntü işleme yöntemi ile tespit etmeyi amaçlamıştır. Daha mimari tasarım aşamasındayken yapılan bu çalışma ile binanın taşıyıcı sistem kurgusunda düzensizlik olup olmadığı, derin öğrenme ve görüntü işleme yöntemi ile tespit edilmeye çalışılmıştır. Çalışmada, seçilen doğru ve yanlış örneklerden bir veri seti girilmiştir. Modelden, yeni projelere ait veriler ile öğretilmiş olan verilerin benzerlikleri hakkında değerlendirme yapması istenmiştir. Modelin izlemesi

gereken yol derin öğrenme ile öğretilmiş, veri setleri ise görüntü işleme yöntemi ile girilmiştir (Bingöl ve ark., 2020).

Metlek ve Kayaalp, arı hastalıklarının tespiti için derin öğrenme yöntemlerine dayalı hibrit bir yöntem geliştirmiştir. Tasarlanan sistem, arılarda görülen farklı hastalık türlerini ayırt edebilmektedir. Çalışmada “The Bee Image Dataset: Annotated Honey Bee Images” veri setinden binlerce arıya ait görüntüler kullanılmıştır. Görüntüler, sadece arının görüleceği şekilde temizlenmiş ve diğer bilgiler ile birlikte veri tabanına yüklenmiştir (Metlek ve Kayaalp, 2021).

Şişmanoğlu ve arkadaşları, derin öğrenmenin 3 farklı modelini kullanarak hisse senedi tahmin sistemi geliştirilmiştir. Çalışmada ABD merkezli IBM hisse senedi fiyatları veri seti olarak kullanılmıştır. Derin öğrenme yöntemi olarak da LSTM, BLSTM ve GRU mimarileri tercih edilmiş ve hisse senetlerine ait gelecekteki değerleri tahmin edilmeye çalışılmıştır (Şişmanoğlu ve ark., 2020).

Canbay ve arkadaşları, Covid-19 hastalığının teşhisinde kullanılan yöntemlerden bilgisayarlı tomografi ve X-Ray verilerini kullanarak bir derin öğrenme algoritması geliştirmiştir. Geliştirilen bu mimariler içerisinde en yüksek başarı CNN mimarisi ile elde edilmiştir. CNN mimarisinin bu kadar başarılı olmasının sebebi, görüntü işleme, görüntüden özellik çıkarma ve görüntünün sınıflandırılması konularında en iyi sonuçları üretmesidir (Canbay ve ark., 2021).

Türkoğlu ve arkadaşları, daha çok sürücülerin yaşadığı uyuşukluk sorununu tespit etmek için CNN-LSTM tabanlı bir model geliştirmiştir. EEG sinyalleri, zaman-frekans dönüştürme yöntemi kullanılarak görüntüye dönüştürülmüştür. CNN modeli ile görüntülerin özellikleri çıkartılmış ve LSTM katmanlarına gönderilmiştir. LSTM çıkışı görüntüler sınıflara ayrılmak üzere sırasıyla tam bağlı katman, softmax katmanı ve sınıflandırma katmanından geçirilmiştir. Oluşturulan modelin, literatürdeki diğer çalışmalardan daha iyi sonuçlar ürettiği gözlemlenmiştir (Türkoğlu ve ark., 2021).

3. Literatürde Derin Öğrenme İle Rüzgar Tahminleri

Günümüzde yenilenebilir enerji kaynakları alanında birçok konuda derin öğrenme yöntemleri kullanılmaktadır. Rüzgâr hızının az olduğu mevsimler rüzgâr enerji santrallerindeki, aşırı soğuk kış ayları ise güneş enerji santrallerindeki enerji üretimini olumsuz yönde etkilemektedir. Enerji endüstrilerinde güvenilir ve stratejik planlama yapılabilmesi için doğru enerji üretim tahminlerine ihtiyaç duyulmaktadır (Ahmad ve ark., 2020). Rüzgâr hızı tahmini, rüzgâr gücü tahmini, rüzgâr türbini ömür tahmini, güneş ısınım tahmini, fotovoltaik güç tahmini gibi birçok konu derin öğrenme sinir ağları kullanılarak tahmin edilmektedir.

Değişen hava koşulları fotovoltaik panellerden elde edilen enerji miktarını önemli ölçüde etkilemektedir. Karabiber ve Alçin, panellerde ki güç değişimini tahmin etmek için aşırı öğrenme makineleri ve destek vektör makinelerini kullanmış ve sonuçlarını karşılaştırmıştır (Karabiber ve Alçin, 2019). Pérez ve arkadaşları bir fotovoltaik enerji santralinin çevresindeki güneş ısınımını, uydu görüntüleri ile tahmin edebilen bir derin öğrenme yöntemi geliştirmiştir (Pérez ve ark., 2021). Güneş enerjisi üretim tahmini için yapılan bir çalışmada, referans alınan bir santralin önceki yıllarında üretilmiş olan elektrik enerjisi verileri kullanılarak LSTM tabanlı bir derin öğrenme ağı geliştirilmiştir (Kıymaz, 2021).

Rüzgâr enerjisi yenilenebilir enerji kaynakları içerisinde önemli bir rol oynamaktadır. Rüzgâr enerjisinden en iyi şekilde faydalanılabilmesi için doğru ve güvenilir rüzgâr hızı tahmininin yapılabilmesi gerekmektedir. Yine bir rüzgâr santralinin işletilebilmesi ve yönetilebilmesi için rüzgâr hızının tahmini oldukça önemlidir. Ani rüzgâr hızları, rüzgâr türbinlerinde ciddi hasarlara sebep olabilmektedir. Bu tarz maddi kayıpların önüne geçebilmek için rüzgâr hızının türbinlere zarar verebilecek hızlara ulaşacağı önceden tahmin edilebilir ve türbinler korunma amaçlı kapatılabilmektedir. Türbinlerde yaşanan teknik arızalar derin öğrenme yöntemleri ile daha erken tespit edilmekte ve kritik hasarların oluşmasının önüne geçilebilmektedir (Helbing ve Ritter 2018). Rüzgâr türbini kurulabilecek potansiyeldeki alanların belirlenmesinde yine derin öğrenme yöntemleri kullanılabilmektedir. Belirlenen alanın, önceki yıllara ait rüzgâr verileri ile bir derin sinir ağı eğitilerek model oluşturulur ve modelin ileri tarihlere ilişkin rüzgâr ile ilgili tahminlerde bulunması istenir.

Diğer yandan rüzgar santrallerinin ilk yatırım maliyetleri, sabit özellikleri, rüzgar hızı potansiyelinin yüksek olduğu alanların bulunması (Demolli ve ark.,2019), rüzgâr hızının belirsizliği, değişken ve aralıklı doğasının olması gibi nedenler tahmin edilebilmesini oldukça zorlaştırmaktadır. Derin öğrenme ise karmaşık problemleri başarıyla çözebilmekte ve büyük boyutlarda ki verileri başarıyla işleyebilmektedir. Dolayısıyla araştırmacılar rüzgâr hızı tahminlerinde derin öğrenmeyi kullanmaya yönelmişlerdir.

Rüzgâr hızının tahmini, rüzgâr enerjisi üretiminde temel konulardan biri haline geldi (Elyasichamazkoti ve Khajehpoor, 2021). Rüzgâr gücü tahmini yapabilmek için farklı yöntemler izlenir. İlk yöntemde, türbine ait önceki yılların rüzgâr gücü verileri kullanılarak ileri tarihler için tahminler yapılır. İkinci yöntemde ise, önce rüzgâr hızı

tahmini yapılır, sonrasında bu tahmin verileri ile bir güç eğrisine göre (Wang ve ark.,2021) veya güç formülleri kullanılarak rüzgâr gücü tahmini yapılır (Alkhayat ve Mehmood,2021).

Rüzgâr türbinlerinde güç tahmini yapan birçok derin öğrenme modeli, türbine ait önceki yılların rüzgâr hızı ve rüzgâr gücü verilerini kullanarak tahmin üretmektedir. Bazı modellerde ise doğruluğu arttırmak için sıcaklık, nem, yağış, hava basıncı ve rüzgâr yönü gibi meteorolojik veriler de kullanılmaktadır. Bununla birlikte, henüz rüzgâr türbini kurulmamış bölgelerde rüzgâr hızı tahminleri yapılabilir ve elde edilen bu tahmin verileri ile rüzgâr gücü tahminleri yapılabilmektedir. Burada güç tahmini yapabilmek için bazı güç formülleri ve seçilecek türbine ait özellikler kullanılmaktadır (Alkhayat ve Mehmood,2021).

Rüzgâr hızı tahminleri dört kategoride: çok kısa vadeli (birkaç saniyeden 30 dakikaya kadar), kısa vadeli (30 dakikadan 6 saate kadar), orta vadeli (6 saatten 24 saate kadar) ve uzun vadeli tahminler (1 günden 7 güne kadar) şeklinde yapılır. Türbin kontrolleri ve yük takibi için çok kısa vadeli tahminler yapılır. Kısa vadeli tahminler, yük dağıtım planlaması için gereklidir. Orta vadeli tahminler, enerji ticaretinin yapılabilmesi için gereklidir. Uzun vadeli tahminler ise daha uzun dönemde ki bakım planlamaları için önemlidir (Wang ve ark.,2021). Aynı zamanda, bölgede rüzgâr türbini kurulması planlarında uzun vadeli rüzgâr tahminleri büyük önem taşımaktadır.

Rüzgâr tahmini yapabilmeyen bir başka yöntemi ise akıllı algoritmalar ve makine öğrenimini bir arada kullanmaktır. Hua ve arkadaşları, geliştirilmiş atom arama optimizasyonu (IASO), değişken mod ayrıştırması (VMD), kısmi en küçük kareler (PLS) ve aşırı öğrenme makinesini (ELM) bir arada kullanarak kısa vadeli rüzgâr hızı tahmini yapabilen bir model oluşturmuştur. Çalışmada, modelin tahmin doğruluğunu test etmek için başka modeller de oluşturulmuş ve sonuçlar karşılaştırılmıştır. En iyi sonuç, VMD-PLS-IASO-ELM modeli ile elde edilmiştir (Hua ve ark., 2021).

Rüzgâr tahminlerinde, nokta tahmini ve aralık tahmini şeklinde iki farklı türde tahmin yapılır. Nokta tahmini yapılırken en iyi sonucun verilmesi ve hata oranının en az olması istenir. Aralık tahmininde ise, en iyi tahmin sonuçlarının belirli bir aralıkta olması beklenir. Tahmin aralığı ne kadar dar bir alanı kapsarsa, o kadar iyi sonuçlar elde edilir. Li ve arkadaşları, bir aralık tahmin yöntemi olan alt-üst sınır tahmini (LUBE) yöntemini, gradyan iniş optimizasyonu ile eğiterek, rüzgâr gücünün kısa vadeli aralık tahminini gerçekleştirmiştir. Çalışmada en iyi performansın, LUBE yöntemi ile uzun-kısa süreli bellek (LSTM) ağlarının birlikte kullanıldığı model ile elde edildiği sonucuna varılmıştır (Li ve ark., 2020).

Yenilenemeyen enerji kaynakları hızla tükenmekte ve tüm dünyada enerji ihtiyacını karşılamakta yetersiz kalmaktadır. Bu yüzden alternatif enerji kaynakları bulunmalı, kullanımı yaygınlaştırılmalı ve bu kaynaklar gelecek nesiller için korunmalıdır. Rüzgâr enerjisi de yenilenebilir, sürdürülebilir, yeşil bir enerji kaynağı olmakla birlikte düşük işletim maliyeti ve yüksek güç üretimi ile mükemmel bir kaynak halindedir. Bali ve arkadaşları da rüzgâr enerjisinin en verimli şekilde kullanılabilmesi için rüzgâr hızının tahmin edilmesi gerektiğini savunmuştur. Çünkü rüzgâr hızının tahmin edilmesi ile üretilen rüzgâr gücü de tahmin edilebilmektedir. Rüzgâr hızı tahmini için LSTM ve ARIMA yöntemlerinin bir arada kullanıldığı yeni bir hibrit model geliştirilmiştir (Bali ve ark., 2020).

Yapılan bir çalışmada (Chen ve ark., 2021) Kuzey Kutbu'nda bir rüzgâr parkında rüzgâr tahmini yapmak için derin öğrenme kullanılmıştır. Santral tarafından kaydedilen belli bir zaman aralığındaki rüzgâr hızı verileri ve güç verileri ile birlikte, yerel bir meteoroloji enstitüsü tarafından yapılan tahmin verileri, derin öğrenme sinir ağlarının eğitilmesi için kullanılmıştır. LSTM ile oluşturulmuş kodlayıcı ve kod çözücüye dayanan bir model oluşturulmuş ve rüzgâr verileri modele girdi olarak okutulmuştur. Oluşturulan modelin genelliğini test etmek için park içinde farklı topografiklerde kurulmuş olan diğer türbinlerde de denenmiştir. Ve modelin başarılı bir şekilde tahmin yapabildiği görülmüştür. Yine yapılan başka bir çalışmada (Hong ve Rioflorido, 2019) gün öncesi rüzgâr enerjisi tahmini için hibrit bir derin öğrenme sinir ağı geliştirilmiştir. Geliştirilen ağ, Çift Gauss İşlevi (DGF) ile Radyal Temel İşlevli Sinir Ağı (RBFNN)'nin beraber kullanıldığı Evrişimli Sinir Ağı (CNN)'na dayanmaktadır. Oluşturulan model ile tahminler üretilerek, kullanıcıların rüzgâr hakkında net sonuçlar elde edebilmesi, güç sistemlerinde programlamanın ve kaynak planlamasının yapılabilmesi amaçlanmıştır.

Rüzgâr enerjisi üretim tahminine yönelik yapılan bir çalışmada, üç farklı derin öğrenme yöntemi kullanılmıştır. LSTM, GRU ve RNN algoritmaları ile kurulan modelde girdi olarak rüzgâr hızı verileri kullanılmıştır. Çalışmada, Belçika- Brüksel'de bir rüzgâr türbini referans alınmıştır. Ve oluşturulan modelin, bir bölgede santral kurulumu için gerekli şartların sağlanıp sağlanmadığı konusunda da kullanılabileceği belirtilmiştir (Chandran ve ark., 2021). İsveç de bir açık deniz rüzgâr çiftliği olan Lillgrund Rüzgâr Çiftliği rüzgâr verileri referans alınarak, bir derin öğrenme sinir ağı oluşturulmuştur. Oluşturulan model LSTM, Bi-LSTM, FFNN, PNN ve NAR sinir ağlarının bir arada kullanıldığı hibrit bir modeldir. Sinir ağlarının hibrit bir şekilde kullanılması, doğrusal olmayan rüzgâr hızı

verilerinin özelliklerini çıkarmada daha etkili olmuştur ve diğer modellere göre daha yüksek tahmin doğruluğu sunmuştur (Neshat ve ark., 2021).

Derin öğrenmede, CNN ve LSTM sinir ağları çok iyi performans gösterdiği için tercih edilmiştir. Algoritmanın eğitilmesi ve tahmin doğruluğunun değerlendirilmesi için Çin’de ki üç farklı rüzgâr çiftliği verileri kullanılmıştır. Yapılan çalışma sonucunda, güç santralleri için dengeleme maliyetini azaltabileceği, küçük şebekelerden maliyete göre enerji satın alan firmalar için tahmin ve kolaylık sağlayabileceği, rüzgâr santralının gün içinde ki tahmin bildirimlerini kolaylaştırdığı ve dolayısıyla ceza maliyetlerini azaltabileceği aktarılmıştır (Qin ve ark., 2021). Chen ve arkadaşları (Chen ve ark., 2021) CNN-LSTM derin öğrenme algoritmasına dayalı bir rüzgâr hızı tahmini modeli geliştirmiştir. Rüzgâr santraline ait mekân ve zaman bilgileri hem CNN modeline, hem de LSTM modeline öğretilerek, iki model birbirine bağlanmıştır. Veriler ile ilk olarak CNN modelini eğitmek için kullanılmış, giriş ve çıkışı aynı olan ama matris boyutları daha küçük olan bir veri elde edilmiştir. Daha sonra CNN çıkışında ki veriler ile LSTM modeli eğitilmiş ve tahminler üretilmiştir. LSTM çıkış verileri CNN’ in kod çözücü katmanına geri gönderilerek CNN matrisinin yeniden oluşması sağlanmıştır. Evrimsel sinir ağları (CNN) ve uzun kısa süreli bellek ağlarının (LSTM) bir arada kullanıldığı diğer bir çalışmada, İzmir Urla’da bulunan bir rüzgâr türbinine ait günlük ve 10 dakikalık ölçüm verileri kullanılmıştır. 10 dakikalık veri seti çözünürlüğü, veri miktarının fazla olması demektir. Dolayısıyla 3 günlük gibi kısa zaman dilimleri için de tahminler yapılabilmiştir (Görgel ve Kavlak, 2020).

Aslam ve arkadaşları tüketicinin ihtiyacı olan enerji miktarı ile birlikte, rüzgâr türbinleri ve fotovoltaik panellerden elde edilen enerji miktarını tahmin eden bir derin öğrenme yöntemi geliştirmiştir. Bu yöntem ile enerji talebine göre enerji üretimi yapılabilmekte, üretim daha verimli gerçekleşmekte ve rüzgâr türbinleri sadece ihtiyaç halinde kullanıldığı için ömürleri uzamaktadır. Rüzgâr türbinleri verilerinin büyük bir çoğunluğu Asya’da bulunan rüzgâr santrallerinden alınmıştır. Veriler, 5 dakika ile 1 saat arasında değişen zaman aralığında alınan rüzgâr hızı, rüzgâr yönü, sıcaklık, nem ve basınç parametreleridir. Elde ki parametreler ile rüzgâr hızı ve rüzgâr enerjisi üretim tahmini yapılmaktadır. Güneş enerjisi tahmini için kullanılan veriler ise dünyanın birçok noktasına ait merkezlerden toplanmıştır. Yine burada da 5 dakika ile 1 saat arasında çözünürlüğe sahip güneş ışıınımı değerleri veri seti olarak kullanılmış, 24 saat ilerisi için güneş ışıınımı ve enerji üretimi tahmini yapılmıştır. Enerji tüketimi tahmininde ise veri seti olarak ticari tüketicilerin ve konut tüketicilerin birkaç ay içinde harcadıkları saatlik enerji miktarı kullanılmıştır. Mevsim, sıcaklık, dönem, müşteri kullanımı gibi farklı etkenler veriler üzerinde değişikliklere sebep olabilmektedir. Enerji üretim ve enerji tüketim tahmini için kullanılan derin öğrenme modellerinin her birinin farklı avantajları ve dezavantajları vardır. En iyi sonuçların ise hibrit derin öğrenme yöntemlerinin kullanılmasıyla elde edildiği sonucuna varılmıştır (Aslam ve ark., 2021). Rüzgâr enerjisinin fiziksel özellikleri, tahmin işleminde birçok soruna sebep olabilmektedir. Rüzgâr tahmininin yapılabilmesi için büyük veri setlerine ihtiyaç vardır ve veri setinin büyümesi öznitelik çıkarımını zorlaştırmaktadır. Xiong ve arkadaşları öznitelik çıkarımının daha sağlıklı yapılabilmesi için ağırlık atamasında Dikkat Mekanizması modelini kullanmıştır. Daha sonra CNN ile büyük boyutlu zaman serisi verilerini işleyerek daha küçük boyutlarda veriler elde edilmiştir. LSTM ise verileri iyileştirerek uzun vadeli eğilimler elde etmek için kullanılmıştır. Oluşturulan hibrit model ile tahmin doğruluğu yüksek ve hata oranı düşük sonuçlar elde edilmiştir (Xiong ve ark., 2022). Hossain ve arkadaşları, Avustralya’nın Yeni Güney Galler eyaletinde bulunan bir rüzgâr santralının enerji tahminini yapabilmek için hibrit derin öğrenme modeli geliştirmişlerdir. Model konvolüsyonel katmanlar, GRU katmanları ve tamamen bağlı sinir ağları ile oluşturulmuştur. Veri seti olarak santralin 5 dakika çözünürlükteki 1 yıllık rüzgâr gücü verileri kullanılmıştır. Konvolüsyon katmanı ile rüzgâr verilerin öznitelikleri çıkartılmış, GRU katmanları ile de en doğru tahminlere ulaşabilmek için gerekli olan bilgiler depolanmıştır. Oluşturulan hibrit modelin LSTM, Bi-LSTM, RNN gibi derin öğrenme modellerinden daha iyi tahminlerde bulunduğu gözlemlenmiştir. Model ile rüzgâr hızı tahmini, güneş enerjisi tahmini, elektrik fiyatları, ihtiyaç duyulan enerji miktarı gibi birçok alanda kullanılabileceği vurgulanmıştır (Hossain ve ark., 2021).

Sadece rüzgâr hızı ve rüzgâr enerjisi tahminlerinde değil, rüzgâr enerji santrallerinin işletme ve bakım maliyetleri de derin öğrenme yöntemleri ile tahmin edilebilmektedir. Yapılan sağlıklı tahminler ile rüzgâr türbininin çalışma süreleri uzatılabilmekte, işletme ve bakım maliyetleri düşürülebilmektedir. Bulut, rüzgâr türbinlerinin kalan faydalı ömürlerinin tahmini için LSTM sinir ağı kullanmıştır. LSTM sinir ağı ile santrale ait geçmiş iki yılın arıza kayıtları toplanıp işlenerek, gelecekte oluşabilecek arıza sayısı ve süresi ile birlikte maliyetlerin de azaltılması amaçlanmıştır. Çalışmada ki asıl amaç, türbinde meydana gelebilecek herhangi bir arızayı önceden tahmin edebilen bir sinir ağı oluşturmaktır (Bulut,

2021). Avrupa İletim Sistemleri Operatörleri (TSOs) her gün piyasa takasından önce, gün öncesi rüzgâr tahminlerini yayınlamaya santrallerin planlama stratejilerini oluşturmasında yardımcı olmaktadır. Toubeau ve arkadaşları da böyle büyük planlamalar için tek bir modele bağlı kalmaktansa birden fazla modelin tahmin sonuçlarının bir arada kullanılarak daha iyi sonuçlar elde edilebileceğini düşünerek bir derin öğrenme yöntemi geliştirmişlerdir. Yöntemin amacı, bir sonraki günün rüzgâr enerjisi üretim tahminini yapmaktır. Veriyi işlemek için kodlayıcı, kod çözücü ve çift yönlü kod çözücü mimarileri olmak üzere LSTM tabanlı üç farklı mimari geliştirilmiş. Bir sonraki adımda, zaman içinde elde edilen yeni veriler eski verilere eklenerek modelin eğitilmesine devam edilmektedir. Tüm bunların sonucunda, tahminde yapılan hataların TSO ve rüzgâr santrallerine maliyetinin ne olduğu hesaplanmıştır (Toubeau ve ark., 2021).

Yıldız ve arkadaşları rüzgâr gücü tahmini için varyasyon mod ayrıştırma (VDM) ve evrişimli sinir ağı (CNN) tabanlı bir model geliştirmiştir. Veri seti olarak Türkiye'nin güneydoğusunda kurulan bir rüzgâr santraline ait 1 senelik rüzgâr hızı, rüzgâr yönü ve rüzgâr gücü verileri kullanılmıştır. Modelde VDM ile verilerin öznelilikleri çıkartılarak HSV renk uzayına dönüştürülmüş daha sonra tüm görüntüler birleştirilerek CNN'de işlenmiştir. Tasarlanan modelin temel amacı, sürekli değişen hava koşullarında bile rüzgâr gücü tahmini yapabilen bir sistem kurmakla birlikte verilerin ayırt edici görsel özelliklerinin gösterilebilmesidir (Yıldız ve ark., 2020). Hu ve arkadaşları, yeni inşa edilmiş rüzgâr santrallerinin geçmiş yıllara ait rüzgâr hızı verileri olmadığından dolayı tahmin modelini geliştirmek için Çin'de kurulu dört eski rüzgâr santralini rüzgâr hızı verilerini kullanmışlardır. Santrallerin hepsi birbirinden farklı hava ve arazi koşullarında kurulmuş olup, farklı rüzgâr hızı özelliklerine sahiptir. Toplanan veriler 10 dakikalık çözünürlüğe sahip, bir santralin 1,5 yıllık, diğer üç santralin 1 yıllık rüzgâr verileridir. Çalışmada, paylaşılan gizli katmanlı bir derin sinir ağı (SHL-DNN) modeli geliştirilmiştir. Modelde girdi ve gizli katmanlar tüm santraller tarafından ortak olarak kullanılmaktadır. Ancak çıktı katmanlarının arasında bir bağlantı yoktur. Oluşturulan modelin tahmin doğruluğunu karşılaştırmak için veriler; derin sinir ağları (DNN), destek vektör regresyonu (SVR) ve aşırı öğrenme makineleri (ELM) ile işlenmiştir. Bu çalışmanın sonuçları rüzgâr santralleri her ne kadar farklı özelliklere sahip bölgelerde olsa da, rüzgâr verilerinin toplanmasıyla yeni bir santral için rüzgâr hızı tahminlerinde bulunabileceğini göstermiştir (Hu ve ark., 2016). Lin ve arkadaşları rüzgâr gücü tahmini için Türkiye'de bulunan bir rüzgâr santralini Scada verilerinden geçmiş hava durumu ve elektrik üretim verilerini toplayarak zamansal evrişimli ağlar (TCN) modelini eğitmişlerdir. Çalışmanın amacı, en az hata oranı ile rüzgâr gücü tahmini yapabilen derin öğrenme yöntemini bulmaktır. Modelin tahmin performansını karşılaştırmak için LSTM, RNN, GRU modelleri ile de ölçümler yapılmış, en düşük hata oranı ile en iyi tahminde bulunan modelin TCN olduğu görülmüştür (Lin ve ark., 2021). Yapılan başka bir çalışmada ise rüzgâr enerjisi tahmini için öz-dikkat zamansal evrişimsel ağ (SATCN) ve uzun-kısa süreli hafıza ağları (LSTM) yöntemlerinin hibrit olarak kullanıldığı bir model geliştirilmiştir. ABD'de bulunan iki rüzgâr santralinden alınan meteorolojik veriler ve rüzgâr enerjisi verileri modeli eğitmek ve test etmek için kullanılmıştır. Verilerin zamansal ve mekânsal özelliklerinin özneliliklerinin çıkarılmasında, çıktıya en çok etki eden özelliklerin üstünde daha çok durduğu için SATCN modeli kullanılmıştır. LSTM modeli ise veri özellikleri ile katman çıkışları arasında bağlantıyı kurmak ve güçlendirmek için kullanılmıştır. Çalışma sonuçları, önerilen modelin ultra kısa süreli rüzgâr enerjisi tahmininde başarılı sonuçlara ulaştığı görülmüştür (Xiang ve ark., 2022).

Rüzgâr hızı tahmini üzerine yapılan birçok çalışmada, rüzgâr hızının zamansal ve mekânsal özellikleri dikkate alınırken meteorolojik etkenlerin sürekli olarak değişmesinin rüzgâr hızına etkisi göz ardı edilmektedir. Chen ve arkadaşları yaptıkları çalışmada çok faktörlü mekânsal-zamansal korelasyon (MFSTC) modeli geliştirmişlerdir. Model ile zaman, mekân ve meteorolojik etkenlere bir arada dikkat edilebilmektedir. Modelde evrişimli sinir ağları (CNN) ve uzun-kısa süreli hafıza ağları (LSTM) yöntemleri hibrit olarak kullanılmıştır. Farklı bölgelerin meteorolojik etkenlerinin uzamsal özelliklerinin çıkartılması için CNN, ölçüm yapılan tarihlerin zamansal özelliklerinin çıkartılması için de LSTM yöntemi kullanılmıştır (Chen ve ark., 2019). Rüzgâr hızı tahmin çalışmalarında sadece bir derin öğrenme yönteminin kullanılması sağlıklı tahmin sonuçlarına sebep olabilmektedir. Bunun üstesinden gelmek için Chen ve arkadaşları, uzun kısa süreli hafıza ağları (LSTM), destek vektör regresyon makinesi (SVRM) ve ekstrem optimizasyon algoritmasının (EO) bir arada kullanıldığı EnsemLSTM adını verdikleri yeni bir yöntem geliştirmişlerdir. Modelin performansını ölçmek için Çin'de bulunan bir rüzgâr santralinden alınan veriler üzerinde model denenmiş ve ultra kısa vadeli

rüzgâr hızı tahmininde ve bir saatlik rüzgâr hızı tahmininde başarılı sonuçlar elde edilmiştir (Chen ve ark., 2018).

Liu ve arkadaşları, optimizasyon, karar verme ve topluluk öğrenme alanlarında daha güçlü performans gösterdiği için pekiştirmeli öğrenme yöntemi ile zaman serisinde güçlü uygulamalar sunduğu için derin öğrenme yöntemlerini bir arada kullanarak, öğrenme yeteneği daha güçlü olan derin pekiştirmeli öğrenme yöntemini geliştirmiştir. Rüzgâr hızı verileri ampirik dalgacık dönüşümü (EWT) ile alt serilere ayrıştırılarak, tahmin sonuçlarını almak için sırasıyla uzun kısa süreli hafıza ağları (LSTM), derin inanç ağları (DBN) ve yankı durum ağları (ESN)'na gönderilmiştir. Nihai tahmin sonuçları LSTM, DBN ve ESN yöntemlerinin tahmin sonuçlarının birleştirilmesiyle elde edilmiştir (Liu ve ark., 2020). Wang ve arkadaşları deterministik ve olasılıksal rüzgâr hızı tahmini için dalgacık dönüşümü (WT), derin inanç ağları (DBN) ve kantil regresyonu (QR)'nun hibrit olarak kullanıldığı bir model geliştirmiştir. Çalışma, rüzgâr hızı tahmin performansını ve verimliliğini arttırmayı amaçlamıştır. Çin ve Avustralya'da bulunan iki rüzgâr santralinden alınan rüzgâr hızı verileri WT ile farklı frekans serilerine ayrıştırılmış, DBN ile doğrusal olmayan ve değişmeyen özellikleri çıkartılmış ve QR ile de rüzgâr hızı belirsizlikleri sentezlenip çıkartılmıştır (Wang ve ark., 2016). Tayvan açık denizinde bulunan bir rüzgâr santralının gün öncesi rüzgâr hızı tahmini için 2D CNN modeline dayanan yeni bir yöntem geliştirilmiştir. Tayvan, Çin, Güney Kore ve Filipinler'deki yedi farklı bölgeden rüzgâr hızı verileri toplanarak Fuhai Rüzgâr Santrali'nin rüzgâr hızı tahmini gerçekleştirilmiştir. Uzamsal ve zamansal veriler başka bir sinyal işleme yöntemine ihtiyaç duyulmadan CNN için 2D olarak gereken bilgiyi sağlamaktadır (Hong ve ark., 2020).

Zhang ve arkadaşları rüzgâr hızı tahmin doğruluğunu iyileştirmek için hibrit bir model geliştirmiştir. Modelde, değişken mod ayrıştırması (VMD), meyve sineği optimizasyon algoritması (FOA), otoregresif entegre hareketli ortalama modeli (ARIMA) ve derin inanç ağı (DBN) bir arada kullanılmıştır. Rüzgâr hızı verilerinin değişken özellikleri VMD ve FOA ile çıkartılmış, ARIMA ile düzenli bileşenler, DBN ile de düzensiz bileşenler tahmin edilmiştir. Tüm modellerin sonuçları birleştirilerek rüzgar hızı tahmin sonuçları elde edilmiştir (Zhang ve ark., 2020). Harbola ve Coors rüzgâr hızı ve rüzgâr yönü tahmini için iki tek boyutlu evrişimli sinir ağı (CNN) modeli önermiştir. İlk model olan 1D tekli CNN (1DS), rüzgârın hızını ve yönünü tahmin etmektedir. İkinci model olan 1D çoklu CNN (1DM) modeli ise tahmin doğruluğunu arttırmak için birçok 1DS model sonucunu birleştirerek en doğru rüzgâr tahmin sonuçlarını vermeyi amaçlamıştır (Harbola ve Coors, 2019). İskoçya da bir açık deniz rüzgâr santrali için uzun kısa süreli hafıza ağları (LSTM), ayrık dalgacık dönüşümü (DWT) ve mevsimsel otoregresif entegre hareketli ortalama (SARIMA)'nın hibrit olarak kullanıldığı, rüzgâr enerjisi tahmini yapan yeni model geliştirilmiştir. Türbinin 1 saniye çözünürlükteki yüksek frekanslı rüzgâr verileri SCADA veri tabanından alınmıştır. Daha sonra bu verilere ön işleme yapılarak saatlik veriler haline getirilmiş, anormal değerler ortadan kaldırılmıştır (Zhang ve ark., 2022). Kuzey Kutbu'ndaki bir rüzgâr santralinde türbülansın rüzgâr gücünü ve rüzgâr hızını ne kadar etkilediğini görmek için farklı makine öğrenmesi yöntemleri kullanılarak sonuçları karşılaştırılmıştır. Makine öğrenmesi tahmin sonuçları birde istatistiksel yöntemlerle karşılaştırılmıştır. Santralden, türbülans içeren veriler ve türbülans içermeyen veriler toplanmış, her iki veri kümesi de ayrı ayrı modelde işlenmiştir. Sonuçlar türbülansın rüzgar hızına ve dolayısıyla rüzgâr gücüne etkisinin önemli bir etkisinin olmadığını göstermiştir (Chen ve ark., 2021).

Mujeeb ve arkadaşları, ABD'nin Maine eyaletinde bulunan şebekeye bağlı bir rüzgâr santralının talebe göre enerji üretimi yapabilmesi ve enerji satışını düzenleyebilmesi için güç üretiminin gün öncesi tahminini yapan bir derin öğrenme modeli geliştirmiştir. Model, verimli derin evrişimli sinir ağı (EDCNN) tabanlı olup, santrale ait üç yıllık rüzgâr verileri ile eğitilmiştir. Çalışma sonucunda önerilen modelin arz-talep dengesini başarılı bir şekilde sağladığı görülmüştür (Mujeeb ve ark., 2019). Lin ve Liu, bir açık deniz rüzgâr türbininin gücünü tahmin etmek için SCADA verileri içerisinde 1 saniye çözünürlükteki, 1 yıllık yüksek frekanslı veri kümesi ile çalışmışlardır. Çalışmada, rüzgâr hızı ve rüzgâr kesmesinin üretilen rüzgâr gücü üzerindeki etkisini ölçmek için türbinin 4 farklı noktasında rüzgâr hızı ölçümü yapılmıştır. Derin öğrenme sinir ağı modeline, farklı noktalarda ölçülen rüzgâr hızları ile birlikte kanat ölçüleri ve ortam sıcaklığı gibi değerler de girilmiştir. Sonuçlar, modelin rüzgâr enerjisi tahminde maliyeti ve süreyi azalttığını göstermiştir (Lin ve Liu, 2020).

Tablo 1. Derin Öğrenme Yöntemleri İle Rüzgar Tahmini Yapan Çalışmaların Özetlenmesi

Yıl	Geliştirici	Yöntem	Veri Ölçeği	Değerlendirme Göstergeleri	Hata Oranı (sırasıyla)
2021	Hua ve ark.	ELM	12000	RMSE, MAE, R, MAPE	0.2188, 0.1742, 0.9909, 0.0465
2020	Li ve ark.	LSTM	17280		
2020	Bali ve ark.	LSTM	420552	RMSE	0.254
2021	Chen ve ark.	EDLSTM	52560	RMSE, MAE	
2021	Chandran ve ark.	RNN-GRU-LSTM	50530	MSE	0.143, 0.130, 0.135
2019	Hong ve Rioflorido	CNN	8760	R^2	0.88
2021	Neshat ve ark.	LSTM-Bi-LSTM	52560		
2021	Qin ve ark.	CNN-LSTM			
2021	Chen ve ark.	CNN-LSTM	13140	MAE, RMSE	0.3509, 0.5193
2020	Görgel ve Kavlak	CNN-LSTM	8640	MSE	1.17
2022	Xiong ve ark.	CNN-LSTM	13440	MSE, MAE, RMSE	0.8951, 0.0505, 0.0946
2021	Hossain ve ark.	CNN-GRU,-CNN	105121	MAE, RMSE, MAPE	0.0159, 0.0373, 0.0813
2021	Bulut	LSTM	67000	MSE	0.08
2020	Yıldız ve ark.	CNN	8760	R, RMSE, MAE, SMAPE	0.9744, 0.0499, 0.0376, 0.2532
2015	Hu ve ark.	SHL-DNN	157680	MAE, MAPE, MSE, RMSE	0.015, 0.28, 0.045, 0.0202
2021	Lin ve ark.	TCN	52560	MAPE	0.0513
2022	Xiang ve ark.	SATCN-LSTM	105120	MAE,	0.196,

				RMSE,	0.361,
				SMAPE	0.4353
2019	Chen ve ark.	CNN-LSTM	25918	MAE,	0.010652,
				RMSE	0.014445
2018	Chen ve ark.	EnsemLSTM	738	MAE,	0.5746,
				RMSE,	0.7552,
				MAPE,	0.054167,
				R	0.9619
2016	Wang ve ark.	DBN	105120	MAE,	0.4282,
				RMSE,	0.5494,
				MAPE	0.0639
2020	Hong ve Satriani	CNN	8760	RMSE,	0.0452,
				NMSE,	0.0891,
				MAPE,	0.2205,
				R^2	0.8570
2019	Zhang ve ark.	DBN	8583	MAE,	0.21,
				MAPE,	0.0514,
				RMSE	0.28
2021	Zhang ve ark.	LSTM	744	R^2	0.996
2021	Chen ve ark.	LR-BPNN-REPTREE-RF	52560		
2019	Mujeeb ve ark	EDCNN	26280	MAPE,	0.0243,
				NRMSE,	0.096,
				MAE	0.0224
2020	Lin ve Liu	DNN	31557600	RMSE,	5.1733,
				R^2 ,	0.91,
				MAE,	3.7441,
				AGH,	0.91,
				MSLE	0.29

SONUÇ

Rüzgâr hızı tahmininde önemli olan, en doğru tahminin en kısa sürede yapılabilmesidir. Değişken ve öngörülemez doğası nedeniyle rüzgar hızı tahmini yapabilmek oldukça zordur. Derin öğrenme yöntemleri ile rüzgâr hızı tahmininde yaşanan zorluklar çözülebilmekte ve büyük boyuttaki veriler kısa sürede işlenebilmektedir. Bu çalışmada, derin öğrenme yöntemleri tanıtılmış, farklı sektörlerdeki kullanımlarından bahsedilmiş, rüzgâr hızı ve rüzgâr gücü tahmininde izlenen yollar, kullanılan yöntemler ele alınmıştır. Yapılan literatür çalışmasında rüzgâr hızı tahminlerinde daha çok CNN ve LSTM yöntemlerinin kullanıldığı görülmüştür. Bu yöntemlerin beraber kullanıldığı çalışmalar da bulunmaktadır. Ayrıca RNN, CNN, LSTM, GRU ve diğer yöntemlerin hibrit olarak kullanıldığı modellerde tekli yöntemlere nazaran daha başarılı sonuçlara ulaşıldığı görülmüştür.

KAYNAKLAR

Ahmad T, Zhang D, Huang C,(2021) Methodological framework for short-and medium-term energy, solar and

wind power forecasting with stochastic-based machine learning approach to monetary and energy policy applications, *Energy*, 231.

Ahmad T, Zhang D, (2022) A data-driven deep sequence-to-sequence long-short memory method along with a gated recurrent neural network for wind power forecasting, *Energy*, 239.

Aksoy B, (2019) Derin Öğrenme ve Robotlardaki Uygulamaları, 4th International Congress on 3d Printing (Additive Manufacturing) Technologies and Digital Industry, Antalya, 1172-1180.

Alkhatat G, Mehmood R, (2021) A review and taxonomy of wind and solar energy forecasting methods based on deep learning, *Energy AI*, 4.

Aly H H H, (2020) A novel deep learning intelligent clustered hybrid models for wind speed and power forecasting, *Energy*, 213.

Aslam S, Herodotou H, Mohsin S M, Javaid N, Ashraf N, Aslam S, (2021) A survey on deep learning methods for power load and renewable energy forecasting in smart micro grids, *Renewable and Sustainable Energy Reviews*, 144.

Aslan M, (2021) Derin Öğrenme ile Şeftali Hastalıklarının Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 23: 540–546.

Bali V, Kumar A, Gangwar S, (2020) A Novel Approach for Wind Speed Forecasting Using LSTM-ARIMA Deep Learning Models, *International Journal of Agricultural and Environmental Information Systems (IJAEIS)*, 11(3): 13-30.

Bingöl K, Akan A, Örmecioglu H, Er A, (2020) Depreme dayanıklı mimari tasarımda yapay zeka uygulamaları: Derin öğrenme ve görüntü işleme yöntemi ile düzensiz taşıyıcı sistem tespiti, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35(4): 2197–2210.

Bisogni C, Cascone L, Castiglione A, Passero I, (2021) Deep learning for emotion driven user experiences, *Pattern Recognition Letters*, 152: 115–121.

Bulut B, (2021) Rüzgar Çiftliklerinde Kalan Faydalı Ömür Tahmini, *International Journal Of 3d Printing Technologies And Digital Industry*, 5(2): 145-154.

Canbay Y, İsmetoğlu A, Canbay P, (2021) Covid-19 Hastalığının Teşhisinde Derin Öğrenme Ve Veri Mahremiyeti, *Mühendislik Bilimleri ve Tasarım Dergisi*, 9(2): 701-715.

Chandran V, Patil C, Merline Manoharan A, Ghosh A, Sumithra M, Karthick A, Rahim R Arun K, (2021) Wind power forecasting based on time series model using deep machine learning algorithms, *Materials Today: Proceedings*, 47: 115–126.

Chen H, Birkelund Y, Yuan F, (2021) Examination of turbulence impacts on ultra-short-term wind power and speed forecasts with machine learning, *Energy Reports*, 7(6): 332-338.

Chen H, Birkelund Y, Zhang Q, (2021) Data-augmented sequential deep learning for wind power forecasting, *Energy Conversion and Management*, 248.

Chen J, Zeng G Q, Zhou W, Du W, Lu K D, (2018) Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization, *Energy Conversion and Management*, 165.

Chen Y, Wang Y, Dong Z, Su J, Han Z, Zhou D, Zhao Y, Bao Y, (2021) 2-D regional short-term wind speed forecast based on CNN-LSTM deep learning model, *Energy Conversion and Management*, 244.

Chen Y, Zhang S, Zhang W, Peng J, Cai Y, (2019) Multifactor spatio-temporal correlation model based on a combination of convolutional neural network and long short-term memory neural network for wind speed forecasting, *Energy Conversion and Management*, 185.

Cömert Z, Akbulut Y, Alçin Ö F, Akpınar M, Budak Ü, Aslan M, Şengür A, (2020) Electrocardiogram beat classification using deep convolutional neural network techniques, *Modelling and Analysis of Active Biopotential Signals in Healthcare*, 1(12).

Daş R, Polat B, Tuna G, (2019) Derin Öğrenme ile Resim ve Videolarda Nesnelerin Tanınması ve Takibi, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(2): 571–581.

Demolli H, Dokuz A Ş, Ecemiş A, Gökçek M, (2019) Wind power forecasting based on daily wind speed data using machine learning algorithms, *Energy Conversion and Management*, 198.

Doğan F ve Türkoğlu İ, (2019) Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme, *Dicle*

Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 10 (2): 409–445.

Dokuz Y, Tüfekçi Z, (2020) A Review on Deep Learning Architectures for Speech Recognition, European Journal of Science and Technology, Özel Sayı: 169-176.

Elyasichamazkoti F, Khajehpoor A, (2021) Application of machine learning for wind energy from design to energy-Water nexus: A Survey, Energy Nexus, 2.

Feng C, Cui M, Hodge B M, Zhang J,(2017) A data-driven multi-model methodology with deep feature selection for short-term wind forecasting, Applied Energy, 190: 1245-1257.

Feng W, Guan N, Li Y, Zhang X, Luo Z, (2017) Audio visual speech recognition with multimodal recurrent neural networks, 2017 International Joint Conference on Neural Networks (IJCNN), 681-688.

Görgel P, Kavlak E, (2020) Uzun Kısa Süreli Hafıza ve Evrimsel Sinir Ağları ile Rüzgar Enerjisi Üretim Tahmini, Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 11(1): 69–80.

Harbola S, Coors V,(2019) One dimensional convolutional neural network architectures for wind prediction, Energy Conversion and Management, 195: 70-75.

Helbing G, Ritter M,(2018) Deep Learning for fault detection in wind turbines, Renewable and Sustainable Energy Reviews, 98: 189-198.

Hinton G E, Osindero S, Teh Y W, (2006) A Fast Learning Algorithm for Deep Belief Nets, Neural Computation, 18 (7): 1527–54.

Hochreiter S, Schmidhuber J, (1997) Long Short-Term Memory, Neural Comput, 9(8): 1735-1780.

Hong Y Y, Rioflorido C L P P, (2019) A hybrid deep learning-based neural network for 24-h ahead wind power forecasting, Applied Energy, 250:530-539.

Hong Y Y, Satriani T R A,(2020) Day-ahead spatiotemporal wind speed forecasting using robust design-based deep learning neural network, Energy,209.

Hossain M A, Chakraborty R K, Elsayah S, Ryan M J, (2021) Very short-term forecasting of wind power generation using hybrid deep learning model, Journal of Cleaner Production, 296.

Hu Q, Zhang R, Zhou Y,(2016) Transfer learning for short-term wind speed prediction with deep neural networks, Renewable Energy, 85.

Hua L, Zhang C, Peng T, Ji C, Nazir M, (2021) Integrated framework of extreme learning machine (ELM) based on improved atom search optimization for short-term wind speed prediction, Energy Conversion and Management, 252.

Işık G, Artuner H, (2016) Recognition of radio signals with deep learning Neural Networks, 2016 24th Signal Processing and Communication Application Conference (SIU), Zonguldak, Türkiye, 837-840.

İnik Ö, Ülker E, (2017) Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6 (3): 85–104.

Karabiber A, Alçın Ö F, (2019) Short Term PV Power Estimation by means of Extreme Learning Machine and Support Vector Machine, [2019 7th International Istanbul Smart Grids and Cities Congress and Fair \(ICSG\)](#), İstanbul, Türkiye, ss. 41-44.

Kayaalp K, Süzen A, (2018) Derin Öğrenme ve Türkiye’deki Uygulamaları, Iksad International Publishing House.

Kaynar O, Görmez Y, Işık Y, (2016) Oto Kodlayıcı Tabanlı Derin Öğrenme Makinaları İle Spam Tespiti, 3. rd International Management Information System Conference, İzmir, Türkiye , ss.44-54

Keleş A, (2018). Derin Öğrenme ve Sağlık Alanındaki Uygulamaları, Turkish Studies Information Technologies & Applied Sciences, 13(21): 113-127.

Kıymaz Y E, (2021) Güneş enerjisi santrallerinde derin öğrenme kullanılarak elektrik üretimi tahmininin yapılması, Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.

Koyun A, Afşin E, (2017) Derinleştirme ile İki Boyutlu Optik Karakter Tanıma,Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 10(1): 11–14.

Küçük D, Arıcı N, (2018) Doğal Dil İşlemede Derin Öğrenme Uygulamaları Üzerine Bir Literatür Çalışması,Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi, 2(2):76-86.

Li C, Tang G, Xue X, Chen X, Wang R, Zhang C, (2020) The short-term interval prediction of wind power using the deep learning model with gradient descend optimization, *Renewable Energy*, 155.

Lin WH, Wang P, Chao KM, Lin HC, Yang ZY, Lai YH, (2021) Wind Power Forecasting with Deep Learning Networks: Time-Series Forecasting, *Applied Sciences*, 11(21):10335.

Lin Z, Liu X, (2020) Wind power forecasting of an offshore wind turbine based on high-frequency SCADA data and deep learning neural network, *Energy*, 201.

Liu H, Yu C, Wu H, Duan Z, Yan G, (2020) A new hybrid ensemble deep reinforcement learning model for wind speed short term forecasting, *Energy*, 202.

Meka R, Alaeddini A, Bhaganagar K, (2021) A robust deep learning framework for short-term wind power forecast of a full-scale wind farm using atmospheric variables, *Energy*, 221.

Metlek S, Kayaalp K, (2021) Arı Hastalıklarının Hibrit Bir Derin Öğrenme Yöntemi İle Tespiti, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(3): 1715–1732.

Mujeeb S, Alghamdi TA, Ullah S, Fatima A, Javaid N, Saba T, (2019) Exploiting Deep Learning for Wind Power Forecasting Based on Big Data Analytics, *Applied Sciences*, 9(20):4417.

Neshat M, Nezhad M M, Abbasnejad E, Mirjalili S, Tjernberg L B, Garcia D A, Alexander B, (2021) A deep learning-based evolutionary model for short-term wind speed forecasting: A case study of the Lillgrund offshore wind farm, *Energy Conversion and Management*, 236.

Pérez E, Pérez J, Segarra-Tamarit J, Beltran H, (2021) A deep learning model for intra-day forecasting of solar irradiance using satellite-based estimations in the vicinity of a PV power plant, *Solar Energy*, 218: 652–660.

Qin J, Yang J, Chen Y, Ye Q, Li H, (2021) Two- stage short- term wind power forecasting algorithm using different feature-learning models, *Fundamental Research*, 1(4): 472–481.

Sertkaya M E, (2018) Derin Öğrenme Tekniklerinin Biyomedikal İmgeler Üzerine Uygulamaları, *Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*, 70s.

Shamshirband S, Rabczuk T, Chau K W, (2021) A Survey of Deep Learning Techniques: Application in Wind and Solar Energy Resources, *IEEE Access*, 2.

Sönmez D, (2018) Geri Yayılım Algoritması'na Matematiksel Yaklaşım, Available online: <https://www.derinogrenme.com/2018/06/28/geri-yayilim-algoritmasina-matematiksel-yaklasim/> (Erişim Tarihi: 03.03.2022)

Şişmanoğlu G, Koçer F, Önde M, Şahingöz O, (2020) Derin Öğrenme Yöntemleri ile Borsada Fiyat Tahmini, *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1): 434–445.

Toraman S, (2018) Derin Öğrenme ile İnsansız Hava Aracı Görüntülerinden Yaya Tespiti, *Journal of Aviation*, 2(2): 64–69.

Toubeau J F, Dapoz P D, Bottieau J, Wautier A, De Grève Z, Vallée F, (2021) Recalibration of recurrent neural networks for short-term wind power forecasting, *Electric Power Systems Research*, 190.

Tüfekçi M, Karpat F, (2019) Derin Öğrenme Mimarilerinden Konvolüsyonel Sinir Ağları (CNN) Üzerinde Görüntü İşleme-Sınıflandırma Kabiliyetinin Arttırılmasına Yönelik Yapılan Çalışmaların İncelenmesi, *International Congress on HumanComputer Interaction, Optimization and Robotic Applications*, 4(5): 25-31.

Türkoglu M, Alçın Ö F, Aslan M, Al-Zebari A, Şengür A, (2021) Deep rhythm and long short term memory-based drowsiness detection, *Biomedical Signal Processing and Control*, 65: 434–445.

Wang H Z, Wang G B, Li G Q, Peng J C, Liu Y T, (2016) Deep belief network based deterministic and probabilistic wind speed forecasting approach, *Applied Energy*, 182: 80-93.

Wang Y, Zou R, Liu F, Zhang L, Liu Q, (2021) A review of wind speed and wind power forecasting with deep neural Networks, *Applied Energy*, 304.

Wu W, Chen K, Qiao Y, Lu Z, (2016) Probabilistic short-term wind power forecasting based on deep neural networks, 2016 International Conference on Probabilistic Methods Applied to Power Systems (PMAPS), Pekin, Çin, 1-8.

Xiang L, Liu J, Yang X, Hu A, Su H, (2022) Ultra-short term wind power prediction applying a novel model named SATCN-LSTM, *Energy Conversion and Management*, 252.

Xiong B, Lou L, Meng X, Wang X, Ma H, Wang Z, (2022) Short-term wind power forecasting based on

Attention Mechanism and Deep Learning, Electric Power Systems Research, 206.

Yan S, (2018) Understanding LSTM and Its Diagrams. Available online: <https://medium.com/mlreview/understanding-lstm-and-its-diagrams-37e2f46f1714> (Erişim Tarihi 02.03.2022).

Yapıcı M, Tekerek A, Topaloğlu N, (2019) Literature Review of Deep Learning Research Areas, Gazi Journal of Engineering Sciences, 5(3): 188–215.

Yıldız C, Açıkgöz H, Korkmaz D, Budak Ü, (2020) An improved residual-based convolutional neural network for very short-term wind power forecasting, Energy Conversion and Management, 228.

Yu B, Sun F, Chen C, Fu G, Hu L, (2022) Power demand response in the context of smart home application, Energy, 240.

Zhang J, Wei Y, Tan Z, (2020) An adaptive hybrid model for short term wind speed forecasting, Energy, 190.

Zhang W, Lin Z, Liu X, (2022) Short-term offshore wind power forecasting - A hybrid model based on Discrete Wavelet Transform (DWT), Seasonal Autoregressive Integrated Moving Average (SARIMA), and deep-learning-based Long Short-Term Memory (LSTM), Renewable Energy, 185: 611-628.

Zhu W, Ma Y, Zhou Y, Benton M, Romagnoli J, (2018) Deep Learning Based Soft Sensor and Its Application on a Pyrolysis Reactor for Compositions Predictions of Gas Phase Components, [Computer Aided Chemical Engineering](#), 44:2245–2250.

Zhu Z, Hu Z, Dai W, Chen H, Lv Z, (2022) Deep learning for autonomous vehicle and pedestrian interaction safety, Safety Science, 145(6): 105479.