

Ocak'23

Sayı/Number: 1 / Volume: 13
Yıl/Year: 2023

Yayın Sahibi

TMMOB
Elektrik Mühendisleri Odası Adına
Mahir ULUTAŞ

Sorumlu Yazı İşleri Müdürü

Eylem ÖLMEZOĞLU

Yayın İdare Merkezi

Ihlamur Sokak No:10 Kat:3
Kızılay - Ankara
Tel: (312) 425 32 72
Faks: (312) 417 38 18
<http://bilimseldergi.emo.org.tr>
bilimseldergi@emo.org.tr
EMO Üyelerine parasız dağıtılır

Dergi Koordinatörü

Sevgi Kinacı
sevgi.kinaci@emo.org.tr

Sayfa Düzeni

TMMOB
Elektrik Mühendisleri Odası

Yayın Türü

Yerel Süreli Yayın
6 ayda bir yayınlanır

Basım Adedi

500

Basım Tarihi

Ocak 2023

EMO BİLİMSEL DERGİ

Elektrik, Elektronik, Bilgisayar, Biyomedikal
Mühendisliği Bilimsel Dergisi

The Journal of Electrical, Electronics, Computer and
Biomedical Engineering

YAYIN KURULU

BAŞ EDİTÖR/EDITOR IN CHIEF

Prof. Dr. Timur Aydemir
Kadir Has Üniversitesi

EDİTÖRLER/EDITORIAL BOARD

Prof. Dr. Erhan Akın
Fırat Üniversitesi

Prof. Dr. Güven Önbilgin
Ondokuz Mayıs Üniversitesi

Prof. Dr. Arif Nacaroğlu
Gaziantep Üniversitesi

Prof. Dr. Özlem Özgün
Hacettepe Üniversitesi



TMMOB

Elektrik Mühendisleri Odası

UCTEA/Chamber of Electrical Engineers

EMO Bilimsel Dergi Danışma Kurulu

| | |
|--------------------------------|--|
| Prof. Dr. A. Hamit Serbest | Çukurova Üniversitesi |
| Prof. Dr. Altay Güvenir | Bilkent Üniversitesi |
| Prof. Dr. Cengizhan Öztürk | Boğaziçi Üniversitesi |
| Prof. Dr. Erhan Akın | Fırat Üniversitesi |
| Prof. Dr. Güven Önbilgin | Ondokuz Mayıs Üniversitesi |
| Prof. Dr. Murat Eyüboğlu | Orta Doğu Teknik Üniversitesi |
| Prof. Dr. Timur Aydemir | Kadir Has Üniversitesi |
| Prof. Dr. Ali Hikmet Doğru | Orta Doğu Teknik Üniversitesi |
| Prof. Dr. Arif Nacaroğlu | Gaziantep Üniversitesi |
| Prof. Dr. Atilla Bir | Fatih Sultan Mehmet Vakıf Üniversitesi |
| Prof. Dr. Aydın Köksal | Bilişim A.Ş. |
| Prof. Dr. Aydoğan Özdemir | İstanbul Teknik Üniversitesi |
| Prof. Dr. Aysin Baytan Ertüzün | Boğaziçi Üniversitesi |
| Prof. Dr. Belgin Turkey | İstanbul Teknik Üniversitesi |
| Prof. Dr. Bülent Sankur | Boğaziçi Üniversitesi |
| Prof. Dr. Cüneyt Güzeliş | Yaşar Üniversitesi |
| Prof. Dr. Erdal Panayırçı | Kadir Has Üniversitesi |
| Prof. Dr. Erkan Afacan | Gazi Üniversitesi |
| Prof. Dr. Ferit Acar Savacı | İzmir Yüksek Teknoloji Enstitüsü |
| Prof. Dr. H. Bülent Ertan | Orta Doğu Teknik Üniversitesi |
| Prof. Dr. Haldun Karaca | Dokuz Eylül Üniversitesi |
| Prof. Dr. İbrahim Eksin | İstanbul Teknik Üniversitesi |
| Prof. Dr. İnci Çilesiz | İstanbul Teknik Üniversitesi |
| Prof. Dr. İrfan Karagöz | Gazi Üniversitesi |
| Prof. Dr. İsmail Hakkı Altaş | Karadeniz Teknik Üniversitesi |
| Prof. Dr. İsmail Hakkı Çavdar | Karadeniz Teknik Üniversitesi |
| Prof. Dr. Kemal Leblebicioğlu | Orta Doğu Teknik Üniversitesi |
| Prof. Dr. Lale Tükenmez Ergene | İstanbul Teknik Üniversitesi |
| Prof. Dr. Mithat İdemen | Okan Üniversitesi |
| Prof. Dr. Muhittin Gökmen | MEF Üniversitesi |
| Prof. Dr. Murat Aşkar | İzmir Ekonomi Üniversitesi |
| Prof. Dr. Müjde Güzelkaya | İstanbul Teknik Üniversitesi |
| Prof. Dr. Osman Eroğul | TOBB Ekonomi ve Teknoloji Üniversitesi |
| Prof. Dr. Oya Kalıpsız | Yıldız Teknik Üniversitesi |
| Prof. Dr. Özlem Özgün | Hacettepe Üniversitesi |
| Prof. Dr. Sermin Onaygil | İstanbul Teknik Üniversitesi |
| Prof. Dr. Tayfun Akgül | İstanbul Teknik Üniversitesi |
| Doç. Dr. Ahmet Hasan Koltuksuz | Yaşar Üniversitesi |
| Doç. Dr. Osman Abul | TOBB Ekonomi ve Teknoloji Üniversitesi |
| Bora Güngören | Portakal Teknoloji |
| Fikret Küçükdeveci | Kardinero Medikal |
| Hasan Ali Pazar | Siemens |

İÇİNDEKİLER / CONTENTS

| | |
|---|----|
| Görünür Işık Haberleşme Sistemlerinde Renk Kaydırmalı Anahtarlama Modülasyonunun Farklı Renk Uzaylarındaki Başarım Analizleri <i>Performance Analysis of Color Shift Keying Modulation in Different Color Spaces in Visible Light Communication Systems</i> Emin Tuğcu | 7 |
| Raylı Sistemlerde Peron Ayırıcı Kapı Sistemi İçin Yapay Sinir Ağı Tabanlı Hata Teşhis Yaklaşımı <i>An Artificial Neural Network Based Fault Detection Approach for Platform Screen Doors in Railway Systems</i> İsa Koç, Ömer Mermer, Necim Kırımça, Mehmet Karaköse | 13 |
| Yüksek DA Gerilim Uygulamaları için Empedans Kaynaklı Yükseltici Çevirici Tasarımı <i>Design of Impedance Source Step-up Converter for High DC Voltage Applications</i> Bülent Dağ, Mehmet Akif Özdemir, Bünyamin Tamyürek, Emrullah Aydın, M. Timur Aydemir | 23 |
| S-kutusu Büyüklüğünün Korelasyon Güç Analizi Sonuçlarına Etkisi <i>Impact of S-box Size on Results of Correlation Power Analysis</i> Selçuk Kavut, Yasin Reşit Yargıcı | 31 |
| Akıllı Şebeke Uygulamalarında Derin Öğrenme Tekniklerinin Kullanımına İlişkin Kısa Bir İnceleme <i>A Brief Review on the Use of Deep Learning Techniques in Smart Grid Applications</i> Reyhan Sağ Örnek, Zeynep Hasırcı Tuğcu | 41 |

Görünür Işık Haberleşme Sistemlerinde Renk Kaydırmalı Anahtarlama Modülasyonunun Farklı Renk Uzaylarındaki Başarım Analizleri

Performance Analysis of Color Shift Keying Modulation in Different Color Spaces in Visible Light Communication Systems

Emin Tuğcu 

Elektronik ve Haberleşme Mühendisliği Bölümü
Karedeniz Teknik Üniversitesi, Trabzon, Türkiye
emintugcu@ktu.edu.tr, ORCID: 0000-0001-5308-3071

Öz

Görünür ışık haberleşme (VLC) sistemleri, görünür ışık bandında aydınlatma amaçlı olarak kullanılan ışığı eş zamanlı olarak haberleşme amaçlı olarak da kullanırlar. Yayılan ışığın insan gözünün sağlığı açısından aydınlatma şartlarını sağlaması gerekmektedir. Renk kaydırmalı anahtarlama (CSK) modülasyonu VLC sistemlerinde aydınlatma şartlarının sağlanabilmesi için IEEE 802.15.7 standardında tanımlanmıştır. Bu makalede, CSK modülasyonunun CIE 1931, CIE 1960 ve CIE 1976 renk uzaylarındaki başarım analizleri gerçekleştirilmiştir. Başarım analizleri için AWGN kanallarda birleşim üst sınırı ve benzetim sonuçlarına ait bit hata oranı grafikleri elde edilmiştir. Elde edilen sonuçlar renk uzaylarının renk kaydırmalı anahtarlama modülasyonunun başarımını etkilediğini göstermiştir.

Anahtar kelimeler: görünür ışık haberleşmesi, renk uzayı, renk kaydırmalı anahtarlama, birleşim üst sınırı

Abstract

Visible light communication (VLC) systems use the light used for illumination purposes in the visible light band for communication purposes simultaneously. The emitted light should meet the lighting conditions in terms of the human eye's health. In order to meet the lighting conditions in VLC systems, Color shift keying (CSK) modulation is defined, outlined in IEEE 802.15.7. In this study, performance analyses of CSK modulation are performed in CIE 1931, CIE 1960, and CIE 1976 color spaces. The bit-error-rate graphics, comparing union bound and simulation outputs, are presented for the performance evaluation in the AWGN channel. Obtained results show that the color space has a significant effect on the performance of CSK modulation.

Keywords: visible light communication, color space, color shift keying, union bound

1. Giriş

Yüksek hızlı kablosuz haberleşme sistemleri, iletişim teknolojilerinde yaşanan gelişmeler sonucunda hayatımızın

temel ihtiyaçlarından birisi durumuna gelmiştir. Kablosuz haberleşme sistemlerindeki veri hızının üst sınırı iletişim bant genişliğine bağlıdır [1]. Yüksek veri hızlarına ve bant genişliğine ihtiyaç duyan uygulamalara olan talebin sürekli artması sınırlı spektruma sahip olan Radyo frekans (RF) sistemleri için önemli bir problemdir. RF sistemlerinde spektral verimlilik kazançlarında üst sınırlara ulaşıldığından veri trafiğinde yaşanan artış nedeniyle RF bandı talepleri karşılamada yetersiz kalmaktadır. RF bandında oluşan kapasite problemi araştırmacıları yeni nesil haberleşme sistemlerinin geliştirilmesi için arayışlara yöneltmiştir. Mevcut durumda kullanılan haberleşme sistemlerinin yerlerini alacak veya tamamlayıcı olarak kullanılacak haberleşme sistemlerinin geliştirilmesi taleplerin karşılanabilmesi için büyük önem arz etmektedir. RF sistemleri için tamamlayıcı nitelikte olan, görünür ışık bandını kullanan görünür ışık haberleşmesi (VLC) hem enerji verimliliği açısından hem de yüksek hızlarda haberleşmeyi sağladığından bu problemin çözümü için önemli bir aday teknolojidir [2- 4].

VLC sistemleri son yıllarda büyük ilgi görmektedir [5]. VLC teknolojisinde ortam aydınlatması ile eş zamanlı olarak bilginin iletimi de gerçekleştirilmektedir. Günlük yaşantımızın vazgeçilmez bir parçası olan ışığın, bilgi taşımak amacıyla kullanılması yenilikçi ve enerji tüketimi açısından etkin bir haberleşme teknolojisinin ortaya çıkması anlamına gelmektedir. VLC sistemlerinin RF sistemleri kadar karmaşık yapıda olmaması ve lisanslanmamış geniş bir banda sahip olmaları bu sistemlere olan ilginin hem akademi hem de endüstride her geçen gün artmasına neden olmaktadır.

Geliştirilecek yeni nesil haberleşme sistemlerinin enerji tüketimi açısından da verimli olması bir diğer önemli husustur. Günümüzde aydınlatma alanında enerji tüketiminin azaltılması konusunda önemli adımlar atılmaktadır. Örneğin, güç tüketimi yüksek olan akkor ve floresan lambaların yerini güç tüketimi düşük olan LED'ler almaya başlamıştır. Avrupa ve ABD başta olmak üzere akkor ve floresan lambalarının yasal düzenlemelerle yasaklanması sonucunda LED'lerin yakın gelecekte standart ışık kaynağı haline geleceği öngörülmektedir. VLC sistemlerinde de verici kısımda temel fonksiyonu aydınlatma olan LED'ler kullanılmaktadır [6]. LED'lerin enerji verimliliklerinin yüksek olması hem ev ve ofis aydınlatması gibi iç mekanlarda hem de sokak lambaları,

trafik lambaları ve araç ön/arka farları gibi dış mekanlarda aydınlatma alanında kullanımlarını yaygınlaştırmıştır.

VLC sistemleri yoğunluk modülasyonuna ve doğrudan algılamaya (IM/DD) dayalı sistemlerdir. İnsan gözü LED'lerin anahtarlanmasıyla oluşan ışık şiddetindeki titreşimi en az 50 Hz'e kadar algılayamamaktadır [7]. Bundan dolayı LED'ler tarafından yayılan ışığın şiddeti veya rengi insan gözünün algılayamayacağı hızda değiştirilerek aydınlatma ile eş zamanlı olarak bilgi iletimi de sağlanmaktadır. Bu durum VLC sistemlerinde iletimde kullanılan optik sinyallerin RF sistemlerinden farklı olarak pozitif ve gerçel olma zorunluluğunu beraberinde getirmektedir. Bundan dolayı RF sistemlerinde kullanılan tekniklerin VLC sistemlerinde değişiklikler yapılmadan kullanılması olanaksızdır.

RF bandı ile karşılaştırıldığında VLC sistemleri çok yüksek spektruma sahiptirler. VLC sistemlerinde yüksek veri hızlarına LED teknolojisindeki gelişmelerin sonucunda ulaşılmıştır. LED'lerin yüksek hızlarda anahtarlanmasıyla yüksek veri hızlarına ulaşılması ve eş zamanlı olarak sağlanması gereken aydınlatma ihtiyacı LED'ler tarafından yayılan ışığın beyaz ışık olma zorunluluğunu beraberinde getirmektedir. Beyaz ışığın LED'ler kullanılarak üretilmesinde temelde iki farklı yöntem kullanılmaktadır. Bu yöntemlerin ilkinde mavi LED'lerin yüzeyinin fosfor kaplanmasıyla beyaz ışık üretilir. Bu yöntem basit ve düşük maliyetli olmasına rağmen haberleşme açısından değerlendirildiğinde modülasyon hızı fosfor etkisinden dolayı düşüktür [8]. İkinci yöntemde ise kırmızı/mavi/yeşil (RGB) ışık yayan kromatik LED'lerin kullanılmasıyla beyaz ışık üretilmektedir. RGB LED'lerin kullanılmasıyla görünür ışık spektrumu yüksek modülasyon hızlarına sahip üç ayrı banda bölünmektedir. Her bir bandın bağımsız olarak modüle edilmesiyse yüksek veri hızlarına ulaşılmaktadır [9]. Her bir bandın bağımsız olarak modüle edilmesi ise beyaz ışığın üretilmesinde problem oluşturmaktadır [10]. Bu problemin çözümü için IEEE 802.15.7 standardında [11] VLC için tanımlanmış renk kaydırmalı anahtarlama (CSK) modülasyonu geliştirilmiştir. IEEE 802.15.7 standardı PHY I, PHY II ve PHY III olmak üzere üç fiziksel katman türünü desteklemektedir [11]. PHY I ve PHY II katmanları veri hızının düşük ve orta olduğu dış mekan uygulamaları için tasarlanmıştır. Bu katmanlar açma-kapama anahtarlama (OOK) ve değişken darbe konum modülasyonlarını (VPPM) desteklemektedirler. PHY III ise yüksek veri hızları için CSK modülasyonunu kullanmaktadır [11].

CSK modülasyonu CIE 1931 renk uzayında tanımlanmıştır. CIE 1931 renk uzayı Uluslararası Aydınlatma Komisyonu (CIE) tarafından insanın renk algısının incelenmesi sonucunda 1931 yılında CIE XYZ olarak tanımlanmış ve standart haline getirilmiştir. Bu standartta, tristimulus değerleri olarak tanımlanan üç değer bir rengi tanımladığı 3 boyutlu bir renk uzayı tanımlanmıştır. Renk uzayları bütün renkleri tanımlamak için kullanılan matematiksel modellerdir ve bütün renkleri temsil edecek şekilde oluşturulurlar [12].

VLC sistemlerinde de yüksek veri hızlarına ulaşabilmek için mavi LED'lere göre 3 boyutlu renk uzayında RGB LED'lerin kullanımı daha etkin bir çözümdür [13]. RGB LED'leri kullanan CSK modülasyonu hem istenen aydınlatma şartlarının sağlanması hem de yüksek veri hızlarına ulaşmak için 3 boyutlu RGB işaret uzayında tanımlanmıştır. 3 boyutlu RGB uzayında semboller arasındaki karar bölgelerinin tam

olarak belirlenmesi karmaşık olduğundan CSK modülasyonu için bit hata oranı (BER) ifadelerini analitik olarak geliştirmek zor bir problemdir. [10] çalışmasında 3 boyutlu RGB uzayının 2 boyutlu uzaya dönüştürülmesiyle semboller arasındaki karar bölgeleri daha yüksek doğrulukla belirlenerek sembol hata oranı (SER) ve BER analizleri yapılmıştır. [14] çalışmasında 3 boyutlu RGB sembol uzayında en yakın komşu semboller arasındaki hata olasılığının hesaplanmasıyla SER analizi yapılmıştır. BER analizi ise SER ifadesinin her bir sembolün taşıdığı bit sayısına oranlanmasıyla yaklaşık olarak elde edilmiştir. [15] çalışmasında RGB uzayındaki tüm semboller arasındaki hata olasılıklarının hesaplanmasıyla birleşim üst sınırı için SER analizi yapılmıştır. [16] çalışmasında 3 boyutlu RGB sembol uzayında ağırlığı yüksek olan semboller arasındaki ikili geçiş olasılıklarının hesaplanmasıyla SER analizi yapılmıştır. [14, 17]'de CSK modülasyonun toplanır beyaz Gaussian gürültülü (AWGN) kanallarındaki BER başarımlarını analizleri gerçekleştirilmiştir.

IEEE 802.15.7 standardında CSK modülasyonu için CIE 1931 renk uzayında 9 farklı renk bandı tanımlanmıştır [11]. CSK modülasyonunun renk bantlarındaki başarımlarını analizleri [17] çalışmasında incelenmiştir. [17] çalışmasında 4-CSK, 8-CSK ve 16-CSK modülasyonları için benzetim çalışmaları yapılmış ve elde edilen sonuçlardan renk bantlarının CSK modülasyonunun başarımlarını etkilediği görülmektedir. Bu çalışmalarda CSK modülasyonu CIE 1931 renklilik diyagramında gerçekleştirilmiştir [18]. CIE tarafından 1960 ve 1976 yıllarında CIE 1960 ve CIE 1976 olmak üzere iki ayrı renklilik diyagramı daha yayımlanmıştır. CIE 1931 renklilik diyagramı gün ışığına yakın ortamdaki renkler için daha iyi sonuçlar verirken CIE 1960 ise karanlık ortam görüşüne daha uygundur [19]. CIE 1960 diyagramı sarı, kahverengi, turuncu ve kırmızı renkleri temsil etmek için yetersiz kaldığından CIE, 1976 yılında 1960 diyagramının koordinat formüllerini geliştirerek yeni bir diyagram daha yayımlanmıştır [20].

Literatür incelendiğinde CSK modülasyonunun bu renk uzaylarındaki başarımlarını analizlerinin gerçekleştirilmediği görülmektedir. Bu çalışmada CSK modülasyonunun CIE 1960 ve CIE 1976 renk uzaylarındaki bit hata oranı (BER) başarımlarını elde edilmiş ve renk uzaylarının CSK modülasyonunun başarımlarına etkileri incelenmiştir.

Makalenin bundan sonraki kısımlarında 2. bölümde CSK modülasyonu ve demodülasyonu genel hatlarıyla açıklanmıştır. 4-CSK, 8-CSK ve 16-CSK modülasyonları için SER ve BER analizleri yapılmıştır. 3. bölümde CSK modülasyon türlerine ait AWGN kanallarda elde edilen birleşim üst sınırı ve benzetim sonuçları verilmiştir. Son bölümde ise çalışmanın sonuçları irdelenmiştir.

2. Materyal ve Metot

2.1. CSK Modülasyonu ve Demodülasyonu

CSK modülasyonu IEEE 802.15.7 standardında VLC sistemleri için geliştirilen bir modülasyon türüdür. Çok renkli kromatik LED'ler kullanılarak gerçekleştirilir. Aydınlatma şartlarının sağlanabilmesi ve göz sağlığı açısından renk bantlarından yayılan toplam ışık yoğunluğunun sabit olması gerekmektedir.

VLC sistemlerinde iletilen işaretleme kısıtlamaları mevcuttur. İşaretin iletimi için LED'lerden yayılan ışığın şiddeti ve rengi değiştirildiği için iletilen işaret vektörü pozitif

değerli olmak zorundadır. $A = \{s_1, s_2, \dots, s_M\}$ olmak üzere M sembolük CSK sisteminde veri ilk olarak renk kodlaması sonucunda s_i sembolleri ile eşleştirilir. $s_i = [p_r, p_g, p_b]^T$ iletilen işaret vektörünün pozitif olma zorunluluğundan dolayı (1) denklemi ile verilen şartları sağlamalıdır.

$$p_r \geq 0, p_g \geq 0, p_b \geq 0 \quad (1)$$

Burada p_r, p_g ve p_b sırasıyla kırmızı, yeşil ve mavi iletim renk bantlardaki ışık yoğunluğunu göstermektedir. Kırpışma etkisinin önlenmesi için LED'lerden yayılan işaretin optik gücü (2) denkleminde verildiği gibi bir sembol süresince sabit kalmalıdır.

$$p_r + p_g + p_b = P_T \quad (2)$$


Burada P_T dimming şartlarına göre değişmektedir. CSK modülasyonu CIE 1931 renk uzayında [18] uluslararası aydınlatma komisyonu tarafından tanımlanan x-y renk koordinatları kullanılarak gerçekleştirilir. CIE 1931 renklilik diyagramı x-y düzleminde farklı dalga boylarındaki renklerin dağılımını gösterir. Tanımlanan renk uzayında tüm renkler kromatik değerlerine karşılık gelen x-y koordinatları ile temsil edilirler. CIE 1960 renklilik diyagramı u-v düzleminde tanımlanmıştır. CIE 1931 diyagramındaki bir noktanın CIE 1960 diyagramı üzerindeki karşılığı (3) denklemi ile verilmiştir [19].

$$u = \frac{4x}{-2x+12y+3}, v = \frac{6y}{-2x+12y+3} \quad (3)$$

CIE 1976 renksellik diyagramı ise $u' - v'$ düzleminde tanımlanmıştır [20]. CIE 1931 diyagramındaki bir noktanın CIE 1976 diyagramı üzerindeki karşılığı (4) denklemi ile verilmiştir [20].

$$u' = \frac{4x}{-2x+12y+3}, v' = \frac{9y}{-2x+12y+3} \quad (4)$$

Şekil 1' de CSK sistemine ait verici blok diyagramı görülmektedir.



Şekil 1: CSK verici blok diyagramı

Örnek olarak CIE 1931 renk uzayı için verici tarafta ilk olarak ikili veri, renk kodlaması sonucunda x-y kromatik değerleri ile tanımlanan M seviyeli sembollere dönüştürülür. Tablo 1, Tablo 2 ve Tablo 3' te CIE 1931, CIE 1960 ve CIE 1976 renk uzaylarında 4-CSK, 8-CSK ve 16-CSK modülasyonları için kromatik değerler verilmiştir.

Tablo 1: 4-CSK modülasyonu kromatik değerleri

| Bant Merkezi | Sembollerin kromatik değerleri | | |
|---------------|--------------------------------|------------------|------------------|
| | 4-CSK (CIE 1931) | 4-CSK (CIE 1960) | 4-CSK (CIE 1976) |
| (0.734 0.265) | (0.402 0.597) | (0.172 0.383) | (0.172 0.574) |
| (0.402 0.597) | (0.435 0.290) | (0.310 0.310) | (0.310 0.465) |
| (0.169 0.007) | (0.169 0.007) | (0.246 0.015) | (0.246 0.023) |
| | (0.734 0.265) | (0.623 0.337) | (0.623 0.506) |

Tablo 2: 8-CSK modülasyonu kromatik değerleri

| Bant Merkezi | Sembollerin koordinat değerleri | | |
|---------------|---------------------------------|------------------|------------------|
| | 8-CSK (CIE 1931) | 8-CSK (CIE 1960) | 8-CSK (CIE 1976) |
| (0.734 0.265) | (0.324 0.400) | (0.181 0.336) | (0.181 0.503) |
| | (0.297 0.200) | (0.247 0.250) | (0.247 0.375) |
| | (0.579 0.329) | (0.400 0.341) | (0.400 0.511) |
| | (0.402 0.597) | (0.452 0.136) | (0.485 0.328) |
| | (0.169 0.007) | (0.402 0.597) | (0.172 0.574) |
| | | (0.169 0.007) | (0.246 0.015) |
| | | (0.513 0.486) | (0.263 0.374) |
| | | (0.734 0.265) | (0.623 0.337) |

Tablo 3: 16-CSK modülasyonu kromatik değerleri

| Bant Merkezi | Sembollerin koordinat değerleri | | |
|---------------|---------------------------------|-------------------|-------------------|
| | 16-CSK (CIE 1931) | 16-CSK (CIE 1960) | 16-CSK (CIE 1976) |
| (0.734 0.265) | (0.402 0.597) | (0.172 0.383) | (0.172 0.574) |
| | (0.413 0.495) | (0.204 0.366) | (0.204 0.549) |
| | (0.335 0.298) | (0.227 0.303) | (0.227 0.454) |
| | (0.324 0.400) | (0.181 0.336) | (0.181 0.503) |
| | (0.623 0.376) | (0.398 0.360) | (0.398 0.540) |
| | (0.513 0.486) | (0.263 0.374) | (0.263 0.560) |
| | (0.435 0.290) | (0.310 0.310) | (0.310 0.465) |
| | (0.402 0.597) | (0.524 0.384) | (0.320 0.527) |
| | (0.169 0.007) | (0.734 0.265) | (0.623 0.506) |
| | | (0.169 0.007) | (0.246 0.015) |
| | | (0.247 0.204) | (0.199 0.247) |
| | | (0.258 0.101) | (0.279 0.164) |
| | | (0.546 0.179) | (0.538 0.265) |
| | | (0.634 0.273) | (0.506 0.327) |
| | | (0.446 0.187) | (0.410 0.258) |
| | | (0.357 0.093) | (0.420 0.164) |

Sembollere ait x-y kromatik değerleri elde edildikten sonra R, G, B kanallarına ait optik güç yoğunlukları (5-7) denklemleri ile elde edilirler [21].

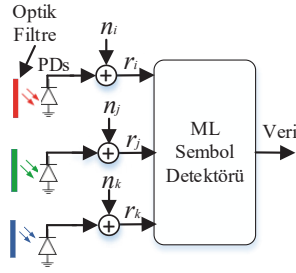
$$x = p_r x_i + p_g x_j + p_b x_k \quad (5)$$

$$y = p_r y_i + p_g y_j + p_b y_k \quad (6)$$

$$p_r + p_g + p_b = P_T \quad (7)$$

Denklem sisteminde yer alan $(x_i, y_i), (x_j, y_j)$ ve (x_k, y_k) CSK sisteminde kullanılan ışık kaynaklarının merkez dalga boylarının kromatik değerlerine karşılık gelir. Her bir sembole ait hesaplanan $[p_r, p_g, p_b]$ yoğunluk bilgileri işaret uzayında $s_i = [p_r, p_g, p_b]^T$ ($0 \leq i \leq M - 1$) olmak üzere 3-boyutlu RGB işaret uzayında sembolleri oluştururlar. CIE 1960 ve CIE 1976 renk uzayları için de R, G, B kanallarına ait optik güç yoğunlukları benzer şekilde elde edilirler.

Şekil 2' de CSK sistemine ait alıcı blok diyagramı görülmektedir. VLC sistemlerinde alıcı tarafta foto-detektörler (PDs) kullanılır. Foto-detektörler tarafından alınan optik işaret elektriksel işarete dönüştürülür. Haberleşme kanalı AWGN kanal olarak modellendiğinde alıcı tarafta alınan işaret (8) ile verilmiştir.



Şekil 2: CSK alıcı yapısı

$$\mathbf{r}_i = \mathbf{s}_i + \boldsymbol{\eta}_i \quad (8)$$

Burada $\boldsymbol{\eta}_i = [\eta_r, \eta_g, \eta_b]^T$ olmak üzere her bir bileşenin varyansı σ^2 olan beyaz gürültüdür. Alınan işaret $\mathbf{r}_i = [\hat{p}_r, \hat{p}_g, \hat{p}_b]^T$, den 3-boyutlu işaret uzayında iletilen sembolere (9)'da verildiği gibi en büyük olabilirlik (ML) sezici ile en küçük öklid mesafesine göre karar verilir.

$$\bar{s} = \arg \min_{s_i \in A} \|\mathbf{r}_i - \mathbf{s}_i\|_2 \quad (9)$$

Burada A 3-boyutlu uzayda M seviyeli CSK sembollerinden oluşan kümeye karşılık gelir. Son olarak karar verilen semboller \bar{s} ikili veriye dönüştürülür.

2.1.1. BER ve SER Analizi

Bu kısımda CSK modülasyonunun AWGN kanallarında SER ve BER analizi yapılmıştır. M seviyeli bir işaret uzayında SER ifadesi (10) ile verilir.

$$P_s = \frac{1}{M} \sum_{i=1}^M \sum_{j \neq i}^M Q \left(\sqrt{\frac{D(\mathbf{s}_i - \mathbf{s}_j)^2}{2N_0}} \right) \quad (10)$$

Burada $D(\mathbf{s}_i - \mathbf{s}_j)$ terimi \mathbf{s}_i sembolü ile \mathbf{s}_j sembolü arasındaki öklid mesafesine karşılık gelir ve (11) ile hesaplanır.

$$D = \|\mathbf{s}_i - \mathbf{s}_j\|_2 \quad (11)$$

Denklem (10)'da N_0 ise AWGN gürültünün tek yanlı güç spektral yoğunluğuna karşılık gelir. 4-CSK modülasyonu için CIE 1931, CIE 1960 ve CIE 1976 renk uzaylarındaki elde edilen SER ifadeleri sırasıyla (12), (13) ve (14) ile verilmiştir.

$$P_s = 0.5Q \left(\frac{0.8157}{\sqrt{2N_0}} \right) + Q \left(\frac{0.817}{\sqrt{2N_0}} \right) + 1.5Q \left(\frac{1.4142}{\sqrt{2N_0}} \right) \quad (12)$$


$$P_s = 0.5Q \left(\frac{0.547}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{0.924}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{1.045}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{1.412}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{1.413}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{1.414}{\sqrt{2N_0}} \right) \quad (13)$$

$$P_s = 0.5Q \left(\frac{0.548}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{0.924}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{1.044}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{1.412}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{1.413}{\sqrt{2N_0}} \right) + 0.5Q \left(\frac{1.414}{\sqrt{2N_0}} \right) \quad (14)$$

8-CSK ve 16-CSK modülasyonları için de SER ifadeleri (10) kullanılarak benzer şekilde hesaplanabilir. (13) ve (14)' den 4-CSK modülasyonu için CIE 1960 ve CIE 1976 renk uzaylarındaki başarımın yaklaşık olarak aynı olduğu görülmektedir. BER analizi ise (10) ile verilen sembol hata olasılığının her sembolün taşıdığı bit sayısına oranıyla elde edilmiş ve (15) ile verilmiştir [14].


$$P_b = \frac{P_s}{\log_2 M} \quad (15)$$

Şekil 3' de 4-CSK modülasyonuna ait birleşim üst sınırı ve benzetim sonuçları verilmiştir. Verilen sonuçlardan birleşim üst sınırı ve benzetim sonuçlarının uyumlu olduğu görülmektedir. Başarım sonuçları incelendiğinde renk uzaylarının CSK modülasyonun başarımına etkisi olduğu görülmektedir. CIE 1960 ve CIE 1976 renk uzayında 4-CSK modülasyonun başarımının (13) ve (14) ile uyumlu olarak yaklaşık olarak aynı olduğu görülmektedir. CIE 1931 ile CIE 1960 ve CIE 1976 renk uzayları arasında ise önemli bir başarım farkı görülmektedir. CIE 1960 ve CIE 1976 renk uzaylarında semboller arasındaki öklid mesafelerinin azalması başarımı düşürmektedir. $1e-3$ hata seviyesinde BER başarımında yaklaşık olarak 2.5 dB fark oluşmaktadır.



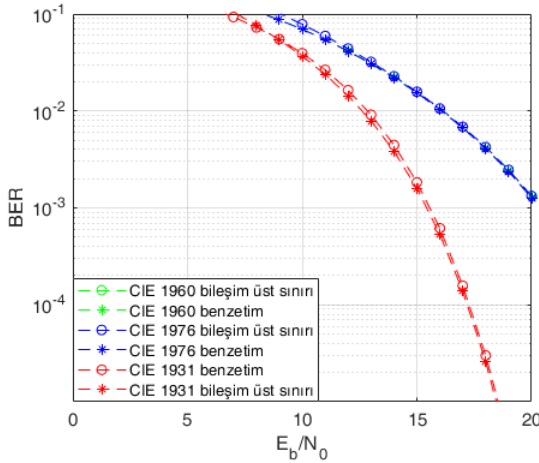
Şekil 3: 4-CSK modülasyonu için BER değişimleri

Şekil 4' te 8-CSK modülasyonuna ait birleşim üst sınırı ve benzetim sonuçları görülmektedir. Verilen sonuçlardan birleşim üst sınırı ve benzetim sonuçlarının uyumlu olduğu görülmektedir. 4-CSK modülasyonunda olduğu gibi 8-CSK modülasyonun da CIE 1960 ve CIE 1976 renk uzaylarında başarımının yaklaşık olarak aynı olduğu görülmektedir. CIE 1931 ile CIE 1960 ve CIE 1976 renk uzayları arasında $1e-3$ hata seviyesinde yaklaşık olarak başarımında 6 dB fark oluşmaktadır.



Şekil 4: 8-CSK modülasyonu için BER değişimleri

Şekil 5' te ise 16-CSK modülasyonuna ait birleşim üst sınırı ve benzetim sonuçları görülmektedir. Verilen sonuçlardan birleşim üst sınırı ve benzetim sonuçlarının uyumlu olduğu görülmektedir. 4-CSK ve 8-CSK modülasyonunda olduğu gibi CIE 1960 ve CIE 1976 renk uzaylarında başarımların yaklaşık olarak aynı olduğu görülmektedir. Modülasyon derecesi yükseldikçe aynı işaret gürültü oranı seviyesinde işaret uzayında semboller arasındaki öklid mesafelerin azalması beklendiği gibi başarımın azalmasına neden olmaktadır.



Şekil 5: 16-CSK modülasyonu için BER değişimleri

3. Sonuçlar

Bu çalışmada VLC sistemleri için 802.15.7 standardında tanımlanan CSK modülasyonun farklı renk uzaylarındaki başarımların analizleri gerçekleştirilmiştir. Bu kapsamda CIE 1931, CIE 1960 ve CIE 1976 renk uzaylarında 4-CSK, 8-CSK ve 16-CSK modülasyonları için AWGN kanallarda birleşim üst sınırı ve benzetim sonuçları elde edilmiştir. Elde edilen sonuçlardan renk uzaylarının CSK modülasyonunun başarımı üzerinde etkisi olduğu görülmektedir. CIE 1960 ve CIE 1976 renk uzaylarında benzetim ve birleşim üst sınırı sonuçlarından CSK modülasyonun başarımının yaklaşık olarak aynı olduğu görülmektedir. 4-CSK modülasyonu için CIE 1960 ve CIE 1976 renk uzayları arasında 1e-3 hata seviyesinde BER başarımında yaklaşık olarak 2.5 dB fark oluşmaktadır. Aynı hata seviyesinde 8-CSK modülasyonunda ise başarımında yaklaşık olarak 6 dB fark oluşmaktadır. CIE 1931 renk uzayından CIE 1960 ve CIE 1976 renk uzaylarına dönüşüm işlemi bu renk uzaylarında CSK modülasyon türlerinde semboller arasındaki öklid mesafelerinin azalmasına neden olduğundan başarımı düşürdüğü sonucuna varılmıştır.

4. Kaynaklar

[1] C. E. Shannon, "Communication in the Presence of Noise", Proceedings of the IRE, vol. 37, no. 1, pp. 10 - 21, 1949.
[2] Z. Ghassemlooy, L. N. Alvez, S. Zvanovec, M.A. Khalighi, Visible Light Communications: Theory and Applications, CRC Press, 2017.
[3] T. Komine, M. Nakagawa, "Fundamental analysis for visible-light communication system using LED lights",

IEEE Transactions on Consumer Electronics, vol. 50, no. 1, pp. 100 - 107, 2004.
[4] A. Yeşilkaya, F. Miramirkhani, H. F. Alsan, E. Başar, "Görünür Işık Kanallarının Modellenmesi ve Optik OFDM için Başarım Analizi", EMO Bilimsel Dergi, vol. 5, no. 9, pp.18-29, 2015.
[5] P. H. Pathak, X. Feng, P. Hu, P. Mohapatra, "Visible light communication and sensing: survey, potential and challenges" IEEE Communication Survey & Tutorials, vol. 17, no. 4, pp. 2047 - 2076, 2015.
[6] H. Elgala, R. Mesleh, H. Haas, "Indoor optical wireless communication: Potential and state-of-the-art", IEEE Communications Magazine, vol. 49, no. 9, pp. 56 - 63, 2011.
[7] D. Han, K. Lee, K. Lee, "Transmitting scalable video coding using VLC with color and dimming control to assure QoS", Information Systems, vol. 48, pp. 267 - 273, 2015.
[8] C. W. Chow, C. H. Yeh, Y. F. Liu, Y. Liu, "Improved modulation speed of LED visible light communication system integrated to main electricity network", Electronics Letters, vol. 47, no. 15, pp. 867 - 868, 2011.
[9] G. Cossu, A. M. Khalid, P. Choudhury, R. Corsini, E. Ciaramella, "3.4 Gbit/s visible optical wireless transmission based on RGB LED", Optics Express, vol. 20, no. 26, pp. B501 - B506, 2012.
[10] L. Jia, J. Y. Wang, W. Zhang, M. Chen, J. B. Wang, "Symbol error rate analysis for colour-shift keying modulation in visible light communication system with RGB light-emitting diodes", IET Optoelectronics, vol. 9, no. 5, pp. 199 - 206, 2015.
[11] "IEEE Standard for Local and Metropolitan Area Networks-Part 15.7: Short-Range Wireless Optical Communication Using Visible Light", IEEE Std 802.15.7-2011, 1-309, 2011.
[12] İ. Yılmaz, M. Güllü, T. Baybura, A. O. Erdoğan, "Renk Uzayları ve Renk Dönüşüm Programı (RDP)", Afyon Kocatepe Üniversitesi Mühendislik Dergisi, vol. 2, no. 2, pp. 19-35, 2002.
[13] Y. Wang, X. Huang, L. Tao, J. Shi, N. Chi, "4.5-Gb/s RGB-LED based WDM visible light communication system employing CAP modulation and RLS based adaptive equalization", Optics Express, vol. 23, no. 10, pp.13626 - 13633, 2015.
[14] R. Singh, T. O'Farrell, J. P. R. David, "An Enhanced Color Shift Keying Modulation Scheme for High-Speed Wireless Visible Light Communications", Journal of Lightwave Technology, vol. 32, no. 14, pp.2582 - 2592, 2014.
[15] R. Singh, T. O'Farrell, J. P. R. David, "Analysis of forward error correction schemes for colour shift keying modulation", 2015 IEEE 26th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC), pp. 575-579, 2015.
[16] E. Tuğcu, C. Albayrak, A. Yazgan, K. Turk, "Renk Kaydırmalı Anahtarlama Modülasyonu için Bit Hata Oranı Analizi", 2018 26th Signal Processing and Communications Applications Conference (SIU), pp. 1-4, 2018.

- [17] R. Singh, T. O'Farrell and J. P. R. David, "Performance evaluation of IEEE 802.15.7 CSK physical layer", IEEE Globecom Workshops (GC Wkshps), pp. 1064 - 1069, 2013.
- [18] CIE, "Commission Internationale de l'Eclairage Proc." 1931.
- [19] D. B. Judd, G. T. Yonemura, "CIE 1960 UCS Diagram and the Müller Theory of Color Vision", Journal of Research of the National Bureau of Standards: Physics and Chemistry, vol. 74A, no. 1, pp. 23 - 30, 1969.
- [20] J. Schanda, M. Danyi, "Correlated Color-Temperature Calculations in the CIE 1976 Chromaticity Diagram", Color Research and Application, vol. 2, no. 4, pp. 161 - 163, 1977.
- [21] P. H. Pathak, X. Feng, P. Hu and P. Mohapatra, "Visible Light Communication, Networking, and Sensing: A Survey, Potential and Challenges," IEEE Communications Surveys & Tutorials, vol. 17, no. 4, pp. 2047 - 2077, 2015.

Özgeçmiş



Emin Tuğcu, lisans, yüksek lisans ve doktora eğitimini Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde tamamlamıştır. Aynı üniversitede Elektronik ve Haberleşme Mühendisliği Bölümü'nde öğretim üyesi olarak görev yapmaktadır. Haberleşme sistemlerinin analizleri ve işaret işleme alanlarında eğitim-öğretim ve araştırma faaliyetlerinde bulunmaya devam etmektedir.

Raylı Sistemlerde Peron Ayırıcı Kapı Sistemi İçin Yapay Sinir Ağı Tabanlı Hata Teşhis Yaklaşımı

An Artificial Neural Network Based Fault Detection Approach for Platform Screen Doors in Railway Systems

İsa KOÇ^{1,2}, Ömer MERMER¹, Necim KIRIMÇA¹, Mehmet KARAKÖSE³

¹Araştırma ve Geliştirme Bölümü

Albayrak Makine Elektronik A.Ş., Eskişehir
omermer@aldoor.com.tr, necim@aldoor.com.tr

²Elektrik Elektronik Mühendisliği Bölümü
Eskişehir Osmangazi Üniversitesi, Eskişehir
isakoc@windowslive.com

³Bilgisayar Mühendisliği Bölümü
Fırat Üniversitesi, Elazığ
mkarakose@firat.edu.tr

Özet

Günümüzde demiryolu sektöründe tren taşımacılığının önemi göz önüne alındığında endüstriyel Peron Ayırıcı Kapı Sistemi (PAKS) genellikle emniyet açısından kritik sistemler olarak tanımlanmaktadır. PAKS sisteminde meydana gelebilecek arızalar, tren ulaşımının elverişliliğini ciddi şekilde etkileyecektir. PAKS sisteminin emniyetli ve güvenilir bir şekilde çalışmasını sağlamak için bu çalışmada PAKS sistemi üzerinde veriye dayalı hata tespit ve sınıflandırma yöntemi üzerine çalışıldı. Bu yöntemde yapay sinir ağı (YSA) güçlü kabiliyetleri nedeniyle tercih edildi. PAKS sistemi üzerinde yapay olarak farklı çalışma durumları (sağlıklı ve hatalı) oluşturularak, PAKS kapısının çalışmasını sağlayan elektriksel motorun akım ve gerilim sinyalleri veri seti olarak kullanıldı. Toplamda beş farklı çalışma durumu için her biri 1000 açma/kapama döngüsü üzerinden veriler toplandı ve her bir durum için 12 adet öz nitelik değerleri hesaplanarak YSA modelleri için giriş/çıkış veri setleri elde edildi. Bu çalışmada dört farklı YSA yapısı üzerinde çalışıldı ve eğitim/test aşamaları bu yapılaraya uygulandı. Doğruluk, hassasiyet, kesinlik, belirginlik gibi performans parametreleri bu YSA modelleri için karşılaştırmalı olarak hesaplandı. Çalışma kapsamında elde edilen sonuçlara göre, toplamda üç katmanlı (giriş-gizli katman-çıkış) ve nöron sayıları sırasıyla 12-7-5 olan yapının en iyi performansı gösterdiği gözlemlendi. Sonuç olarak YSA yapısının PAKS sistemi üzerindeki oluşabilecek hataları teşhis etmede kullanışlı bir Yapay Zeka (YZ) aracı olduğu söylenebilir.

Anahtar kelimeler: Yapay sinir ağı, peron ayırıcı kapı sistemi (PAKS), hata teşhis, hata sınıflandırma, veriye dayalı yöntem

Abstract

Considering the importance of train transportation in the railway sector today, the industrial Platform Screen Door System (PSD) is generally defined as safety critical systems. Failures that may occur in the PSD system will seriously

affect the availability of train transportation. In this study, data driven fault detection and classification method was studied on the PSD system in order to ensure the safe and reliable operation of the PSD system. In this method, artificial neural network (ANN) is preferred because of its powerful capabilities. Different operating states (healthy and faulty) were created artificially on the PSD system and the electrical motor current and voltage signals were used as data set. Data set were collected over 1000 on/off cycles for each of five different operating states in total, and input/output data sets for ANN models were obtained by calculating 12 features for each state. Four different ANN structures were studied and training/testing stages were applied to them at this study. Performance parameters such as accuracy, precision, precision, and specificity were calculated comparatively for these ANN models. According to the results, it has been shown that the structure with three layers (input-hidden layer-output) and the number of neurons 12-7-5, respectively, show the best performance. Consequently, it is observed that the ANN structure is a useful AI tool in fault detection on the PSD system.

Keywords: Artificial neural network, platform screen door system (PSD), fault detection, fault classification, data-driven approach

1. Giriş

Hızlı kentleşme nedeniyle, dünya çapındaki metropoller sürekli olarak hava kirliliği ve trafik sıkışıklığı ile mücadele etmektedir. Metrolar ve trenler, kolay ve güvenilir ulaşım, trafik sıkışıklığını ve hava kirliliğini azaltmak noktasında çok önemli bir rol oynamaktadır. Yeni nesil tren ve metrolarda ise daha yüksek hızı ve otonom ulaşım sistemleri nedeniyle, Peron Ayırıcı Kapı Sistemi (PAKS) kullanmak son yirmi yılda temel bir gereklilik haline geldiği ve peron ayırıcı kapı sistemlerinin mekatronik modellemesi kapsamında matematiksel modelleme ile simülasyon çalışmaları yapıldığı

anlaşılmaktadır [1]. PAKS yapıları birçok modern metro istasyonunda [1] ve birçok RBT (Hızlı Otobüs Transit) istasyonunda [2] yolcu ile araç arasında bariyer görevi gören kayar kapı sistemi olarak tanımlanmaktadır. PAKS sistemleri üstlendikleri fonksiyonellik açısından emniyet-kritik sistemler olarak adlandırılır ve özellikle raylı sistemlerde yolcuları tren raylarına erişimden koruyarak istasyon enerji tüketiminin optimizasyonu, hava kalitesi kontrolü, intiharı önleme ve emniyet gibi birçok işleve hizmet etmektedir [3].

PAKS sistemi, yalnızca platform ve ray arasında bir bariyer oluşturmakla kalmaz, aynı zamanda araca emniyetli iniş/binişi de sağlamaktadır [1, 3]. Bu nedenle metro istasyonları için PAKS sistemi günümüzde hızla yayılmakta ve kullanılmaktadır. Bundan dolayı özellikle son on yılda, PAKS sistemi üzerine farklı araştırmalar yapılmıştır. Bu araştırmalar çoğunlukla PAKS sisteminin istasyonun çevresel koşullarına [4-6], istasyondaki hava kaçağına [7], istasyonun enerji tüketimine [8], yolcu bekleme süresine [9], yolcunun acil tahliyesine [10,11], fonksiyonel emniyet ve güvenliğe [12], ve PAKS sistemi üzerinde kontrol/izleme yaklaşımları konularında olduğu görülmektedir [13].

Mühendislik noktasından bakıldığında, emniyetle ilgili standartların gerekliliklerine uymak ve istenen emniyet seviyesine (Emniyet Bütünlük Seviyesi veya SIL olarak anılır) ulaşmak ve bunu beklenen hazır oluş (availability) seviyesinde sunmak için, yeterli düzeyde durum izleme ve teşhis araçlarının geliştirilmesi gerekmektedir [14, 15]. Durum izleme ve hata teşhisinin temel amacı arızalara sebebiyet verebilecek hataların gerektiği kadar erken tespit etmek, yerini belirlemek ve izole etmektir. Özellikle demiryolu uygulamalarında, sistemlerde oluşabilecek hataları etkin bir şekilde teşhis ederek tanımlayabilmek işletmede yaşanan arıza/aksama sürelerini en aza indirebilir ve hatta önleyebilir.

Raylı sistemlerde hata teşhisine yönelik yaklaşımlar iki kategoriye ayrılır: Bunlar veriye dayalı ve modele dayalı yöntemlerdir [16]. Genel olarak, model tabanlı teşhiste, izlenen sistemin mantıksal ve matematiksel modelleri kullanılırken, veriye dayalı teşhiste ise sağlıklı ve hatalı durumlar için mevcut verilerden öğrenilen yapay zeka modelleri kullanılır [17]. Model tabanlı yaklaşım matematiksel modellemeye dayanmaktadır ve özellikle tren kapı sistemleri üzerinde uygulama çalışmaları yapıldığı gerçekleştirilen literatür çalışmasından anlaşılmaktadır [18, 19]. Bunun yanında tren kapı sisteminde arıza teşhisine yönelik bilgiye dayalı ontolojik yaklaşım geliştirildiği ve [20] son zamanlarda, Cauffriez ve ark. [21] tren kapı sisteminin referans bir modelini oluşturmak için bond grafiği metodolojisini üzerine çalıştıkları görülmektedir. Ek olarak, Yu'nun [22] çalışmasında, genel proses izlemede temel bileşen analizi yapılarak arıza teşhis yöntemi sunulmuştur. Model tabanlı arıza teşhisindeki en önemli kısıtlama, üzerinde çalışılan sistem hakkında iyi bir uzmanlığa ihtiyaç duyulmasıdır. Diğer bir zorluk ise içerisinde birçok mekaniksel ve elektriksel bileşen barındıran sistemleri (tren kapısı, peron ayırıcı kapı, asansör kapısı, vb.) doğru ve kesin matematiksel bir modelle tanımlanmasının oldukça zor olmasıdır.

Diğer taraftan veriye dayalı yöntemler kullanarak gerek tren kapı sistemi üzerinde gerekse farklı sistemler üzerinde literatürde yapılan çalışmalar, model tabanlı arıza teşhis

yaklaşımlarının aksine uygulama daha fazla ön plana çıkmaktadır. Bu çalışmalarda Endüstri 4.0'ın yakın zamanda ortaya çıkışı ve yeni dijital teknolojilerin kullanıma geçmesiyle Yapay Zeka tabanlı sistemlerin kullanımını yaygınlaştı [23]. İlk zamanlarda AI sistemlerinin endüstride veriye dayalı hata teşhisinde kullanılmasındaki temel kısıtlama endüstriyel boyutta veri elde edilememesi olarak belirtilmektedir. Zaman içinde bu verinin kalitesinin artması (gürültüsüz, eksiksiz, uygun değer aralıkları, uygun örnekleme, zaman/frekans alan dönüşümleri) ve hatalı durumları ifade edebilecek verilerin de elde edilmesiyle AI modellerinin veri tabanlı hata teşhisinde kullanımını önemli ölçüde arttı [23]. Sun ve ark. [24], tren kapı sistemindeki hava kaçaklarını algılayabilecek makine öğrenmesi modelleri kullanan bir hata tespiti sistemi yazarlar tarafından önerildi. Başka bir çalışmada, tren kapı sistemindeki araba grubu ve rulman hataları Bayesian ağ olasılıksal makine öğrenmesi sınıflandırma modelleri kullanılarak motor akım verileri üzerinden hata teşhis çalışmaları yapıldığı görülmektedir [25]. Ayrıca diğer bir çalışmada farklı bir tren kapı sistemindeki hataların teşhis edilmesi benzer bir modelle yapıldığı anlaşılmaktadır [26].

Ek olarak, farklı makine öğrenmesi [27-30] ve derin öğrenme [31, 32] algoritmalarının tren kapı sistemlerinde ortaya çıkabilecek çeşitli hataların tespiti noktasında uygulama çalışmaları son zamanlarda artarak devam etmektedir.


Bu çalışmalar arasında son yıllarda, özellikle Yapay Sinir Ağları (YSA) algoritmalarının gerçek sistemlerde oluşabilecek hataların teşhis edilmesinde oldukça etkili olduğu görülmektedir. Farklı YSA yapıları kullanılarak asansör kapısı [33], elektrik motoru [34,35] ve tren kapı sistemleri [31, 32, 36] gibi gerçek uygulamalar üzerinde değişik hataların yüksek doğruluk oranıyla tespit edilmesi çalışmalarını literatürde mevcuttur. Yapılan literatür araştırması sonucunda, PAKS sistemine yönelik herhangi bir hata teşhis yaklaşımının olmadığı görülmektedir. PAKS yapılarının son yıllarda hem metro hem de metrobüs istasyonlarında kullanım oranının hızla artması düşünüldüğünde, bu sistemlerde meydana gelebilecek olası arızaların önceden tespit edilmesi büyük önem taşımaktadır.

Bu çalışmada metro istasyonlarında kullanılan tam boy PAKS sistemlerinde oluşabilecek mekaniksel arızaların YSA modeli kullanılarak teşhis edilmesi gerçekleştirildi. Bunun için motor akım ve gerilim verileri ve farklı istatistiksel yöntemler ile öz nitelikler çıkarılarak PAKS sisteminin sağlıklı ve hatalı durumları teşhis edilerek sınıflandırma işlemi yapıldı.


2. PAKS Sisteminin Yapısı

2.1. PAKS Sisteminin Mekaniksel ve Elektriksel Üniteleri

Peron Ayırıcı Kapı Sisteminde yer alan sistem bileşenleri (otomatik kayar kapı, acil çıkış kapısı, peron sonu kapısı, sabit panel) ve bir uygulama örneği Şekil 1'de gösterilmektedir. PAKS otomatik kayar kapı sistemi, tren kapı sistemi ile benzer mekanik ve elektriksel ünitelere sahiptir [1, 21, 37]. Tahrik ünitesi, taşıma ünitesi, hareket mekanizması, kontrol ünitesi ve kapı kanadı PAKS kayar kapı sistemini oluşturan alt sistemlerdir. Albayrak firması tarafından üretilen ALPSD-1000 serisine ait tam boy bir PAKS kayar kapı sisteminin görseli Şekil 2'de yer almaktadır.




Şekil 1. PAKS sistem bileşenleri ve uygulama örneği



Şekil 2. PAKS kayar kapı sistemi görseli

PAKS kayar kapı sistemini oluşturan her bir birim, ilgili görevleri yerine getirmek için özel alt bileşenlere sahiptir. Bu bağlamda PAKS kayar kapı sisteminin detay mimari yapısı Şekil 3'de verilmektedir. Burada motor kapı kontrol ünitesi (Door Control Unit-DCU) tarafından kapının istenilen çalışma senaryolarına uygun bir şekilde sürme görevini üstlenmektedir. Motor çıkışı, motor kasnağına bağlı kayış-kasnak ünitesini hareket ettirerek kapının taşıma rayı boyunca hareket etmesini sağlamaktadır. Bu arada kapı kanatları askı aparatları ile taşıyıcı araba grubuna birleştirilerek tek bir parça olarak hareket ederler. Albayrak firması tarafından ALPSD-1000 serisinden üretilen PAKS kayar kapı düzeneği çalışma kapsamında kullanılmıştır.



Şekil 3. PAKS kayar kapı sisteminin mimari yapısı

2.2. PAKS Sistemi Arıza Tanımları ve Veri Toplama

Bu çalışmada PAKS kayar kapı sistemi mekanik kısmında dört hata durumu oluşturularak toplamda beş farklı senaryo (sağlıklı çalışma durumu da dahil edilerek) üzerinden YSA tabanlı hata teşhis yöntemi uygulandı. Tablo 1'de verilen bu durumlar, YSA modelinde bu durumlara karşılık gelen etiketler ve çalışmada kullanılan data sayıları gösterilmektedir. Bu hata durumları YSA tabanlı hata teşhis yaklaşımının PAKS kayar kapı sistemi üzerinde uygulanabilirliğini göstermek için yapay olarak kolay oluşturulabilecek arızalardan seçildi ve arızaların uygulamada ortaya çıkma olasılıkları dikkate alınmadı. Ek olarak Tablo 1'te tanımlanan her bir hata durumu PAKS sistemine ayrı ayrı (tekil olarak) uygulandı. Her bir durum için kayar kapı sistemi 1000 açma/kapama olacak şekilde tekrarlı bir şekilde çalıştırılarak arıza koşulları verileri alındı.

Tablo 1: PAKS kayar kapı sisteminin çalışma durumları (sağlıklı ve hatalı)

| ID | Arıza Koşulları | Açma/kapama | Etiket |
|-----|-----------------------|-------------|--------|
| H/S | Sağlıklı | 1000 | 0 |
| K-1 | Kayış Gergin | 1000 | 1 |
| K-2 | Kayış Gevşek | 1000 | 2 |
| K-3 | Kayış Dişleri Aşınma | 1000 | 3 |
| K-4 | Kasnak Dişleri Aşınma | 1000 | 4 |

Literatürde veriye dayalı yöntemlerde özellikle motor akımı sinyali yaygın bir şekilde kullanıldığı görülmektedir. Elektrik motoru [34], asansör kapı [33] ve tren kapı sistemleri [31, 32] gibi gerçek sistemlerde zaman serisi olarak motor akım sinyali belirli bir örnekleme frekansı ile okunduğu anlaşılmaktadır. Bu çalışmada tipik elektriksel imza sinyali olan motor akımı ve gerilim sinyalleri 20Hz örnekleme frekansı ile MODBUS TCP haberleşme protokolü kullanılarak 3 saat boyunca DCU üzerinden alındı. Bu sinyallere ait gerçek zamanlı veri örnek kayıtları Tablo 2'de verilmektedir.

Tablo 2: PAKS kayar kapı sisteminde alınan gerçek zamanlı veri örnek kayıtları

| Tarih /Zaman | Akım (mA) | Gerilim (V) |
|------------------|-----------|-------------|
| 28.09.2021 12:56 | 0 | 0 |
| 28.09.2021 12:56 | 3190 | 30 |
| 28.09.2021 12:56 | 3340 | 29 |
| 28.09.2021 12:56 | 2180 | 29 |
| 28.09.2021 12:56 | 2140 | 30 |
| 28.09.2021 12:56 | 2140 | 31 |

2.3. Öznitelik Çıkarma

Zaman serisi olarak elde edilen bu sinyallerin özelliklerini daha iyi anlamak ve PAKS kayar kapı sisteminin sağlıklı ve hatalı durumlarında nasıl değişiklik gösterdiklerini daha iyi

ortaya koyabilmek için, Tablo 3’de gösterilen temel istatistiksel yöntemler motor akımı ve gerilimi sinyallerine uygulanmıştır. Bu istatistiksel yöntemler; Ortalama (mean), standart sapma (standard deviation), çarpıklık (skewness), basıklık (kurtosis), aralık (range) ve RMS (Root Mean Square) olup toplamda altı adet öz nitelik bilgisi içermektedir. Akım ve gerilim sinyallerinin her biri için bu yöntemler/formüller kullanılarak toplamda altı adet öz nitelik oluşturulmuş olmakla birlikte Tablo 3’de bu öz niteliklerin isimleri ve formülleri verilmiştir.


Tablo 3: YSA için kullanılan öz-nitelik isimleri ve formülleri

| # | Öz-nitelik adı | Denklem |
|---|---------------------|--|
| 1 | Ortalama | $\frac{\sum x_i}{N}$ |
| 2 | Standart Sapma (SS) | $\frac{\sqrt{\sum(x_i - \bar{x})^2}}{N - 1}$ |
| 3 | Çarpıklık | $\frac{\sum(x_i - \bar{x})^3 / N}{SS^3}$ |
| 4 | Basıklık | $\frac{\sum(x_i - \bar{x})^4 / N}{SS^4}$ |
| 5 | Aralık | $\max(x) - \min(x)$ |
| 6 | RMS | $\frac{\sqrt{\sum x_i^2}}{N}$ |

Zaman serisi olarak ölçülen akım ve gerilim sinyalleri üzerinde kapının bir açma/kapama döngüsü esas alınarak pencereleme (windowing) yapılmıştır. Yukarıda verilen bu formüller, her bir çalışma durumu için, pencereleme yapılmış akım ve gerilim verileri üzerinde ayrı ayrı uygulanarak 1000 açma/kapama döngüsü için toplamda 1000 adet akıma ait ve 1000 adet gerilime ait öz-nitelikler hesaplanmıştır.

3. PAKS Kayar Kapı Sistemi için YSA Tabanlı Hata Teşhis Yaklaşımı

Şekil 4’de temel yapısı gösterilen Yapay sinir ağı (YSA), beyin hücrelerinin biyolojik yapısından esinlenen bir yapay zekaya yaklaşımıdır [38]. Temel olarak YSA giriş, gizli katman ve çıkış olmak üzere üç katmana sahiptir. Yapay sinir ağı, nöron hücrelerine benzer şekilde, işleme elemanı, giriş ve çıkışlardan oluşan bir yapıdır. Her giriş kendisi ile bağlantılı ağırlıklarla çarpılır ve eşik (bias) ile birlikte işlem elemanı olan nöron gövdesine iletilirler. İlk aşamada çarpılan girişler toplama fonksiyonu ile toplanır ve ikinci adımda transfer fonksiyonu ile çıkışa aktarılır. Eğitim işleminden önce katmanların nöron sayısı, eğitim algoritmaları, iterasyon sayısı, performans değerleri ve doğrulama kontrolleri ayarlanabildiğinden YSA’nın çok esnek ve çok yönlü bir araç olduğu ifade edilebilir. Son yirmi yılda YSA, çoğunlukla sınıflandırma, kümeleme, örüntü tanıma, görüntü işleme, kontrol, optimizasyon ve modelleme gibi farklı görevleri yerine getirmek için kullanılmaktadır [39].




Şekil 4. Çalışmada kullanılan YSA mimari yapısı

Bu çalışmada kullanılan YSA yapısında tek bir gizli katman seçildi. Giriş olarak akım ve gerilim verilerine ait toplamda 12 adet öz nitelik bulunduğu için giriş katmanındaki nöron sayısı 12 olarak kabul edildi. Aynı şekilde çıkışımızda 5 farklı durum (sağlıklı ve dört arıza durumu) olduğu için çıkış katmanında 5 nöron belirlendi. Ayrıca, gizli katmandaki nöron sayısı da 3, 5, 7 ve 9 alınarak farklı nöron sayısını YSA performansını nasıl etkilediği araştırıldı. Bahsedilen bu YSA yapıları Tablo 4’de yer almaktadır. Ek olarak YSA yapısının öğrenme oranı 0.6 ve momentum katsayısı 0.95 olarak seçildi. Her bir akım ve gerilim verilerine ait 5000 adet öz nitelik değeri (örnek) 80:20 oranında eğitimde (4000 örnek) ve test verisi (1000 örnek) olarak bölünerek ve YSA yapılarının eğitime ve test işlemlerinde kullanıldı. Burada kullanılan veri setleri karıştırılarak ve rastgele bir şekilde eğitime/test veri ayrımı yapıldı.

Tablo 4: Katman Sayısı ve Nöron Dahil YSA Yapısı

| YSA Modeli | Nöron sayısı | | | Momentum katsayısı | Öğrenme katsayısı |
|------------|--------------|--------------|-------|--------------------|-------------------|
| | Giriş | Gizli katman | Çıkış | | |
| YSA-1 | 12 | 3 | 5 | 0.95 | 0.6 |
| YSA-2 | 12 | 5 | 5 | 0.95 | 0.6 |
| YSA-3 | 12 | 7 | 5 | 0.95 | 0.6 |
| YSA-4 | 12 | 9 | 5 | 0.95 | 0.6 |

YSA yapılarında artımlı ve toplu eğitim olmak üzere iki farklı yaklaşım mevcuttur [40]. Artımlı eğitim aynı zamanda örnek-örnek modeli olarak da bilinir ve daha çok dinamik yapay sinir ağlarında uygulanmaktadır. Statik ağlarda da uygulanabilen bu yaklaşımda ağırlıklar her iterasyonda güncellenir. Bu yaklaşımda örnekler tek tek alındığı için küçük depolama içermesine rağmen ilk kötü örnek eğitimi yanlış yöne zorlayabilir. Diğer bir yaklaşım olan toplu eğitimde, tüm girişler yapay sinir ağına girdikten sonra ağırlıklar güncellenir. Bu yaklaşım MATLAB ortamı için de daha verimli bir çalışma yöntemidir [41]. Bu çalışmada toplu eğitim yaklaşımı kullanıldı. Eğitim için oluşturulan giriş-çıkış veri setleri kullanılarak YSA modellerinin eğitim işlemi gerçekleştirildi. Bu bölümde iterasyon sayısı 200 ve eğitim hatası 0.001 olarak kabul edildi. Optimize edilen YSA modeli daha sonrasında test verisi ile doğrulanarak ve modele ait performans metrikleri hesaplandı. Bu işlem basamaklarının detaylı olarak görselleştirildiği akış diyagramı Şekil 5’de verilmektedir.



Şekil 5. Uygulama akış diyagramı

4. Deneysel Sonuçlar

4.1. Performans Kriterleri

Bu çalışmada öncelikle Doğru Pozitif (DP-TP), Yanlış Pozitif (YP-FP), Doğru Negatif (DN-TN) ve Yanlış Negatif (YN-FN) olmak üzere dört indeksten oluşan karmaşıklık matrisi (confusion matrix) kullanılarak YSA yapılarının performansları analiz edildi. Şekil 6'da tipik bir karmaşıklık matrisi ve bu parametrelerinin karşılık geldiği kısımlar gösterilmektedir. Bu kapsamda TP ve TN doğru tahmin edilen veri sayısını, FP ve FN ise yanlış tahmin edilen veri sayısını temsil etmektedir.

| | | |
|----------------|------------------|------------------|
| | gerçekte pozitif | gerçekte negatif |
| tahmin pozitif | doğru pozitif | yanlış pozitif |
| tahmin negatif | yanlış negatif | doğru negatif |

Şekil 6. Karmaşıklık matrisi ve uygulama parametreleri

Karmaşıklık matrisine ek olarak, literatürde [42] başka yardımcı performans ölçütleri belirlendi ve aşağıda bunlarla alakalı bilgiler ve formüllere yer verildi. Doğruluk (accuracy) parametresi modelin kapsamlı bir performansı gösterir. Doğru yapılan tahminlerin bütün tahminlere bölümü şeklinde tanımlanır ve denklem (1) deki gibi hesaplanır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

Hassasiyet (sensitivity-recall) parametresi yalnızca pozitif örneklere ve tahminlere odaklanır. Genel olarak hassasiyet, pozitif olarak tahmin edilmesi gereken örneklerin oransal olarak kaçının doğru tahmin edildiğinin göstergesidir. Denklem 2'de verilen ifade ile hesaplanır. Burada M sınıflandırma sayısını göstermektedir.

$$\text{Hassasiyet} = \frac{\sum_i \frac{TP_i}{TP_i + FN_i}}{M} \quad (2)$$

Son olarak pozitif olarak tahmin ettiğimiz örneklerin kaçının doğru olarak tahmin edildiğini gösteren performans parametresi kesinlik (precision) olarak isimlendirilir ve Denklem 3'de hesaplama formülü yer almaktadır.

$$\text{Kesinlik} = \frac{\sum_i \frac{TP_i}{TP_i + FP_i}}{M} \quad (3)$$

Ayrıca bu performans parametrelerinden kesinlik ve hassasiyet değerlerini kullanarak tek bir değere indirgeyen F1-skor parametresi Denklem 4'deki gibi formüle edilebilir ve birden fazla model arasından en iyisi seçmek için kullanılabilir bir parametredir.

$$F1 - \text{skor} = \frac{2 \times \text{Kesinlik} \times \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}} \quad (4)$$

4.2. Deneysel sonuçlar

Bu çalışmada kullandığımız data setleri motor akım ve gerilim sinyallerinden hesaplanan toplamda 12 adet öz nitelik değerinin 1000 açma/kapama döngüsü ve 5 farklı çalışma durumları (sağlıklı/arızalı) için elde edilen verilerden oluşmaktadır. Sonuçta, giriş data seti matrisi 5000x12 boyutlarında, çıkış data seti 5000x5 boyutlarında oluşturularak eğitim ve test aşamalarında kullanıldı. Eğitim aşamasında ezber etkisini azaltmak için giriş ve çıkış veri setleri aynı şekilde karıştırılmış ve yine tamamıyla rastgele bir şekilde 80:20 oranında bölünerek eğitim ve test veri setleri oluşturuldu.

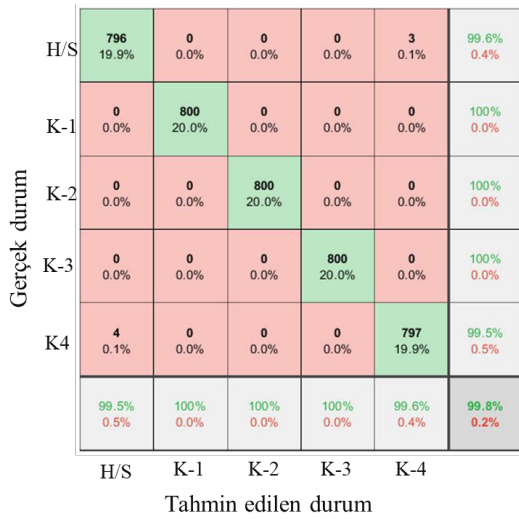
Tablo 4'de verilen dört farklı YSA yapıları öncelikle bu eğitim veri setleri ile eğitilerek sonrasında test veri setleri ve performansları hesaplandı. Tüm YSA için bu performans parametreleri Tablo 5'de özet şeklinde sunuldu. Burada YSA-1 modeli hassasiyet parametresi diğer modellerle kıyaslandığında düşük durmaktadır. Bu modelin yeterli sayıda doğru tahmin edememesinden kaynaklanmaktadır. Burada en iyi performans YSA-3 modelinin gösterdiği anlaşılmaktadır. Gizli katmandaki nöron sayısını artırmak belli dereceye kadar YSA performansını artırırken, bir noktadan sonra YSA'nın performansını düşürmektedir. Literatürde YSA üzerinde yapılan bazı çalışmalarda [43] benzer sonuçları

görmek mümkündür. Burada gizli katmandaki nöron sayılarını belli bir değerden daha fazla artırmak YSA modelini eğitirken “aşırı uyum problemine” neden olabilmektedir. Bu da test aşamasında eğitilen modelin performansında düşüş meydana getirebilmektedir.

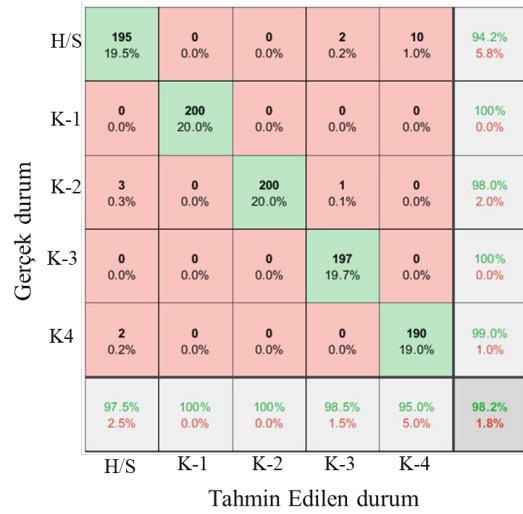
Tablo 5. YSA modellerinin performans metriklerinin karşılaştırılması

| YSA modeli | Keskinlik (Precision) (%) | Hassasiyet (Sensitivity) (%) | F1-skor (F1-score) (%) | Doğruluk (Accuracy) (%) |
|------------|---------------------------|------------------------------|------------------------|-------------------------|
| YSA-1 | 98,6 | 79,8 | 88,2 | 78,9 |
| YSA-2 | 98,3 | 99,5 | 98,8 | 97,8 |
| YSA-3 | 99,6 | 99,6 | 99,6 | 98,2 |
| YSA-4 | 98,3 | 99,5 | 98,8 | 97,8 |

Şekil 7’de ise en iyi performansı gösteren YSA modelinin (YSA-3) eğitime ve test aşamalarından sonra elde edilen karmaşıklık matrisleri gösterilmektedir. Buradan da görüleceği üzere, optimize edilen YSA modeli test aşamasında eğitime aşamasından daha yüksek bir performans göstermektedir.




(a)



(b)

Şekil 7. YSA-SL3 model için (a) eğitime ve (b) test sonucunda elde edilen karmaşıklık matrisi

Ayrıca Şekil 8’de bu optimize edilmiş YSA-3 modelinin eğitime aşamasında ortalama kare hatası (mean squared error) değerinin iterasyon sayısına göre değişimi görülmektedir. YSA-3 modelinin çok hızlı bir şekilde (ilk 20-30 iterasyon) 1×10^{-3} hata değerine ulaştığı ve bu noktadan sonra iterasyona bağlı olarak hata değerinin daha da azalmadığı anlaşılmaktadır. Bu da eğitime aşaması için iterasyon sayısının 200 yerine 20-30 olarak alınabileceğini ve böylece çok daha hızlı bir şekilde eğitimin tamamlanacağını göstermektedir.



Şekil 8. YSA-3 modelin eğitime aşamasında ortalama kareler hata oranının değişimi

Deneylerden elde edilen sonuçlar, PAKS kayar kapı sisteminde hataları da içeren çalışma durumlarının YSA modeli ile oldukça başarılı bir şekilde sınıflandırılabilirliğini göstermektedir. Burada PAKS sistemin ilgili çalışma durumunu belirlemek için problemi çoklu sınıflandırma olarak ele almak YSA modellerinin yüksek bir başarı oranı ortaya çıkarmasını sağlamıştır.

5. Sonuçlar

Veri tabanlı arıza tespiti ve sınıflandırma yaklaşımları sistemlerin sürekli olarak izlenmesi ve arızaların daha erken bir aşamada tespit/teşhis edilmesine imkan vermektedir. Bu çalışmada raylı sistemlerde önemi ve kullanımı her geçen gün artan Peron Ayırıcı Kapı Sisteminin (PAKS) ana bileşeni olan kayar kapı sistemi analiz edildi ve olası mekanik arıza türleri çoklu veriye dayalı YSA modelleri kullanılarak incelendi. YSA hakkında yapılan literatür çalışmalarında verimli bir sınıflandırıcı olduğu görülmekte olup bu çalışmada, YSA modelleri üzerinde odaklanılarak, farklı nöron sayıları üzerinden optimize işlemi gerçekleştirildi. Deneyler, dört farklı YSA modeli kullanılarak 5 farklı çalışma durumu için gerçekleştirilerek, daha spesifik bakıldığında, her bir çalışma durumu için 1000 açma/kapama döngüsü üzerinden motor akım ve gerilim elektriksel sinyalleri ölçülerek 12 adet öz-nitelik değeri hesaplandı ve YSA modellerinin eğitim/test davranışları ve performansları araştırıldı. Performans metrikleri (doğruluk, hassasiyet, kesinlik, vb.) dikkate alınarak her bir modelin diğerleriyle karşılaştırılması bu çalışmada gerçekleştirildi. Ayrıca söz konusu bu çalışmada, giriş-gizli katman-çıkış katmanlarındaki nöron sayılarının sırasıyla 12-7-5 olan yapının en iyi performansı gösterdiği görüldü.

Sonuçlarımız, elektriksel motor ve gerilim sinyallerinin istatistiksel yöntemlerle öz-nitelik değerlerini kullanarak, PAKS kayar kapı sistemindeki hataların veriye dayalı bir şekilde tespit ve sınıflandırılmasının yüksek bir başarı oranında verimli bir şekilde uygulanabileceğini göstermektedir. Bu çalışmada yalnızca akım ve gerilim verilerinin kullanılmasına rağmen, gelecekte bu çalışmayı; daha fazla sinyal kullanarak gerçekleştirme, farklı YSA algoritmalarının karşılaştırılmasını yapma ve ayrıca bu YSA modellerinin uç platforma (edge device) yerleştirme ile PAKS kayar kapı sisteminin hata tespitine yönelik sürekli izlenmesi çalışmaları ile genişletmek mümkün olabilecektir.

6. Teşekkür

Bu çalışma, ECOMAI PENTA-EURIPIDES (Hibe No. 2021028) çatı projesi kapsamında TÜBİTAK (Hibe No. 9210043) tarafından desteklenmiştir.

7. Kaynakça

- [1] İ. Koç, Ö. Mermer, N. Kırımça, F.H. Çakır ve M. Karaköse, "Modeling and Simulation of Platform Screen Door (PSD) System using Matlab-Simulink" *International Conference on Data Analytics for Business and Industry (ICDABI)*, Sakhr – Kingdom of Bahrain, Eki. 2022, ss. 629-633.
- [2] C. Zhou, Z. Su, ve J. Zhou, "Design and Implementation of the Platform Screen Doors System for BRT", içinde *ICCTP 2010*, Beijing, China, Tem. 2010, ss. 2540-2552. doi: 10.1061/41127(382)271.
- [3] U. T. Abdurrahman, A. Jack, ve F. Schmid, "Effects of platform screen doors on the overall railway system", program adı: 8th International Conference on Railway Engineering (ICRE 2018), London, UK, 2018. doi: 10.1049/cp.2018.0053.
- [4] Z. Yang, X. Su, F. Ma, L. Yu, ve H. Wang, "An innovative environmental control system of subway", *Journal of Wind Engineering and Industrial Aerodynamics*, c. 147, ss. 120-131, Ara. 2015, doi: 10.1016/j.jweia.2015.09.015.
- [5] S. He, L. Jin, T. Le, C. Zhang, X. Liu, ve X. Ming, "Commuter health risk and the protective effect of three typical metro environmental control systems in Beijing, China", *Transportation Research Part D: Transport and Environment*, c. 62, ss. 633-645, Tem. 2018, doi: 10.1016/j.trd.2018.04.015.
- [6] H. Han, J.-Y. Lee, ve K.-J. Jang, "Effect of platform screen doors on the indoor air environment of an underground subway station", *Indoor and Built Environment*, c. 24, sy 5, ss. 672-681, Ağu. 2015, doi: 10.1177/1420326X14528731.
- [7] X. Li ve Y. Wang, "Simulation study on air leakage of platform screen doors in subway stations", *Sustainable Cities and Society*, c. 43, ss. 350-356, Kas. 2018, doi: 10.1016/j.scs.2018.08.035.
- [8] Z. Su ve X. Li, "Energy benchmarking analysis of subway station with platform screen door system in China", *Tunnelling and Underground Space Technology*, c. 128, s. 104655, Eki. 2022, doi: 10.1016/j.tust.2022.104655.
- [9] O. Lindfeldt, "The impact of platform screen doors on rail capacity", *Int. J. TDI*, c. 1, sy 3, ss. 601-610, Oca. 2017, doi: 10.2495/TDI-V1-N3-601-610
- [10] L. Qu ve W. K. Chow, "Platform siren doors on emergency evacuation in underground railway stations", *Tunnelling and Underground Space Technology*, c. 30, ss. 1-9, Tem. 2012, doi: 10.1016/j.tust.2011.09.003.
- [11] J. S. Roh, H. S. Ryou, ve S. W. Yoon, "The effect of PSD on life safety in subway station fire", *J Mech Sci Technol*, c. 24, sy 4, ss. 937-942, Nis. 2010, doi: 10.1007/s12206-010-0217-7.
- [12] L. Min, C. Zhaoyong, ve Z. Jin, "Study on PSD system control strategy for safety", içinde *2012 3rd International Conference on System Science, Engineering Design and Manufacturing Informatization*, Chengdu, China, Eki. 2012, ss. 154-159. doi: 10.1109/ICSSEM.2012.6340789.
- [13] M. Çeçen, N. Kırımça, Ö. Mermer ve M. Karaköse, "Control and Monitoring Approaches of Platform Screen Door Systems in Railway Systems", *Otomatik Kontrol Ulusal Toplantısı, Elazığ, Türkiye*, Eyl. 2022, ss. 592-597.
- [14] Functional Safety of Electrical/Electronic/Programmable Electronic Safety Related Systems, IEC 61508-3, European

- Committee for Electrotechnical Standardization, Brussels, Belgium, 2000.
- [15] M. S. Durmuş, S. Takai, ve M. T. Söylemez, "Fault diagnosis in fixed-block railway signaling systems: a discrete event systems approach: FAULT DIAGNOSIS IN FIXED-BLOCK RAILWAY SIGNALING SYSTEMS", *IEEJ Trans Elec Electron Eng*, c. 9, sy 5, ss. 523-531, Eyl. 2014, doi: 10.1002/tee.22001.
- [16] C. Li, S. Luo, C. Cole, ve M. Spiriyagin, "An overview: modern techniques for railway vehicle on-board health monitoring systems", *Vehicle System Dynamics*, c. 55, sy 7, ss. 1045-1070, Tem. 2017, doi: 10.1080/00423114.2017.1296963.
- [17] K. Tidriri, N. Chatti, S. Verron, ve T. Tiplica, "Bridging data-driven and model-based approaches for process fault diagnosis and health monitoring: A review of researches and future challenges", *Annual Reviews in Control*, c. 42, ss. 63-81, 2016, doi: 10.1016/j.arcontrol.2016.09.008.
- [18] H. Dassanayake, C. Roberts, C. J. Goodman, ve A. M. Tobias, "Use of parameter estimation for the detection and diagnosis of faults on electric train door systems", *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, c. 223, sy 4, ss. 271-278, Ara. 2009, doi: 10.1243/1748006XJRR265.
- [19] L. Shuai, J. Limin, Q. Yong, Y. Bo, ve W. Yanhui, "Research on Urban Rail Train Passenger Door System Fault Diagnosis Using PCA and Rough Set", *TOMEJ*, c. 8, sy 1, ss. 340-348, Eyl. 2014, doi: 10.2174/1874155X01408010340.
- [20] E. Miguelanez, K. E. Brown, R. Lewis, C. Roberts, ve D. M. Lane, "Fault diagnosis of a train door system based on semantic knowledge representation", içinde *4th IET International Conference on Railway Condition Monitoring (RCM 2008)*, Derby, UK, 2008, ss. 27-27. doi: 10.1049/ic:20080333.
- [21] L. Cauffriez, S. Grondel, P. Loslever, ve C. Aubrun, "Bond Graph modeling for fault detection and isolation of a train door mechatronic system", *Control Engineering Practice*, c. 49, ss. 212-224, Nis. 2016, doi: 10.1016/j.conengprac.2015.12.019.
- [22] J. Yu, "Local and global principal component analysis for process monitoring", *Journal of Process Control*, c. 22, sy 7, ss. 1358-1373, Ağu. 2012, doi: 10.1016/j.jprocont.2012.06.008.
- [23] D. Gonzalez-Jimenez, J. del-Olmo, J. Poza, F. Garramiola, ve P. Madina, "Data-Driven Fault Diagnosis for Electric Drives: A Review", *Sensors*, c. 21, sy 12, s. 4024, Haz. 2021, doi: 10.3390/s21124024.
- [24] X. Sun, K. V. Ling, K. K. Sin, ve L. Tay, "Intelligent Fault Detection and Diagnosis of Air Leakage on Train Door", içinde *2018 International Conference on Intelligent Rail Transportation (ICIRT)*, Singapore, Ara. 2018, ss. 1-4. doi: 10.1109/ICIRT.2018.8641662.
- [25] S. Kim, N. H. Kim, ve J.-H. Choi, "Information Value-Based Fault Diagnosis of Train Door System under Multiple Operating Conditions", *Sensors*, c. 20, sy 14, s. 3952, Tem. 2020, doi: 10.3390/s20143952.
- [26] R. Chen, S. Zhu, F. Hao, B. Zhu, Z. Zhao, ve Y. Xu, "Railway Vehicle Door Fault Diagnosis Method with Bayesian Network", içinde *2019 4th International Conference on Control and Robotics Engineering (ICCRE)*, Nanjing, China, Nis. 2019, ss. 70-74. doi: 10.1109/ICCRE.2019.8724211.
- [27] Y. Sun, Y. Cao, ve L. Ma, "A Fault Diagnosis Method for Train Plug Doors via Sound Signals", *IEEE Intell. Transport. Syst. Mag.*, c. 13, sy 3, ss. 107-117, 2021, doi: 10.1109/MITS.2019.2926366.
- [28] H. Chen, B. Jiang, S. X. Ding, ve B. Huang, "Data-Driven Fault Diagnosis for Traction Systems in High-Speed Trains: A Survey, Challenges, and Perspectives", *IEEE Trans. Intell. Transport. Syst.*, c. 23, sy 3, ss. 1700-1716, Mar. 2022, doi: 10.1109/TITS.2020.3029946.
- [29] G. W. Han vd., "Incipient anomaly detection for railway vehicle door system based on adaptive mean shift clustering", içinde *2017 Chinese Automation Congress (CAC)*, Jinan, Eki. 2017, ss. 1297-1302. doi: 10.1109/CAC.2017.8242967.
- [30] X. Heng, Q. Jiang, D. Liu, L. Xie, T. Zhan, ve N. Jin, "Fault Diagnosis of Subway Plug Door Based on KPCA and CS-LSSVM", içinde *2020 15th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, Kristiansand, Norway, Kas. 2020, ss. 100-105. doi: 10.1109/ICIEA48937.2020.9248245.
- [31] S. Ham, S.-Y. Han, S. Kim, H. J. Park, K.-J. Park, ve J.-H. Choi, "A Comparative Study of Fault Diagnosis for Train Door System: Traditional versus Deep Learning Approaches", *Sensors*, c. 19, sy 23, s. 5160, Kas. 2019, doi: 10.3390/s19235160.
- [32] N. Lehrasab, H. P. B. Dassanayake, C. Roberts, S. Fararooy, ve C. J. Goodman, "Industrial fault diagnosis: Pneumatic train door case study", *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, c. 216, sy 3, ss. 175-183, May. 2002, doi: 10.1243/095440902760213602.
- [33] P. Wen, M. Zhi, G. Zhang, ve S. Li, "Fault Prediction of Elevator Door System Based on PSO-BP Neural Network", *ENG*, c. 08, sy 11, ss. 761-766, 2016, doi: 10.4236/eng.2016.811068.
- [34] T. Ince, S. Kiranyaz, L. Eren, M. Askar, ve M. Gabbouj, "Real-Time Motor Fault Detection by 1-D

- Convolutional Neural Networks”, *IEEE Trans. Ind. Electron.*, c. 63, sy 11, ss. 7067-7075, Kas. 2016, doi: 10.1109/TIE.2016.2582729.
- [35] Chow, M.-Y., “Methodologies of using neural network and fuzzy logic technologies for motor incipient fault detection”, Singapore: World Scientific, 1997.
- [36] B. Bagheri, H. Ahmadi, ve R. Labbafi, “Application of data mining and feature extraction on intelligent fault diagnosis by Artificial Neural Network and k-nearest neighbor”, içinde *The XIX International Conference on Electrical Machines - ICEM 2010*, Rome, Italy, Eyl. 2010, ss. 1-7. doi: 10.1109/ICELMACH.2010.5607984.
- [37] A. Boussif ve M. Ghazel, “Model-Based Monitoring of a Train Passenger Access System”, *IEEE Access*, c. 6, ss. 41619-41632, 2018, doi: 10.1109/ACCESS.2018.2860966.
- [38] B. Yegnanarayana, “Artificial neural networks”, PHI Learning Pvt. Ltd., 2009
- [39] I. N. da Silva, R. Andrade Flauzino, S. F. dos Reis Alves, D. Hernane Spatti, ve L. H. B. Liboni, *Artificial Neural Networks: A Practical Course*, 1st ed. 2017. Cham: Springer International Publishing : Imprint: Springer, 2017. doi: 10.1007/978-3-319-43162-8.
- [40] I. A. Basheer, and M. Hajmeer, “Artificial neural networks: fundamentals, computing, design, and application,” *Journal of Microbiological Methods* vol. 43(1), ss.3–31, 2000.
- [41]]H. Demuth, M. Beale, and M. Hagan, “Neural Network Toolbox TM 6 User’s Guide”. Network, the MathWorks, Inc.P, 2010.
- [42] Z. Comert, A.F. Kocamaz, “A study of artificial neural network training algorithms for classification of cardiocography signals,” *Bitlis Eren University Journal Of Science And Technology* vol. 7(2), ss 93–103, 2017.
- [43] Y. Liu, J. Starzyk, Z. Zhu, “Optimizing number of hidden neurons in neural networks.. *IASTED International Conference on Artificial Intelligence and Applications* ss.138-143, Austria, 2007.

Özgeçmişler



İsa Koç, 1989'da Beypazarı'nda doğdu. Lisans derecesini Atatürk Üniversitesi Elektrik- Elektronik Mühendisliği ve yüksek lisans derecesini Eskişehir Osmangazi Üniversitesi Elektrik-Elektronik Mühendisliği alanında sırasıyla 2013 ve 2017 yıllarında almıştır. Halen aynı üniversitede doktora çalışmalarına devam etmektedir. Aynı zamanda Albayrak Makine Elektronik A.Ş. firmasında Ar-Ge mühendisi olarak görev yapmaktadır. Güncel araştırma alanları arasında veri analizi, AI tabanlı hata sınıflandırma, Matlab/Simulink tabanlı sistem modelleme, akustik ve elektromanayetik dalgalar yer almaktadır.



Ömer Mermer, lisans ve yüksek lisans derecesini Ege Üniversitesi Elektrik ve Elektronik Mühendisliği alanında sırasıyla 1998 ve 2001 yıllarında almıştır. 2006 yılında Iowa Üniversitesi'nden (ABD) Fizik Doktora derecesini almıştır. 2016 yılında Üniversiteler Arası Kurul tarafından Doçent unvanını almıştır. Halen Albayrak Makine Elektronik A.Ş. firmasında Ar-Ge bölümünde RAMS Yöneticisi olarak görev yapmaktadır. Güncel araştırma alanları arasında AI tabanlı hata sınıflandırma, kestirimci bakım, fonksiyonel emniyet, sistem modelleme ve optoelektronik aygıt ve sensor uygulamaları yer almaktadır.



Necim Kırımça, lisans derecesini İstanbul Teknik Üniversitesi Elektrik Mühendisliği alanında 1988 yılında almıştır. Halen Albayrak Makine Elektronik A.Ş. firmasında Kalite ve Ar-Ge Yöneticisi görev yapmaktadır. Güncel araştırma alanları arasında kalite yönetimi, fonksiyonel emniyet, hata sınıflandırma yer almaktadır.



Prof. Dr. Mehmet Karaköse, 1976 yılında Elazığ'da doğdu. Lisans derecesini 1998 yılında Fırat Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nden aldı. 2001 yılında Bilgisayar Mühendisliği'nde Yüksek lisansını ve 2005 yılında Elektrik-Elektronik Mühendisliğinde Doktora eğitimini tamamladı. 1999-2005 yılları arasında Bilgisayar Mühendisliği Yazılım Anabilim Dalı'nda araştırma görevlisi, 2005-2014 yılları arasında Yrd.Doç.Dr., 2014-2020 yılları arasında Doç.Dr. olarak çalışmış olup 2020 yılından beri Prof. Dr. olarak aynı bölümde görev almaktadır. Araştırma alanları akıllı sistemler, bulanık sistemler, simülasyon ve modelleme, hesapsal zeka, arıza teşhisi, optimizasyon algoritmaları, görüntü işleme, makine görmesi, beyin-bilgisayar etkileşimi, raylı sistemler ve kuantum hesaplama modelleridir. IEEE kıdemli üyesidir. Çeşitli dergiler ve konferans bildirilerinde yayınlanan birçok makale yazmıştır ve birçok TÜBİTAK projesi tamamlamıştır. Bilgisayar Mühendisliği Bölümü'nde Otomata Teorisi, Algoritma Analizi, Derleyici Tasarımı, Sistem Teorisi, Yapay Zeka, Hesapsal Zeka, Kuramsal Hesaplama ve İnsan-Bilgisayar Etkileşimi derslerini vermektedir.

Yüksek DA Gerilim Uygulamaları için Empedans Kaynaklı Yükseltici Çevirici Tasarımı

Design of Impedance Source Step-up Converter for High DC Voltage Applications

DAĞ Bülent^a, ÖZDEMİR Mehmet Akif^a, TAMYÜREK Bünyamin^a, AYDIN Emrullah^b, AYDEMİR M. Timur^c

^aGazi Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü, Ankara

e-mail: mehmetakif@gazi.edu.tr, bulentdag@gazi.edu.tr, btamyurek@gazi.edu.tr

^bTurgut Özal Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü, Malatya

e-mail: emrullah.aydin@ozal.edu.tr

^cKadir Has Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü, İstanbul

e-mail: timur.aydemir@khas.edu.tr

Özet

Bu çalışmada yüksek DA gerilimli bir güç kaynağında kullanılmak üzere yüksek kazançlı yeni nesil bir empedans kaynaklı yükseltici çeviricinin güç katı tasarımı yapılmıştır. Ele alınan empedans kaynaklı çevirici yeni geliştirilmiş bir topoloji olup, çeviricinin temel çalışma prensibi daha önceki bir çalışmada detaylı şekilde incelenmiştir. Bu çalışmada çeviricinin hedeflenen uygulamaya yönelik tasarımı için gereken gerilim-denge ve akım-denge eşitlikleri çıkarılmıştır ve bu eşitlikler kullanılarak uygun devre elemanları değerleri belirlenmiştir. Tasarlanan çeviricinin kararlı durum performansı Matlab-Simulink benzetim modeli ile doğrulanmıştır.

Anahtar Kelimeler: Empedans kaynaklı çevirici, Yüksek DA gerilimi, Güç katı tasarımı.

Abstract


In this study, design of power stage of a new generation impedance source step-up converter, to be used in a high DC voltage power supply, is performed. The used impedance source converter is a newly developed topology and its basic operation principles have been investigated in detail in a recent study. In this study, the required volt-balance and current-balance equations of the converter are obtained for the design of the converter in accordance with the targeted application and the corresponding circuit component values are determined. Steady-state performance of the designed converter is validated with Matlab-Simulink simulation model.

Keywords: Impedance source converter, High DC voltage, Power stage design

1. Giriş

Yüksek DA Gerilim (YDAG) güç kaynakları tıp endüstrileri, askeri radar teknolojisi, telekomünikasyon ve havacılık gibi farklı sektörlerde yaygın olarak kullanılmaktadır. Bu tür YDAG

güç kaynaklarının tipik uygulamaları, X-ışını sistemleri, yürüyen dalga tüpleri (TWT), yalıtım testi cihazları, magnetron ve gyrotron gibi yüksek güçlü vakum cihazları, darbeli güç uygulaması vb. olarak sıralanabilir. Yariletken teknolojisinin gelişkin olmadığı dönemlerde yüksek gerilim seviyelerine ulaşmak için şebeke gerilimini diyotlarla doğrultup kondansatörlerle katlayan, yarım dalga veya tam dalga gerilim katlayıcı devreler kullanılmıştır. Greinacher gerilim çiftleyici, geliştirilmiş Greinacher gerilim çiftleyici, iki katlı Greinacher gerilim çiftleyici (dörtleyici), Cockroft-Walton (CW) gerilim çiftleyici ve CW gerilim katlayıcı devreler bunlara örnek olarak gösterilebilir [1-3]. Ancak, şebeke gerilimini doğrultup ardından kondansatör tabanlı gerilim katlayıcılarla hedeflenen yüksek gerilimi elde etmek şebeke frekansında bir transformatör kullanımı gerektirmektedir. Bu, ağırlık ve hacim demek olduğundan, özellikle havacılık uygulamaları için bu yapı yerine yüksek frekanslı Darbe Genişlik Modülasyonlu (DGM) dönüştürücü sistemler kullanılmaya başlanmıştır. Geleneksel düşük frekanslı yüksek gerilim üreteçlerinin yerini alan anahtarlama modda çalışan yüksek gerilim, yüksek frekanslı (YGYF) güç dönüştürücüler sayesinde yüksek güç yoğunluğu ve yüksek verim yanında daha iyi kalıcı durum davranışı ve dinamik davranış elde edilebilmektedir [2-4]. Ancak, bu yapı basit olmakla beraber bazı temel sorunlar içermektedir. Öncelikle, yüksek çıkış geriliminden dolayı birincil-ikincil arası ve ikincil sargı katmanları arasındaki yalıtım mesafesi yüksek (<5 kV/mm) olmalıdır. Bu durum ise kaçak kapasitansın ve kaçak endüktansın büyük olmasına yol açmaktadır (>0.4 uF ve >0.01 mH) [5,6]. Ayrıca, istenilen gerilim düzeylerine çıkabilmek için transformatörlerin sarım oranlarının yüksek olması gerekir (>100) ve yüksek sarım oranları da kaçak kapasitansı artıran diğer bir etkidir. Bu yapıda görülen yüksek kaçak endüktans değerleri, ikincil taraftan birincil tarafa (sarım oranının karesiyle çarpılarak) yansıyan transformatör kapasitansı ve yine ikincilden birincile yansıyan yariletken eklem kapasitansları devrenin çalışmasında ciddi sorunlar doğurmaktadır. Kaçak endüktanslar nedeniyle gerilim



Şekil 1 Önerilen yüksek DA gerilim güç kaynağı yapısı

sıçramaları, kaçak kapasitanslar nedeniyle de akım sıçramaları ve yavaş tepki ortaya çıkmakta, akımın şekli bozulmakta ve toplam verim düşmektedir [7,8].

Yüksek DA gerilim güç kaynaklarında kullanılan transformatörlerin ikincilden birincile yansıyan kaçak eleman değerlerini küçültmenin en etkili yolunun transformatörün sarım oranının mümkün olduğunca küçük tutulması olduğu anlaşılmaktadır. Sarım sayısını düşürmenin yollarından birisi modüler yapılar kullanmaktır [4, 9, 10]. Bu yöntemdeki amaç, bir modüldeki transformatörün sarım oranını düşük tutmak için modül bazında çıkış gerilimini düşük tutup istenilen gerilimi sağlamak için modül çıkışlarının seri bağlanarak toplam gerilimin yükseltilmesidir. Ancak bu yöntem, birden fazla modül kullanımından dolayı, sistemin boyutlarını, ağırlığını ve maliyetini artırmaktadır. Diğer yandan son zamanlarda, diyotlar ile doğrultulan giriş AA geriliminin evirici ve transformatörlü yapı ile yükseltilmeden önce bir DA-DA çevirici ile yükseltip eviriciye uygulanması gündeme gelmiştir. Bu yapı özellikle yenilenebilir enerji kaynaklarının şebekeye bağlanmasında sıklıkla tercih edilmeye başlanmıştır. Bu yapıda giriş gerilimini yükseltmek için klasik yükseltici (boost) devreleri hem verim, hem de güvenilirlik açısından tercih edilmemektedir. Özellikle bu çalışmadaki uygulamanın gerektirdiği kV'lar seviyesine klasik yükseltici çeviriciler ile çıkmak pratikte uygulanabilir değildir. Bu kapsamda, özellikle yenilenebilir kaynakların şebekeye bağlanmasında, empedans kaynaklı (Z-Kaynak, Yarı-Z-Kaynak, Y-Kaynak) DA-DA çeviricilerin tercih edildiği görülmektedir [11-17]. Empedans kaynaklı (EK) çeviriciler, gerilim kaynaklı ve akım kaynaklı çeviricilerin iyi yanlarını bir araya getirirken artı üstünlükler de sunarlar. Bu yeni nesil çeviricilerin avantajları; aynı devre ile hem yükseltme hem de alçaltma sağlayabilme, geniş giriş akımı aralığı, yüksek gerilim kazancı ve düşük anahtar gerilim stresi olarak sıralanabilir [18,19]. Özellikle yarı-Z-kaynak yapısı, sürekli ve düşük dalgacıklı giriş akımı, yüksek verimlilik ve güvenilirlik gibi klasik Z-kaynak yapısına göre sunduğu artı avantajlardan dolayı daha sıklıkla tercih edilmektedir [11-15, 18,19]. Bu sebeple, yürütülmekte olan proje kapsamında da genel yapısı [11-17]'de sunulmuş olan yapılar ile aynı olan, ancak giriş katında yeni nesil bir izoleli yarı-Z-kaynak çeviricinin kullanıldığı, bir yüksek DA gerilim kaynağı yapısı tercih edilmiştir. Giriş katında empedans kaynaklı bir DA-DA çevirici kullanımı ile güç kaynağının trafo girişine olabildiğince yüksek bir DA giriş gerilimi sağlanarak trafonun sarım sayısının ve kaçak elemanlarının asgari düzeyde tutulması projenin temel amacıdır. Ayrıca, empedans kaynaklı çeviricilerin yüksek verimlilik ve düşük anahtar gerilim stresi ile yüksek gerilim kazancı sunmaları sayesinde verimli, kompakt ve sorunsuz bir yüksek gerilim DA güç kaynağı tasarımı hedeflenmektedir. Kullanılan yeni nesil yarı-Z-kaynak çevirici topolojisinin avantajları ve tercih sebebi 2. Bölüm'de açıklanmıştır.

Bu çalışmada, yürütülen proje kapsamında tasarlanan yüksek güçlü DA güç kaynağının giriş katında kullanılan Z-

kaynak çeviricinin gereksinimlere uygun güç katı tasarımı sunulmuştur. Çalışmanın 2. Bölümü'nde önerilen güç kaynağı yapısı ve giriş katında kullanılan empedans kaynaklı çevirici topolojisi verilmiştir. 3. Bölüm'de empedans kaynaklı çeviricinin kararlı durum özelliklerini belirleyen gerilim-denge ve akım-denge eşitlikleri elde edilmiştir. 4. Bölüm'de güç kaynağı gereksinimlerine göre DA-DA çeviricinin devre elemanları ile güç katı tasarımı sunulmuştur. Belirlenen devre elemanlarına göre çeviricinin performansı Matlab-Simulink modeli ile doğrulanarak sonuçlar 5. Bölüm'de verilmiştir. 6. Bölüm'de ise sonuçların değerlendirilmesi verilmiştir.

2. Yüksek Gerilim DA Güç Kaynağı Yapısı ve Empedans Kaynaklı Çevirici

Önerilen yüksek DA gerilim güç kaynağının yapısı Şekil 1' de gösterilmiştir. Güç kaynağı, 350 V giriş gerilimi ile 10 kV çıkış gerilimi sağlayacak ve 2 kW güç kapasitesinde olacaktır. Şekil 1'deki yapıya göre, doğrultulmuş 350 V gerilim öncelikle bir EK çevirici ile 2 kV'a çıkarılacaktır. Daha sonra, 2 kV DC gerilim bir evirici ile AA gerilime dönüştürülüp 2.5 sarım oranlı bir trafo ve trafonun çıkışındaki gerilim katlayıcı (2 kat)+süzgeç yapısı ile 10 kV'a çıkarılacaktır. Bu yapıdan anlaşılacağı üzere giriş katında 350 - 2000 V, 2 kW anma değerlerinde bir EK çevirici gerekmektedir. Bu noktada, kullanılacak olan EK çeviricinin topolojisi önem arz etmektedir. Literatürde son zamanlarda geliştirilmiş quasi-Z-source tabanlı yeni nesil çeviriciler göze çarpmaktadır. Bu çeviriciler izolesiz [20,21] ve izoleli [22,23] olmak üzere iki ana grupta sınıflandırılabilirler. İzoleli çeviriciler izolasyonun gerekli olduğu uygulamalarda tercih edilebilirken, izolasyonun gerekmediği durumlarda da yüksek gerilim kazancı sağlamalarından dolayı tercih edilebilirler. Ancak izoleli yapılarda çıkış diyot gerilimi genelde bağlantı endüktörünün sarım oranı kadar artabildiğinden, bu durum tasarım aşamasında eleman seçiminde dikkate alınmalıdır. Diğer yandan izolesiz yapılar gereken yüksek gerilim kazancını sağlayabilmek için çok fazla miktarda gerilim katlayıcı kullanmakta olup, giriş akımı süresiz yapıdadır ve anahtar ve diyot gerilimleri açısından [22]'deki topolojiye göre fazladan bir avantaj sağlamamaktadır. Bu değerlendirmeler doğrultusunda, güç kaynağının girişinde kullanılmak üzere tercih edilen EK çeviricinin devre şeması Şekil 2' de gösterilmiştir. Kullanılacak olan giriş EK çeviricisinin detaylı analizi ve çalışma modları [22]'de anlatılmıştır. Ancak, çeviricinin güç katı tasarımında devre elemanları seçimi için gereken tüm gerilim-denge ve akım-denge eşitliklerine ihtiyaç vardır. Bu eşitliklerin bir kısmı [22]'de sadece çıkış gerilim

kazancını belirlemek amacıyla kısmen çıkarılmış olup, gereken eşitliklerin tamamı bir sonraki bölümde çıkarılacaktır.

3. EK Çeviricinin Statik Analizi

Yüksek gerilim DA güç kaynağında, giriş DA gerilimini yükseltmek için kullanılacak olan EK çeviricinin devre şeması Şekil 2.a'da gösterilmiştir. [22]'de detaylıca açıklandığı gibi, çevirici her zaman sürekli iletim modunda (Continuous Conduction Mode) çalışmakta olup, çeviricinin ikisi S anahtarının AÇIK ve KAPALI durumlarına karşılık gelen iki ana mod olmak üzere, toplam yedi alt çalışma modu bulunmaktadır. Ana modlar haricindeki diğer modlar S anahtarının ve diyotların kaçak bileşenlerinden kaynaklı çok kısa süreli modlar olup, bu sebeple ihmal edilmeleri mümkündür. Çeviricinin ana AÇIK modunda, S anahtarı ve D_o diyotu iletimdeyken, D_1 , D_2 ve D_3 diyotları kapalı durumdadır. Ana KAPALI modunda ise S anahtarı ve D_o diyotu kapalı, D_1 , D_2 ve D_3 diyotları açık durumdadır. Çeviricinin statik analizi için gereken, ikincil tarafa transfer edilmiş AÇIK ve KAPALI mod eşdeğer devreleri Şekil 2.b ve c'de gösterilmiştir. Şekil 2'deki devrelerde, L_{in} çeviricinin giriş endüktörünün endüktansı, L_m ise bağlantı endüktörünün manyetikleme endüktansıdır. Şekil 2.b ve c'deki L_{lke} bağlantı endüktörünün toplam kaçak endüktansına karşılık gelmektedir. İkincil kapasitörleri C_3 ve C_4 eşdeğer kapasitörler olup AÇIK modda birbirlerine seri, KAPALI modda ise paralel durumdadırlar. Bu kapasitörler eşdeğer oldukları için, bu kapasitörlerin ortak parametreleri alt simgesi '34' olan ortak bir parametre ile gösterilecektir. Şekil 2.b ve c'deki üst tire " ' " işaretli semboller ilgili parametre değerinin ikincil tarafa yansıtılmış değerini ifade etmektedir. İlgili kapasitans ve endüktans değerleri $C'_1 = C_1/n^2$, $C'_2 = C_2/n^2$, $L'_m = n^2 L_m$, $L'_{in} = n^2 L_{in}$, $L'_{lke} = n^2 L_{lke}$ eşitlikleri ile ve devredeki ilgili tüm gerilim ve akımlar sırasıyla $v' = nv$ ve $i' = i/n$ eşitlikleri ile ikincil tarafa yansıtılırlar. Burada, $n = n_2/n_1$ bağlantı endüktörünün sarım oranıdır.

Şekil 2.b ve c'den, giriş endüktansı, L'_{in} , manyetikleme endüktansı L'_m ve kaçak endüktans L'_{lke} için gerilim-denge eşitlikleri aşağıdaki gibi elde edilir;

$$\langle V'_{Lin} \rangle = D(nV_{in} + V'_{C2}) + (1-D)(nV_{in} - V'_{C1}) \quad (1)$$

$$\langle V'_{Lm} \rangle = DkV'_{C1} - (1-D)kV'_{C2} \quad (2.a)$$

$$\langle V'_{Lm} \rangle = D(V_{C0} - 2V_{C34}) - (1-D)V_{C34} \quad (2.b)$$

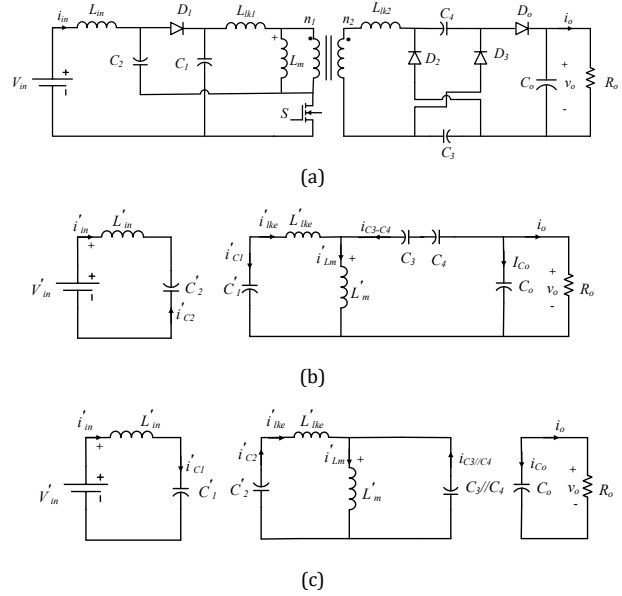
$$\langle V'_{lke} \rangle = D(V'_{C1} + 2V_{C34} - V_{C0}) + (1-D)(-V'_{C2} + V_{C34}) \quad (3)$$

Bu eşitliklerde D , çeviricinin görev periyodunu, üçgen parantez içerisinde gösterilen gerilimler de endüktörlerin ortalama gerilim değerlerini belirtmektedir. $k = L_m/(L_m+L_{lke})$ bağlantı endüktörünün bağlantı katsayısıdır. Kararlı durumda endüktör gerilimlerinin ortalama değerleri sıfır olacağı için, (1)-(3) eşitlikleri sıfıra eşitlenerek kararlı durum ortalama kapasitör gerilim değerleri aşağıdaki gibi elde edilir;

$$V'_{C1} = \frac{(1-D)nV_{in}}{(1-2D)} \quad (4)$$

$$V'_{C2} = \frac{DnV_{in}}{(1-2D)} \quad (5)$$

$$V_{C34} = V_{C3} = V_{C4} = kV'_{C2} \quad (6)$$



Şekil 2. EK çevirici devre şemaları (a) asıl devre (b) AÇIK mod eşdeğer devresi (c) KAPALI mod eşdeğer devresi.

$$V_{C0} = nkV_{in} \frac{(1+D)}{(1-2D)} \quad (7)$$

Diğer yandan, Şekil 2.b ve c kullanılarak, C_1 , C_2 , C_3 ve C_4 kapasitörlerinin akım-denge eşitlikleri aşağıdaki gibi elde edilir;

$$\langle I'_{C1} \rangle = -DI'_{lke-on} + (1-D)I'_{in} \quad (8)$$

$$\langle I'_{C2} \rangle = -DI'_{in} + (1-D)I'_{lke-off} \quad (9)$$

$$\langle I_{C34} \rangle = D(I'_{Lm} - I'_{lke-on}) + (1-D) \frac{(I'_{Lm} - I'_{lke-off})}{2} \quad (10)$$

$$\langle I_{C0} \rangle = D(I'_{lke-on} - I'_{Lm} - \frac{V_{C0}}{R_o}) - (1-D) \frac{V_{C0}}{R_o} \quad (11)$$

Bu eşitliklerde, I'_{lke-on} ve $I'_{lke-off}$ sırasıyla, eşdeğer kaçak endüktansın (L'_{lke}) AÇIK ve KAPALI modlardaki ortalama akım değerleridir. Kararlı durumda ortalama kapasitör akımları sıfır olacağı için, (8)-(11) eşitlikleri sıfıra eşitlenerek ortalama endüktör akımları aşağıdaki gibi elde edilir;

$$I'_{lke-on} = \frac{(1-D)}{D} I'_{in} \quad (12)$$

$$I'_{lke-off} = \frac{D}{(1-D)} I'_{in} \quad (13)$$

$$I'_{Lm} = \frac{(2-D)}{(1+D)} I'_{in} \quad (14)$$

burada,

$$I'_{in} = \frac{V_{C0} I_o}{nV_{in}} \quad (15)$$

$$I_o = \frac{V_{C0}}{R_o} \quad (16)$$

Anahtar ve diyotların kapalı durum gerilim stresleri de eleman seçiminde gereken diğer parametrelerdir. Şekil 2'nin analizinden, S anahtarının ve D_{o-3} diyotlarının kapalı durum

gerilimleri V_{DS} ve V_{D0-3} aşağıdaki gibi elde edilir,

$$V_{DS} = V_{C1} + V_{C2} = \frac{V_{in}}{1-2D} \quad (17)$$

$$V_{D0} = V_{D2} = V_{D3} = \frac{nV_{in}}{1-2D} \quad (18)$$

$$V_{D1} = \frac{V_{in}}{1-2D} \quad (19)$$

Eşitlik (4)-(7), (12)-(15) ve (17)-(19) ile sırasıyla ortalama kapasitör gerilimleri, ortalama endüktör akımları ve anahtar gerilimleri elde edilmiştir. Bir sonraki bölümde, bu eşitlikler kullanılarak hedeflenen tasarım gereksinimlerini karşılayacak şekilde endüktans, kapasitans, ve anahtar gerilim değerleri belirlenecektir.

4. EK Çevirici Güç Katı Tasarımı

EK çeviricinin, hedeflenen yüksek gerilim DA güç kaynağı ile uyumlu olacak şekilde belirlenmiş tasarım gereksinimleri Tablo 1'de verilmiştir. Verilen giriş-çıkış gerilimleri ve (7) kullanılarak, bağlantı endüktörünün sarım oranı, $n = 1.8$ olarak elde edilir. Sarım oranı belirlendikten sonra, (4)-(6) eşitlikleri kullanılarak, yansıtılmamış ortalama kapasitör gerilimleri, $V_{C1} = 612.5$ V, $V_{C2} = 262.5$ V, $V_{C3} = V_{C4} = 463$ V olarak elde edilirler. Anahtar ve diyot gerilimleri de (17)-(19) dan, $V_{DS} = V_{D1} = 875$ V, $V_{D0} = V_{D2} = V_{D3} = 1575$ V olarak elde edilirler.

Endüktör tasarımında, endüktans değeri yanında ortalama endüktör akımı da gereken diğer parametrelerdendir. L_{in} ve L_m endüktör akımlarının yansıtılmamış ortalama değerleri (14) ve (15)'den, $I_{Lin} = 5.71$ A, $I_{Lm} = 7.47$ A olarak elde edilirler. Diğer yandan, anahtar seçiminde de kapalı durum gerilim stresi yanında ortalama ve tepe anahtar akımları da anahtar seçimi için gerekmektedir. Şekil 2.a ve b'nin analizinden, AÇIK durumdaki ortalama anahtar akımı, I_{DS} , aşağıdaki gibi elde edilir,

$$I_{DS} = I_{in} + I_{Ike-on} \quad (20)$$

Eşitlik (12) ve (15) deki yansıtılmamış akım eşitlikleri (20) de yerine koyulursa, ortalama anahtar akımı aşağıdaki gibi elde edilir,

$$I_{DS} = \frac{(1-D)}{D} I_{in} + I_{in} = 19.03 \text{ A} \quad (21)$$

Azami anahtar akımı (I_{DS-max}), azami endüktör akımı dalgacığı gereksinimine göre (%20 tepe-tepe, %10 tepe), $I_{DS-max} = 1.1 \times I_{DS} = 21$ A olarak elde edilir.

Endüktans değeri belirlemek için AÇIK veya KAPALI mod endüktör gerilimlerine ihtiyaç vardır. AÇIK mod için hesaplama yapılırsa, L_{in} ve L_m endüktörlerinin açık mod gerilimleri, Şekil 2.b'den aşağıdaki gibi elde edilir,

$$V_{Lin-on} = V_{in} + V_{C2} = 350 + 262.5 = 612.5 \text{ V} \quad (22)$$

$$V_{Lm-on} = (V_{Co} - 2V_{C34})/n = (2000 - 2 \times 463)/1.8 = 597 \text{ V} \quad (23)$$

Endüktans hesabında aşağıda verilen tipik endüktör eşitliği kullanılır,

$$L = \frac{V \Delta T}{\Delta I} \quad (24)$$

Eşitlik (24)'de, ΔI tepeden-tepeye akım değişimi, ΔT ise değişimin süresidir. AÇIK mod seçildiği için $\Delta T = DT_s$ olacaktır. Burada T_s anahtarlama periyodudur. Eşitlik (22)-(24) ve Tablo

Tablo 1 EK çeviricinin tasarım gereksinimleri

| Parametre | Değeri (birimi) |
|---|-----------------|
| Çıkış gerilimi (V_o) | 2 (kV) |
| Giriş gerilimi (V_{in}) | 350 V |
| Çıkış gücü (P_o) | 2 (kW) |
| Anahtarlama frekansı (f_s) | 50 (kHz) |
| Görev periyodu (D) | 0.3 |
| Bağlantı endüktörü bağlantı katsayısı (k) | 0.98 |
| Endüktörlerin akım dalgalanması (tepe-tepe) | %20 |
| Kapasitörlerin gerilim dalgalanması (tepe-tepe) | %4 |

1'de verilen endüktör akımı dalgalanma miktarı gereksiniminden, giriş ve manyetikleme endüktans değerleri aşağıdaki gibi elde edilir,

$$L_{in} = \frac{V_{Lin-on} DT_s}{\Delta I_{in}} = \frac{612.5 \times 0.3 \times 1 / (50 \times 10^3)}{0.2 \times 5.71} = 3.22 \text{ mH} \quad (25)$$

$$L_m = \frac{V_{Lm-on} DT_s}{\Delta I_{Lm}} = \frac{597 \times 0.3 \times 1 / (50 \times 10^3)}{0.2 \times 7.47} = 2.4 \text{ mH} \quad (26)$$

Son olarak, kapasitans değeri belirlemek için AÇIK veya KAPALI mod ortalama kapasitör akımlarına ihtiyaç vardır. AÇIK mod seçildiğinde, Şekil 2.b'den, C_{0-4} kapasitörlerinin ortalama AÇIK mod akımları aşağıdaki gibi elde edilir,

$$I_{C1-on} = I_{Ike-on} = \frac{1-D}{D} I_{in} = 13.3 \text{ A} \quad (27)$$

$$I_{C2-on} = I_{in} = 5.71 \text{ A} \quad (28)$$

$$I_{C3,C4-on} = I'_{Lm} - I'_{Ike-on} = \left(\frac{2-D}{1+D} - \frac{1-D}{D} \right) I'_{in} = -3.25 \text{ A} \quad (29)$$

$$I_{C0-on} = -I_{C3,C4-on} - I_o = 2.25 \text{ A} \quad (30)$$

Kapasitans hesabında ise aşağıda verilen tipik kapasitör eşitliği kullanılır,

$$C = \frac{I \Delta T}{\Delta V} \quad (31)$$

Eşitlik (27)-(30)'dan elde edilen akım değerleri ve Tablo 1 de verilen gerilim dalgalanma gereksiniminden C_{0-4} kapasitörlerinin değerleri aşağıdaki gibi elde edilir,

$$C_1 = \frac{I_{C1-on} DT_s}{\Delta V_{C1}} = \frac{13.3 \times 0.3 \times 1 / (50 \times 10^3)}{0.04 \times 612.5} = 3.26 \text{ } \mu\text{F} \quad (32)$$

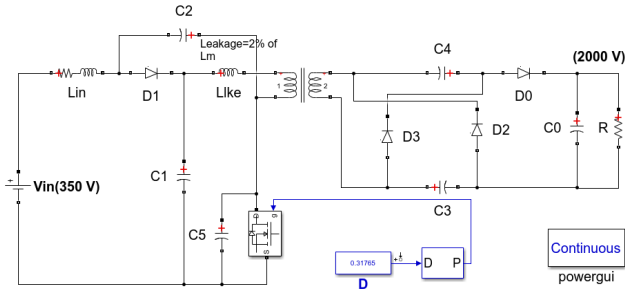
$$C_2 = \frac{I_{C2-on} DT_s}{\Delta V_{C2}} = \frac{5.71 \times 0.3 \times 1 / (50 \times 10^3)}{0.04 \times 262.5} = 3.26 \text{ } \mu\text{F} \quad (33)$$

$$C_3 = C_4 = \frac{I_{C3,C4-on} DT_s}{\Delta V_{C3,C4}} = \frac{3.25 \times 0.3 \times 1 / (50 \times 10^3)}{0.04 \times 463} = 1.05 \text{ } \mu\text{F} \quad (34)$$


$$C_0 = \frac{I_{C0-on} DT_s}{\Delta V_{C0}} = \frac{2.25 \times 0.3 \times 1 / (50 \times 10^3)}{0.04 \times 2000} = 169 \text{ nF} \quad (35)$$

5. EK Çeviricinin Benzetimi

Bir önceki bölümde tasarlanan EK çeviricinin, hesaplanan devre elemanlarının değerleri kullanılarak benzetimi Matlab-Simulink ortamında gerçekleştirilmiştir. Şekil 3'de EK çeviricinin benzetim modeli görülmektedir. Modeldeki anahtara paralel C_5 kapasitörü anahtarın çıkış kapasitörünü (C_{DS}) modellemek için eklenmiş olup, değeri 1 nF'dir. Ayrıca,



Şekil 3. EK çeviricinin Matlab-Simulink benzetim modeli.




Şekil 4. Çıkış geriliminin tam yük altında kalkışının benzetim sonucu.

bağlantı endüktörünün kaçak endüktansının oranı olarak, endüktörün tasarım hedeflerinden birisi olan %2 seçilmiştir. Bağlantı endüktörünün tasarımı proje kapsamında yürütülmekte olan çalışmalardan bir diğeridir ve bu çalışmanın konusu değildir. Bu çalışma kapsamında belirlenen devre elemanlarına göre oluşturulmuş EK çeviricinin nominal yük altında ilk kalkış gerilim eğrisinin benzetim sonucu Şekil 4'de gösterilmiştir. Gerilim eğrisindeki salınımlar EK çeviricinin küçük sinyal dinamik modeli ile ilişkilidir. Çeviricinin dinamik analizi, kapalı döngü denetleyici tasarımı başlığı altında, gelecek çalışmalar kapsamında detaylıca ele alınacaktır ve bu çalışmanın konusu değildir. Diğer yandan, bu çalışmadaki sonuçların irdelenmesi amacıyla, Şekil 5'de sırasıyla giriş gerilimi, giriş akımı ve manyetikleme endüktansı akımının yakın gösterim benzetim sonuçları kararlı durum için gösterilmiştir. Giriş geriliminin tepeden-tepeye değişiminin tasarım hedefi olan %4 dalgalanma kriterini ($2000 \cdot 0.04 = 80$ V) karşıladığı görülmektedir. Benzer şekilde endüktör akımlarının ortalama değerleri ve dalgalanma yüzdeleri de tasarım hedefleri ile uyumludur.


Şekil 6'da S anahtarları ve çıkış diyot gerilimlerinin benzetim sonuçları görülmektedir. Anahtar ve diyot gerilimleri de tasarım hedefleri ile uyumludur. Anahtarların KAPALI mod gerilim değerlerindeki beklenen değerlere göre bir miktar fazlalık, 2000 V çıkış gerilimi için gereken görev periyodunun, ideal olmayan model elemanlarından dolayı bir miktar fazla (0.317) set edilmesinden dolayıdır. Çeviricinin kapalı döngü denetiminde set edilen çıkış gerilimi için gereken görev periyodunu denetleyici ayarlayacaktır.

6. Sonuç


Bu çalışmada yüksek DA gerilim bir güç kaynağının giriş katında, ilk kademe yükseltici olarak kullanılacak olan yeni nesil bir EK çeviricinin, hedeflenen gereksinimler doğrultusunda tasarımı ve benzetimi yapılmıştır. Yüksek gerilim trafosundan önce bu şekilde yüksek kazançlı bir EK



a) Çıkış gerilimi, V_o



b) Giriş akımı, I_{in}



c) Manyetikleme endüktansı akımı, I_m

Şekil 5. EK çeviricinin Matlab-Simulink benzetim sonuçları.


çeviricinin kullanımı ile trafonun sarım oranının ve dolayısı ile kaçak elemanlarının değerlerinin düşürülmesi hedeflenmektedir. Tasarım için gereken ortalama kapasitör akımları ve endüktör gerilimleri, EK çeviricinin kararlı durum (statik) analizi ile elde edilmiştir. Benzetim sonuçlarına göre, EK çevirici tasarımının gereksinimler ile uyumlu olduğu görülmüştür. Bundan sonraki aşamada, çeviricinin kapalı döngü performansı ve verimlilik analizleri için, tasarlanacak olan bir denetleyici ile beraber ilk modeli üretilip deneysel çalışmalar gerçekleştirilecektir.

Teşekkür

Bu çalışma, TÜBİTAK tarafından desteklenen 121E377 kodlu Empedans Kaynaklı DA-DA Dönüştürücülü Yüksek Gerilim DA Güç Kaynağı Tasarımı başlıklı proje kapsamında gerçekleştirilmiştir. Destek için TÜBİTAK'a teşekkür ederiz.

Kaynaklar

- [1] V. Garcia, M. Rico, J. Sebastian, M. M. Hernando and J. Uceda, "An optimized DC-to-DC converter topology for high-voltage pulse-load applications", Proceedings of 1994 Power Electronics Specialist Conference - PESC'94, Taipei, Taiwan, vol. 2, pp. 1413-1421, 1994.



Şekil 6. EK çeviricinin Matlab-Simulink benzetim sonuçları.

- [2] S. Mao, T. Wu, X. Lu, J. Popovic and J. A. Ferreira, "High frequency high voltage power conversion with silicon carbide power semiconductor devices", 6th Electronic System-Integration Technology Conference (ESTC), Grenoble, pp. 1-5, 2016.
- [3] M. Forouzesh, et al., "Step-up DC-DC converters: a comprehensive review of voltage-boosting techniques, topologies and applications", IEEE Transactions on Power Electronics, vol. 32, no. 12, pp. 9143-9178, 2017.
- [4] S. Mao, C. Li, W. Li, J. Popovic and J. A. Ferreira, "Review of high frequency high voltage generation architectures", IEEE 3rd International Future Energy Electronics Conference and ECCE Asia (IFEEC 2017 - ECCE Asia), Kaohsiung, pp. 2260-2266, 2017.
- [5] Y. A. Wang, D. M. Xiao, "Design of an electrostatic precipitator power supply based on transformer stray capacitance effects", Electric Power Components and Systems, vol. 38, no. 9, pp. 1005-1029, 2010.
- [6] J. Liu, L. Sheng, J. Shi, Z. Zhang and X. He, "Design of high voltage, high power and high frequency transformer in LCC resonant converter", Twenty-Fourth Annual IEEE Applied Power Electronics Conference and Exposition, Washington DC, pp. 1034-1038, 2009.
- [7] M. Borage, K. V. Nagesh, M. S. Bhatia and S. Tiwari, "Design of LCL-T resonant converter including the effect of transformer winding capacitance", IEEE Transactions on Industrial Electronics, vol. 56, no. 5, pp. 1420-1427, 2009.
- [8] L. Deng, P. Wang, X. Li, H. Xiao and T. Peng, "Investigation on the parasitic capacitance of high frequency and high voltage transformers of multi-section windings", IEEE Access, vol. 8, pp. 14065-14073, 2020.
- [9] S. Mao, Z. Yao, D. Zhu, J. Popovic and J. A. Ferreira, "A 300kHz 4kW 140kVDC output voltage power supply with modular high voltage generation architecture and planar transformer", 21st European Conference on Power Electronics and Applications (EPE '19 ECCE Europe), Genova, Italy, pp. 1-5, 2019.
- [10] K. An, G. Ning, H. Wang, M. Su and Y. Fu, "A novel DCX based on ZVZCS full-bridge cells with voltage-doubler rectifier for DC grids", IEEE 4th International Electrical and Energy Conference (CIEEC), pp. 1-6, 2021.
- [11] D. Vinnikov, I. Roasto, "Quasi-Z-Source-Based isolated DC/DC converters for distributed power generation", IEEE Transactions on Industrial Electronics, vol. 58, no.1, pp. 192-201, 2011.
- [12] Y. P. Siwakoti, F. Blaaberg, P. C. Loh, G. E. Town, "High-voltage boost quasi-Z-source isolated DA/DA converter", IET Power Electronics, vol. 7, no. 9, pp. 2387-2395, 2014.
- [13] O. Husev, et al., "Galvanically isolated quasi-Z-source DC-DC converter with a novel ZVS and ZCS technique", IEEE Transactions on Industrial Electronics, vol. 62, no. 12, pp. 7547-7556, 2015.
- [14] M. Heidari, et al., "A high voltage gain ZVT quasi-Z-source converter with reduced voltage stress", IEEE Transactions on Power Electronics, vol. 37, no. 11, pp. 13696-13710, 2022.
- [15] E. S. Oluwasogo, H. Cha, and T-T. Nguyen, "Beta-quasi-Z-source (β -qZS) DC-DC converter without duty cycle constraint for wide input voltage applications", IEEE Transactions on Industrial Electronics, vol. 69, no. 12, pp. 12784-12794, 2022.
- [16] Y. Siwakoti, et al., "Magnetically coupled high-gain Y-source isolated DC/DC converter", IET Power Electronics, doi: 10.1049/iet-pel.2013.0957, pp. 1-8, 2014.
- [17] X. Fang, X. Ding, S. Zhong, Y. Tian, "Improved quasi-Y-source DC-DC converter for renewable energy", CPSS Transactions on Power Electronics and Applications, vol. 4, no. 2, pp. 163-170, 2019.
- [18] K. Hada, A. K. Sharma, P. S. Tomar, J. Gupta, "Modern Z-source power conversion technologies: A review", International Research Journal of Engineering and Technology, vol. 4, no. 6, pp. 3207-3211, 2017.
- [19] Y. P. Siwakoti, et al., "Impedance-source networks for electric power conversion part I: A topological review",

IEEE Transactions on Power Electronics, vol. 30, no. 2, pp. 699-716, 2015.

[20] M. M. Haji-Esmaili, E. Babaei, M. Sabahi, "High step-up quasi-Z-source DC-DC converter," IEEE Transactions on Power Electronics, vol. 33, no. 12, pp. 10563-10571, 2018.

[21] M. Veerachary, P. Kumar, "Analysis and design of quasi-Z-source equivalent DC-DC boost converters," IEEE Transactions on Industrial Electronics, vol. 56, no. 6, pp. 6642-6656, 2020.

[22] F. Evran, M.T. Aydemir, "Z-source-based isolated high step-up converter," IET Power Electronics, vol. 6, no. 1, pp. 117-124, 2012.

[23] F. Evran, M.T. Aydemir, "Isolated high step-up Dc-DC converter with low voltage stress," IEEE Power Electronics, vol. 29, no. 7, pp. 3591-3603, 2014.

Özgeçmişler



Bülent Dağ, lisans ve yüksek lisans derecelerini 1998 ve 2002 yıllarında Orta Doğu Teknik Üniversitesi Elektrik-Elektronik Mühendisliği, doktora derecesini 2015 yılında Gazi Üniversitesi Elektrik-Elektronik Mühendisliği Ana Bilim Dalı'ndan almıştır. 2020 yılından beri Gazi Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde öğretim üyesi olarak çalışmaktadır. Çalışma alanları arasında mıknatıslı elektrik makineleri ve anahtarlamalı güç kaynakları yer almaktadır.



Mehmet Akif Özdemir, 1988 Bayburt doğumludur. Lisans eğitimini 2011 yılında Ege Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünde tamamlamıştır. Yüksek lisans derecesini 2021 yılında Gazi Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nden almıştır. Doktora eğitimine TÜBİTAK bursiyeri olarak Gazi Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde devam etmektedir. Güç elektroniği alanında çalışmalar yapmaktadır.

Özgeçmişler



Dr. Bünyamin Tamyürek, 1970 Artvin-Yusufeli doğumludur. Lisans derecesini 1991 yılında Yıldız Teknik Üniversitesi Elektrik Mühendisliği Bölümü'nden, yüksek lisans ve doktora derecelerini 1996 ve 2001 yıllarında New York eyaletinin Troy şehrinde yer alan Rensselaer Polytechnic Institute mühendislik okulunun Elektrik Güç Mühendisliği Bölümü'nden almıştır. Dr. Tamyürek, Amerika Birleşik Devletleri'nin Ohio eyaletine bağlı Columbus şehrinde, enerji üretim, iletim ve dağıtımını yapan American Electric Power (AEP) isimli kuruluşta iki yıl süreyle yenilenebilir enerji kaynakları ve enerji depolama sistemleri konusunda araştırma ve geliştirme mühendisi olarak görev almıştır. Türkiye dönüşünden sonra 2004-2019 yılları arasında Eskişehir Osmangazi Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü'nde çalışmış. 2019 yılından itibaren de Gazi Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü'nde öğretim üyesi olarak çalışmaktadır. Güç elektroniği, kesintisiz güç kaynakları, elektrikli araçlarda elektrikli tahrik ve batarya şarj sistemleri, raylı sistemler, enerji depolama sistemleri, akıllı şebekeler ve askeri ve endüstriyel uygulama alanlarında enerji verimliliği yüksek güç dönüştürücü tasarımı konularında çalışmalar yapmaktadır.



Emrullah Aydın, 1986 yılında Elazığ'da doğdu. Lisans eğitimini 2009 yılında Fırat Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde tamamladı. 2014 ve 2020 yıllarında Gazi Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde sırasıyla Yüksek Lisans ve Doktora eğitimlerini tamamlamıştır. Doktora eğitimini tamamladıktan sonra Malatya Turgut Özal Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde Dr. Öğretim Üyesi olarak çalışmaya başlamış ve halen burada çalışmaya devam etmektedir. İlgi duyduğu araştırma alanları arasında Kablosuz Güç Aktarımı, Elektrik Makinaları, Güç Elektroniği ve İndüksiyon Isıtma Sistemleri yer almaktadır.



Prof. Dr. M. Timur Aydemir, Lisans ve Yüksek Lisans derecelerini Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nden, doktora derecesini University of Wisconsin - Madison Üniversitesi'nden aldı. 2001-2002 yıllarında Fulbright bursiyeri olarak ABD'de University of Wisconsin - Madison Üniversitesi'nde misafir araştırmacı olarak görev yaptı. Güç Elektroniği, Elektrik Makineleri ve Yenilenebilir Enerji Kaynakları alanında çalışmaları bulunmaktadır. 2012-14 yılları arasında EMO Ankara Şubesi Eğitim Komisyonu Başkanlığı yapmıştır. Halen Kadir Has Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde öğretim üyesi olarak görev yapmaktadır.

S-kutusu Büyüklüğünün Korelasyon Güç Analizi Sonuçlarına Etkisi Impact of S-box Size on Results of Correlation Power Analysis

 Selçuk Kavut¹, Yasin Reşit Yargıcı² 

¹Bilgisayar Mühendisliği Bölümü, Balıkesir Üniversitesi, Balıkesir, Türkiye

skavut@balikesir.edu.tr

²İşbir Sentetik Dokuma Sanayi A.Ş., Balıkesir, Türkiye

ysn.yargici@gmail.com

Öz

Simetrik bir krypto-sistemde küçük S-kutularının kullanımı, gömüldüğü donanımın güç tüketimini azaltmaktadır. Bu durumun yan kanal analizi (YKA) sonuçlarında gürültünün bozucu etkisini arttırdığı bilinmektedir. Bu çalışmamızda, bahsedilen etkiyi deneysel olarak doğrulamak için, 4×4 S-kutularına sahip hafif sıklet blok şifreleme algoritması PRESENT, SAKURA-X kriptografik donanımı üzerinde gerçekleştirilmiş ve en etkili YKA yöntemlerinden olan korelasyon güç analizi (KGA) yapılmıştır. Bunun sonucunda, ölçüm düzeneğimiz vasıtasıyla alınan güç ölçümlerinde oluşan gürültünün doğru anahtar tespitini zorlaştırdığı görülmüştür. Ayrıca, PRESENT için gürültülü güç ölçümlerinin benzetimi ile KGA yürütüldüğünde, doğru anahtarın başarılı bir şekilde elde edildiği gözlenmiştir. Diğer taraftan, S-kutuları 8×8 AES S-kutusu ile değiştirilmiş PRESENT için aynı ölçüm düzeneğiyle KGA uyguladığımızda, güç tüketimi artışına paralel olarak, gürültü etkisinin daha az olduğu ve doğru anahtarın daha kolay elde edildiği gösterilmiştir. Anahtar Kelimeler: AES, PRESENT, SAKURA-X, Korelasyon Güç Analizi (KGA)

Abstract

Use of small S-boxes in a symmetric crypto-system reduces power consumption of its embedded hardware. It is known that this increases the adverse effect of noise on the results of side channel analysis (SCA). Here, to verify the mentioned effect experimentally, the lightweight block cipher PRESENT having 4×4 S-boxes is implemented on the cryptographic hardware SAKURA-X and correlation power analysis (CPA), one of the most powerful methods of SCA, is realized. Consequently, we find that the noise occurring within the power traces obtained by our measurement setup makes it difficult to identify the correct key. Further, when we apply CPA to PRESENT by simulating the noisy power traces, we get the correct key successfully. On the other hand, applying CPA, with the same measurement setup, to PRESENT in which the S-boxes are replaced with the AES S-box, we show that, parallel to the increase in power consumption, the noise effect is lesser and it is easier to find the correct key.

Key Words: AES, PRESENT, SAKURA-X, Correlation Power Analysis (CPA)

1. Giriş

Günümüzde, oldukça kısıtlı donanım kapasitesine sahip olan radyo frekansı ile tanımlama (RFID) etiketleri, sensör ağları, temassız akıllı kartlar ve nesnelerin interneti (IoT) cihazları gibi elektronik sistemlerde verinin korunmasını amaçlayan hafif sıklet kriptografi, simetrik kriptografinin artan bir ilgi odağı haline gelmiştir. Simetrik krypto-sistem tasarımında, n biti m bite gönderen bir fonksiyon olarak tanımlanan S-kutusu (yerleştirme kutusu), kullanıldığı krypto-sistemin güvenliği ve verimliliği açısından önemli rol oynayan temel yapı taşıdır. S-kutularının büyüklüğü, genellikle kullanılan mikroçip alanı ve güç tüketimini etkileyen en önemli faktördür. Çalışmamızda ele aldığımız PRESENT algoritması [1], hafif sıklet şifreleme gerektiren uygulamalar için ISO/IEC 29192-2:2012 standardına [2] göre önerilen bir blok şifredir. Donanımsal açıdan eniyelenmiş bir algoritma olan PRESENT, 4×4 büyüklüğünde S-kutuları kullanmaktadır ve örneğin, 8×8 S-kutularına sahip ileri şifreleme standardı AES ile karşılaştırıldığında 2.5 kat daha küçük mikroçip alanında gerçekleştirilebilmektedir [1].

1996'da Kocher'in değişen şifreleme zamanlarının gizli anahtar hakkında bilgi sızdırdığını gösteren çalışması [3] ve 1999'da Kocher vd.'nin kriptografik cihazın güç tüketimine bağlı olarak gerçekleştirdikleri kriptotez analiz [4], yan kanal analizi (YKA) literatürünün gelişimine katkı sağlayan öncü çalışmalarıdır. Genel olarak, kriptografik donanımların kullanılan şifreleme algoritması ve anahtara bağlı olarak dışarıya sızdırdıkları zamanlama, ses, güç tüketimi ve elektromanyetik radyasyon gibi yan kanal bilgilerinden faydalanılarak yapılan kriptotez analiz YKA denilmektedir. Örneğin, kriptografik cihazda yürütülen bir blok şifrenin tur işlemi esnasında tükettiği gücün, S-kutusu çıkışındaki bitlerin Hamming ağırlığına (veya giriş ve çıkış bitleri arasındaki Hamming uzaklığına) bağlı olduğunu varsayarsak, ortalamaların uzaklığı, karşılıklı bilgi veya Pearson korelasyonu gibi bir istatistiksel ayırıcı vasıtasıyla doğru korelasyon bulunarak gizli anahtar ortaya çıkarılabilir. Bahsedilen ayırıcıların kullanıldığı YKA yöntemleri (veya saldırı türleri) literatürde sırasıyla, farksal güç analizi (FGA) [4], karşılıklı bilgi analizi (KBA) [5] ve korelasyon güç analizi (KGA) [6] olarak bilinmektedir. Güç analizi sınıfına giren bu saldırı türleri, kriptografik donanıma zarar vermeden ve az maliyetle gerçekleştirilebilmektedirler. FGA saldırısı, Lo vd. [7] tarafından AES algoritması için gerçekleştirilen güç analizinin sonuçları ile deneysel olarak gösterildiği gibi, KGA

ile karşılaştırıldığında gürültü ve girişimden daha fazla etkilenmekte ve yanlış anahtar tahminlerinin artmasına neden olmaktadır. Bununla birlikte, çoklu bitin kullanıldığı FGA saldırısının, Hamming ağırlığı modelinin uygulandığı KGA saldırısı ile eşdeğer olduğu Dogett vd. [8] tarafından ispatlanmıştır. Moradi vd.'nin [9], KBA saldırısını KGA ile karşılaştırdığı çalışmada ise, KGA'nın daha verimli olduğu teorik olarak ispatlanmış ve deneysel olarak doğrulanmıştır. Diğer taraftan, donanımsal açıdan maliyet artışına neden olmakla birlikte, güç analizi saldırılarına karşı koymak için kriptografik algoritmanın hesapladığı ara değerlerin rastgeleleştirilmesine dayanan maskeleye (gizlilik paylaşımı) [10, 11], gürültü eklenerek sinyal-gürültü (SNR) oranının azaltılması [12] veya yürütülen işlem sırasının/program akışının rastgeleleştirilmesi [13] gibi önlemler literatürde bilinen yöntemlerdendir.

Aynı algoritma kullanılsa bile kriptografik donanıma bağlı olarak farklı biçim ve değerlerde yan kanal bilgisi ortaya çıkabildiğinden, YKA gerçekleştirildiği donanıma özeldir. Bununla birlikte, gerektirdiği veri karmaşıklığı ve işlemci gücü açısından pratikte yürütülmesi genellikle mümkün olmayan farksal [14] ve doğrusal [15] kriptanaliz gibi şifreleme algoritmasının sadece matematiksel tanımından faydalanan kriptanaliz türleri ile karşılaştırıldığında, YKA çok daha verimli şekilde kullanılan anahtarları ortaya çıkarabilmektedir.

Aşağıdaki bölümde literatürde yapılan önceki çalışmalar özetlenmekte ve bir sonraki bölümde PRESENT algoritması tanıtılmaktadır. Bölüm 4'te sunulan ölçüm düzeneği ile, Bölüm 5'te açıklanan KGA için gerekli güç ölçümlerinin nasıl elde edildiği açıklanmaktadır. Bölüm 6'da gerçekleştirdiğimiz KGA sonucu ortaya çıkan bulgular tartışılmakta ve bir sonraki sonuç bölümü ile makalemiz sonlanmaktadır.

2. Önceki çalışmalar

Yan kanal bilgisi vasıtasıyla hedeflenen şifreleme algoritmasının aşırı tanımlanmış bir denklem sistemi biçiminde temsil edilmesine dayanan bir saldırı türü olan cebirsel YKA [16], literatürde bilinen güçlü kriptanaliz yöntemlerinden birisidir. PRESENT algoritması için gerçekleştirilen ilk YKA saldırıları [17, 18], kriptografik algoritmanın belirli çıktıların düşük dereceli bir polinom biçiminde temsil edilmesiyle gerçekleştirilen ve küp saldırıları olarak bilinen bu türden saldırılardır. Daha yakın zamanda, Duan vd. [19] PRESENT algoritmasının ATmega 16 geliştirme kartı üzerinde gerçekleştirilmesine FGA saldırısı uygulayarak, rastgele değerlerle maskeleye göre daha hızlı olan ve daha az bellek gerektiren sabit değerle maskelemenin, algoritmayı FGA saldırısına karşı dayanıklı hale getirilebildiğini deneysel olarak göstermişlerdir. Sadhukhan vd. [20], PRESENT dâhil olmak üzere bazı hafif sıklet blok şifrelerin hem maskesiz hem de (eşik gerçekleştirilmesi olarak bilinen) maskeli versiyonlarını performans ve verimlilik açısından uygulamaya özgü tümleşik devre (ASIC) ve alanda programlanabilir kapı dizileri (FPGA) platformlarında AES ile karşılaştırmışlardır.

Bir blok şifrenin YKA saldırılarına karşı en hassas bileşeninin S-kutuları olduğu bilinmektedir. Goubin vd. [21], 8×8 büyüklüğündeki AES S-kutularını 4×4 ve 16×16 büyüklüğündeki S-kutuları ile değiştirerek, S-kutusu büyüklüğünün maskeleye durumunda yan kanal analizine etkisini çalışmışlar ve 16×16 büyüklüğündeki S-kutularının daha iyi güvenlik sağladığını göstermişlerdir. Diğer taraftan, Carlet vd. [22] tarafından bir S-kutusunun YKA karşısındaki (maskeleye yapılmaksızın) içsel dayanıklılığı bilgi teorisi açısından çalışılmış ve öz-korelasyon spektrumu ile ilişkisi

ortaya konulmuştur. Elde edilen bu ilişki, aynı varyansa sahip bağımsız toplanır Gauss gürültüsü varsayımı altında genel olarak küçük S-kutularının YKA karşısında daha güçlü olduğunu teorik olarak göstermektedir. Heuser vd.'nin [23] 4×4 S-kutularına sahip hafif sıklet blok şifrelerin dayanıklılığını 8×8 S-kutuları kullanan blok şifreler ile (güç ölçümlerinin benzetimi vasıtasıyla) başarı oranı metriğine göre karşılaştırdığı çalışması, [22] çalışmada gösterilen teorik sonucu doğrular niteliktedir. Fiziksel donanım üzerinde gerçekleştirme göz önüne alındığında, PRESENT algoritmasının KGA saldırısı karşısında dayanıklılığı ilk olarak Zhang vd. [24] tarafından ASIC üzerinde donanım gerçekleştirilmesi hedef alınarak çalışılmıştır. Bu çalışmanın daha pratik hale getirildiği Wang vd.'nin [25] çalışmada, Hamming uzaklığı modeline göre güç ölçümü tahmini yapmak için kullanılan bit sayısının artırılması ile, daha az sayıda güç ölçümünün anahtarları ortaya çıkarabildiği gösterilmiştir. PRESENT algoritmasının Arduino Uno üzerinde yazılım gerçekleştirilmesine KGA saldırısı uygulayan Lo vd. [26], aynı çalışmada güç ölçümü tahmininde S-kutusu kullanımının tur anahtar eklemeye fonksiyonuna göre daha iyi sonuç verdiğini göstermişlerdir. Yakın zamanda, PRESENT algoritmasının ASIC gerçekleştirilmesini hedef alan Fang ve Alioto [27], son tura kapalı metnin kullanılmasına dayanan bir KGA saldırısı gerçekleştirerek, hem ilk hem de son turun korelasyon matrislerinin kullanıldığı birleştirilmiş bir KGA saldırısı ile anahtarın daha verimli şekilde tespit edilebildiğini gözlemlemişlerdir. Ayrıca, Gunathilake vd. [28] tarafından PRESENT algoritmasının Arduino Uno üzerinde yazılım gerçekleştirilmesine ilk defa korelasyon elektromanyetik analizi uygulanmıştır. İlgili literatür ile karşılaştırıldığında, bu çalışmada ele aldığımız PRESENT algoritmasının büyüklüğü değiştirilmiş S-kutularına sahip bir versiyonunun herhangi bir donanım gerçekleştirilmesi ve bunun KGA sonuçlarına etkisi bildiğimiz kadarıyla literatürde daha önce incelenmemiştir. Elde ettiğimiz sonuçlar, Carlet vd.'nin [22] teorik çıkarımını ile Heuser vd.'nin [23] benzetim sonuçlarını doğrulamakta ve bununla birlikte nicemleme hatasından dolayı PRESENT algoritmasında kullanılan anahtarın tespit edilemeyeceğini göstermektedir.

3. PRESENT Algoritması

PRESENT algoritması 31 turluk bir blok şifredir. Bu algoritmada 64-bit uzunluktaki açık veriler, 80 veya 128 bitlik anahtar ile şifrelenerek kapalı veriler elde edilmektedir. Çalışmamızda, 80 bitlik anahtar ile gerçekleştirilmiştir. PRESENT algoritmasının sözde kodu Şekil 1'de gösterilmiştir.

```

for (i = 1; i <= 31; i++)
{
    addRoundKey(Blok, Ki);
    sBoxLayer(Blok);
    pLayer(Blok);
}
addRoundKey(Blok, K32);

```

} i. tur

Şekil 1. PRESENT algoritmasının sözde kodu.

Yukardaki sözde koddan görüldüğü gibi, şifrelemenin her bir turu üç aşamada gerçekleştirilmektedir. Bu aşamalar sırasıyla tur anahtar eklemeye (addRoundKey), yer değiştirme (sBoxLayer) ve permütasyon (pLayer) aşamalarıdır. İlk aşamada tur girdisi olan 64-bit uzunluktaki blok, PRESENT'in anahtar üretme algoritması tarafından üretilen aynı uzunluktaki tur anahtar K_i ($i = 1, 2, \dots, 32$) ile XOR işlemine tabi tutulur. Şekil 1'de Blok ile gösterilen tur girişi veya son tur çıkışı (b_0, b_1, \dots, b_{63}), üretilen i . tur anahtarları $1 \leq i$

≤ 32 için $K_i = (k_0^i, k_1^i, \dots, k_{63}^i)$ olmak üzere, addRoundKey aşğıdaki işlemi gerçekleştirir:

$$(b_0, b_1, \dots, b_{63}) \leftarrow (b_0, b_1, \dots, b_{63}) \oplus (k_0^i, k_1^i, \dots, k_{63}^i). \quad (1)$$

Bir sonraki sBoxLayer aşamasında XOR işleminden çıkan 64 bitlik blok, her biri 4-bit uzunluğunda olan 16 alt bloğa bölünür ve bölünen bu alt bloklardaki her 4-bit (Tablo 1’de onaltılık tabanda verilen) S-kutusunda geçirilerek sBoxLayer aşamasının çıktısı elde edilir. Diğer bir ifadeyle, $0 \leq i \leq 15$ için $\omega_i = (b_{4i}, b_{4i+1}, b_{4i+2}, b_{4i+3})$ olarak tanımlanırsa, 16 alt blok $(\omega_0, \omega_1, \dots, \omega_{15})$ ile gösterilebilir; bu durumda, sBoxLayer aşğıdaki işlemi gerçekleştirir:

$$(b_0, b_1, \dots, b_{63}) \leftarrow (S^b(\omega_0^h), S^b(\omega_1^h), \dots, S^b(\omega_{15}^h)), \quad (2)$$

burada, en soldaki bit en değerli bit olmak üzere, ω_i^h ve $S^b(\omega_i^h)$ sırasıyla ω_i ’nin onaltılık tabandaki ve $S(\omega_i^h)$ ’nin ikili tabandaki karşılıklarını temsil etmektedirler.

Tablo 1. PRESENT algoritmasının 4-bit S-kutusu.

| | | | | | | | | |
|--------|---|---|---|---|---|---|---|---|
| x | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
| $S(x)$ | C | 5 | 6 | B | 9 | 0 | A | D |
| x | 8 | 9 | A | B | C | D | E | F |
| $S(x)$ | 3 | E | F | 8 | 4 | 7 | 1 | 2 |

pLayer aşamasında ise, her $0 \leq i \leq 15$ ve $0 \leq j \leq 3$ değerleri için, permütasyon sonrasında $i + 16j$ pozisyonundaki bit, permütasyon öncesi $4i + j$ pozisyonundaki bit ile aynı olacak şekilde, eşitlik (2) ile elde edilen bloğun bitleri permütasyona uğrar.

Bahsedilen üç aşamanın oluşturduğu tur, 31 kere döngüsel biçimde gerçekleştirildikten sonra, döngü çıkışı Şekil 1’de görüldüğü gibi anahtar algoritmasının ürettiği 32. tur anahtarı (K_{32}) ile XOR edilir ve kapalı metin elde edilmiş olur.

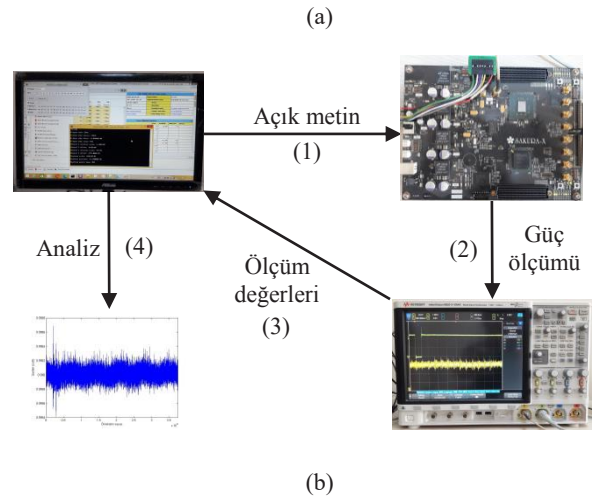

4. Ölçüm düzeneği

Yan kanal analizini yürütmek için gereken güç ölçümlerini almak amacıyla kullandığımız SASEBO-GIII (yan kanal analizi standart değerlendirme kartı) olarak da bilinen SAKURA-X [29], Keysight MSO-X 4104A osiloskop ve bilgisayardan oluşan ölçüm düzeneğimizin görseli, kullanılan cihazların döngüsel olarak tekrar eden çalışma sırası ile birlikte Şekil 2’de gösterilmiştir.

Çalışma döngüsüne girmeden önce, bilgisayar tarafından ölçüm parametreleri (kanal ayarları, tetikleme modu gibi) osiloskopa ve şifrelemede kullanılacak olan gizli anahtar da SAKURA-X kriptografik kartına gönderilir. Gönderilen bu başlangıç parametrelerinden sonra, Şekil 2’de görüldüğü gibi, öncelikle rastgele üretilen bir açık metin bilgisayardan SAKURA-X kartına gönderilir ve şifreleme işlemi hem bilgisayarda hem de kriptografik kartta gerçekleştirilir. SAKURA-X kartında şifreleme gerçekleştiği esnada oluşan güç tüketimi, osiloskop vasıtasıyla ölçülür ve ölçüm değerleri bilgisayara kaydedilir. SAKURA-X kartında şifreleme sonucu elde edilen kapalı metin aynı zamanda bilgisayara gönderilerek, bağımsız olarak bilgisayarın da hesapladığı kapalı metin ile karşılaştırılır. Bu işlem döngüsel olarak kaç adet güç ölçümü isteniyorsa o kadar tekrar edilir.

Ölçüm düzeneğinde kullanılan SAKURA-X kartı Spartan-6 (kontrol FPGA’i) ve Kintex-7 (kriptografik FPGA) olmak üzere iki FPGA içermektedir. Kintex-7 kriptografik algoritmayı


gerçeklemek için kullanılırken, Spartan-6 kriptografik FPGA ile haberleşerek konfigürasyon kontrolünü sağlamaktadır [30]. Deney düzeneğinde, SAKURA-X kartından osiloskop ile ölçüm almak için 50Ω değerindeki SMA-BNC kablo kullanılmaktadır. Bu ölçüm değerleri osiloskop ile 2.5GS/s örnekleme hızında örneklenmekte ve bilgisayara da bu şekilde kaydedilmektedir. Döngüsel olarak çalışan ölçüm düzeneğinden elde edilen güç ölçümlerine, (aşğıdaki bölümde ele alınan) Hamming uzaklığına dayalı KGA uygulanmakta ve (bir sonraki bölümde) bulunan sonuçlar saldırının başarısını ölçen bir metrik olan tahmin entropisi [31] ile değerlendirilmektedir.



Şekil 2. Ölçüm düzeneği (a) görseli, (b) çalışma döngüsü.

5. Korelasyon güç analizi

Kriptografik bir cihaz, şifreleme algoritmasını çalıştırırken algoritmanın kullandığı veriye bağlı olarak güç tüketir. Güç analizi ile yürütülen bir saldırıda, bu güç tüketimleri ölçülerek cihazın kullandığı gizli veri (anahtar) elde edilmeye çalışılır. Özel olarak, en güçlü YKA yöntemlerinden birisi olan KGA saldırısında, güç ölçüm değerleri Hamming ağırlığı veya Hamming uzaklığı gibi güç modelleri kullanılarak tahmin edilir ve bu tahminin gerçek güç ölçümü ile istatistiksel ilişkisine bakılarak kriptografik donanımda kullanılan anahtar ortaya çıkarılmaya çalışılır. Çalışmamızda, Hamming ağırlığı modeline göre daha verimli olan Hamming uzaklığı modeline dayalı KGA yürütülmüştür. Hamming uzaklığı modeli genel olarak herhangi bir şifreleme algoritmasının bir turu gerçekleştiğinde harcanan gücün, o turun girişindeki ve çıkışındaki blokların Hamming uzaklığı ile orantılı olduğu varsayımına dayanır. KGA saldırısı uygulanırken, kriptografik



Şekil 3. Son tur anahtarı için Hamming uzaklık modelinin uygulanması.

donanımdan elde edilen gerçek güç ölçümleri ile bu donanımda işlenen veriden elde edilen güç tüketim tahminleri arasındaki ilişkinin doğrusal olduğu kabul edilir. Bu nedenle, eğer güç tüketim tahminini elde etmek için kullanılan aday anahtar doğru anahtar ise bahsedilen korelasyon en yüksek olur.

PRESENT blok şifreleme algoritmasının son turda kullanılan tur anahtarını elde etmeye çalıştığımızı düşünelim. Hamming uzaklığı ile güç ölçümü tahminini gerçekleştirebilmek için, tur girişini bilmemiz gerekir. Ancak tur girişi kullanılan tur anahtarına bağlı olduğu için, bunu sadece tur anahtarını tahmin ederek yapabiliriz. Bu tahminler arasında doğru tur anahtarı, yukarıda bahsedildiği gibi, gerçek güç ölçümleri ile kullanılan model arasındaki istatistiksel ilişkiye bakılarak bulunmaktadır.

Şekil 3'te gösterildiği gibi, son tur çıkışı olan kapalı metnin ilk dört bitini kullanarak tur anahtarının dört bitini bulmayı hedeflediğimizi varsayalım (saldırının gerçekleşebilmesi için kapalı metni biliyor olmamız gerekmektedir). Kapalı metni $C = (c_0, c_1, c_2, \dots, c_{63})$ ile ve son tur anahtarını $K = (k_0, k_1, k_2, \dots, k_{63})$ ile gösterelim. Kapalı metine pLayer permütasyonunun tersi uygulanarak elde edilen bloğun ilk dört bitini $(c_0, c_{16}, c_{32}, c_{48})$ olur. Bu dört bite, karşılık gelen tur anahtarının dört bitini $(k_0, k_{16}, k_{32}, k_{48})$ XOR işlemi ile eklendiğinde, elde edilen $(c_0 \oplus k_0, c_{16} \oplus k_{16}, c_{32} \oplus k_{32}, c_{48} \oplus k_{48})$ sonucunu veren S-kutusu girişi (S-kutusu dönüşümünün tersi uygulanarak elde edilebilir) son tur girişinin ilk dört bitini verir. Burada bahsedilen dört bitlik tur anahtarını bilmediğimiz için olası bütün adaylar ($2^4 = 16$ tane) tahmin edilir. Bu ise, son tur girişinin ilk dört bitini için 16 tane tahmin yaptığımız anlamına gelmektedir. Son tur çıkışını (kapalı metni) bildiğimizi varsaydıığımızdan, yapılan tahminlerin her birinin kapalı metnin ilk dört bitini olan (c_0, c_1, c_2, c_3) vektörüne Hamming uzaklığı gerçek güç tüketimi için yapılan bir tahmin olmaktadır. Uyguladığımız Hamming uzaklığına dayalı KGA saldırısına göre, bu tahminlerden gerçek güç tüketimleri ile korelasyonu en yüksek olan aday, kullanılan gerçek dört bitlik tur anahtarı olarak elde edilir.

Yan kanal analizinin uygulanacağı kriptografik donanımdan N tane güç ölçümü alındığını ve her bir güç ölçümü için donanımın ürettiği kapalı metinleri bildiğimizi varsayalım. Korelasyon analizini yürütmek için öncelikle kapalı metinlerin her birine karşılık gelen olası bütün güç ölçümü tahminleri yapılır. Örneğin, yukarıda bahsedildiği gibi son tur anahtarının 4 bitini elde edilmek istendiğinde, son tur girişinin 4 bitini için 16 aday olduğundan her bir kapalı metinden

16 güç ölçümü tahmini bulunur. Genel olarak aday sayısına A dersek, $N \times A$ büyüklüğünde bir tahmin matrisi oluşturulur. Bu matris H olsun. Şifreleme süresi boyunca alınan güç ölçümünün B örneklemeden oluştuğunu varsayarsak, donanımdan elde edilen gerçek güç ölçümleri ile de $N \times B$ büyüklüğünde bir başka matris oluşturulur. Bu matrise de T diyelim. Korelasyon analizinde, H matrisin her bir kolonu h_i ($i = 1, 2, \dots, A$) için T matrisinin her bir kolonu t_j ($j = 1, 2, \dots, B$) ile olan korelasyonu aşağıdaki formül ile hesaplanır:


$$R_{i,j} = \frac{\sum_{k=1}^N (h_{k,i} - \bar{h}_i)(t_{k,j} - \bar{t}_j)}{\sqrt{\sum_{k=1}^N (h_{k,i} - \bar{h}_i)^2 \sum_{k=1}^N (t_{k,j} - \bar{t}_j)^2}}, \quad (3)$$

burada \bar{h}_i ve \bar{t}_j , sırasıyla H ve T matrislerin i . ve j . kolonlarının ortalama değerleridir. Verilen denklem ile elde edilen $A \times B$ büyüklüğündeki R matrisi gerçek güç ölçümleri ve Hamming uzaklığı modeli ile tahmin edilen güç ölçümleri arasındaki istatistiksel ilişkiyi veren bir korelasyon matrisidir. R matrisinin her bir satırı tahmin edilen bir anahtar (örneğin, daha önce bahsedilen PRESENT algoritması durumunda son tur anahtarının 4 bitini) için korelasyon profili oluşturur. Doğru tahmin edilen anahtar için bu profil yüksek tepe değerlere sahip olacaktır. Böylelikle hangi tahminin doğru anahtar olduğuna karar verilir.


Bu çalışmada, S-kutuları başvuru tablosu olarak gerçekleştirilmiş ve saldırı başarısını değerlendirmek için YKA karşısındaki dayanıklılığı ölçen bir metrik olan tahmin entropisi kullanılmıştır. Tahmin entropisi, belirli bir sayıda güç ölçümü ile doğru anahtarın elde edilebilmesi için denemesi gereken aday anahtarlarının ortalama sayısını gösteren bir ölçüttür. KGA için bu ölçüt, R matrisinin belirlediği korelasyon profillerine göre denemesi gereken anahtarlar arasında doğru anahtarın kaçınıcı sırada olduğu bulunarak hesaplanır.

6. Bulgular


PRESENT blok şifreleme algoritmasının SAKURA-X tarafından icra edilmesi esnasında bir şifreleme süresince osiloskop ile alınan tipik bir ölçüm sonucu aşağıdaki Şekil 4'te gösterilmektedir. Ölçümlerdeki gürültü miktarını azaltmak ve böylelikle daha sağlıklı sonuçlar elde etmek amacıyla, aynı açık metin ve anahtar için SAKURA-X kartının birden fazla sayıda şifreleme yapması sağlanmış ve her bir şifrelemede tekrar ölçüm alınarak elde edilen ölçümlerinin ortalaması KGA saldırısını yürütmek için kullanılmıştır. Şekil 5'te bahsedildiği gibi elde edilen 30 ölçümünün ortalaması gösterilmektedir.



Şekil 4. PRESENT algoritması için tipik bir ölçüm sonucu.



Şekil 5. PRESENT algoritması için 30 ölçüm ortalaması.




Şekil 6. PRESENT için elde edilen tahmin entropisi.


Şekil 5'ten, ortalama gürültü değerlerinin daha düşük olduğu, bununla birlikte tur zamanlarının halen belirlenemediği ve gürültü etkisinin devam ettiği gözlenmektedir. Her bir güç ölçümü (aynı açık metin ve anahtar için) 30 ölçümün ortalamasından elde edilen 5000 güç ölçümü ile yürüttüğümüz KGA sonucunda elde edilen doğru anahtarın tahmin entropisi

grafığı Şekil 6'da verilmiştir. Şekil 6'dan görüldüğü üzere, 5000 güç ölçümü sonucunda, doğru anahtarı bulmak için denenmesi gereken anahtar sayısı azalmış olmakla birlikte, doğru anahtar elde edilememiştir. Ortalaması alınan ölçümlerinin sayısını 200'e çıkardığımızda bile doğru anahtarın tespit edilemediği gözlenmiştir. Gerçekte bu sonuç, az güç tüketimi nedeniyle, ölçüm sayısını artırarak azaltamadığımız gürültünün, osiloskopun nicemleme hatasından (veya dikey çözünürlüğünün yetersiz kalmasından) kaynaklandığını ve bu hatanın KGA başarısını etkilediğini göstermektedir. Bununla birlikte, nicemleme hatasının olmadığı durumlarda 30 yerine çok daha yüksek sayıda ölçümlerin ortalamaları kullanılırsa, tahmin entropisi grafiğinde daha hızlı bir düşüş beklenebilir.


Bir blok şifreleme algoritmasında kullanılan S-kutusunun büyüklüğünün kriptografik donanımın harcadığı gücü etkileyen bir faktör olduğu bilinmektedir. Bunu test etmek için, S-kutusu büyüklüğü 8-bit olan bir başka şifreleme algoritması AES için de KGA gerçekleştirilmiş ve sonuçlar karşılaştırılmıştır. Şekil 7'de AES algoritmasının bir şifreleme süresince osiloskop ile alınan tipik bir ölçüm sonucu ve Şekil 8'de PRESENT algoritmasında olduğu gibi aynı açık metin ve anahtar için elde edilen 30 ölçümün ortalaması gösterilmektedir. PRESENT için elde edilen ölçümler (Şekil 4 ve Şekil 5) ile karşılaştırıldığında, bu iki şekildeki ölçümlerin nispeten daha az gürültülü oldukları (bir başka deyişle sinyal-gürültü oranının daha yüksek olduğu) ve her iki şekilde de AES algoritmasındaki turların gerçekleşme zamanlarının görülebildiği gözlenmektedir.




Şekil 7. AES algoritması için tipik bir ölçüm sonucu.




Şekil 8. AES algoritması için 30 ölçüm ortalaması.



Şekil 9. AES için elde edilen tahmin entropisi.




Şekil 10. Değiştirilmiş PRESENT için bir ölçüm.



Şekil 11. Değiştirilmiş PRESENT için 30 ölçüm ortalaması.

AES algoritması için de, her bir güç ölçümü (aynı açık metin ve anahtar için) 30 ölçümünün ortalamasında elde edilen 5000 güç ölçümü ile yürüttüğümüz KGA sonucunda bulunan doğru anahtarın tahmin entropisi grafiği Şekil 9'da verilmiştir. Şekil 9'da görüldüğü gibi 1100 güç ölçümünden sonra doğru

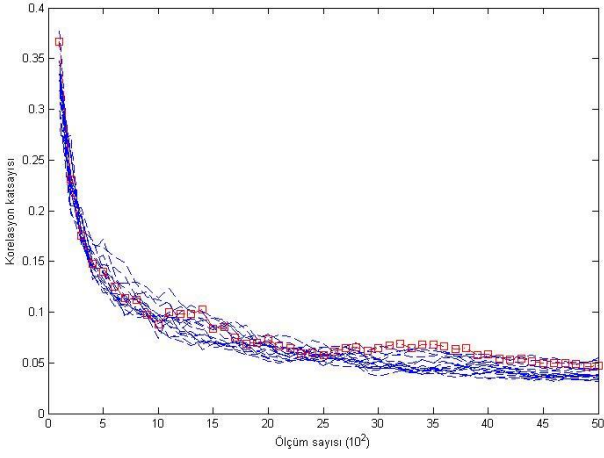
anahtar elde edilmektedir. Bu sonuç, S-kutusu büyüklüğü arttıkça elde edilen güç ölçümlerinin gürültüden daha az etkilenebileceğini doğrulamaktadır. Ayrıca, çalışmamızda bu gerçek, PRESENT algoritmasında kullanılan 16 adet 4x4 büyüklüğündeki S-kutusu yerine 8 adet 8x8 büyüklüğündeki AES S-kutusu kullanılarak da doğrulanmıştır. Şekil 10 ve Şekil 11'de S-kutuları değiştirilmiş PRESENT için sırasıyla tipik bir ölçüm sonucu ve 30 ölçüm ortalaması verilmektedir. Bu ölçümler, orijinal PRESENT algoritması için verilen Şekil 4 ve Şekil 5 ile karşılaştırıldığında, özellikle Şekil 11'de görülen ortalama ölçümde tur işlemini yansıtan tepe değerlerin çok daha net bir şekilde seçilebildiği gözlenmektedir. Gerçekte bu gözlem, devrenin harcadığı gücün arttığı bir göstergesidir. Bahsedilen S-kutusu değişikliği gerçekleştirildiğinde elde ettiğimiz doğru anahtar için tahmin entropisi Şekil 12'de gösterilmektedir. Şekil 12'den görüldüğü gibi, 900 ölçümden sonra doğru anahtar bulunabilmektedir.




Şekil 12. Değiştirilmiş PRESENT için tahmin entropisi.

Şekil 7 ve Şekil 8'de AES için elde edilen güç ölçümleri ile karşılaştırıldığında ise, değiştirilmiş PRESENT algoritmasının her tur için kullandığı S-kutusu sayısı daha az olması nedeniyle, Şekil 10 ve Şekil 11'e göre tur geçişleri AES için daha belirgin görülmektedir. Bununla birlikte, KGA saldırısında 64 bitlik şifreleme yapan PRESENT algoritmasında tur anahtarının 1/8'i kullanılırken, 128 bitlik şifreleme yapan AES algoritmasında tur anahtarının 1/16'sı kullanılmaktadır. Bu nedenle, Hamming uzaklığı modeline göre yapılan güç tahmininin PRESENT için güç ölçümüne daha iyi bir yaklaşımlama yaptığı ve böylelikle daha az sayıda güç ölçümü kullanılarak doğru anahtarın tespit edilebildiği sonucuna varılabilir.


Doğru anahtar, aday anahtarların tahmin entropilerine bakılarak belirlenebileceği gibi elde edilen korelasyon profillerine bakılarak da belirlenebilir. Bir önceki bölümde (3) eşitliği ile verilen korelasyon matrisi R , PRESENT, AES ve S-kutuları değiştirilmiş PRESENT algoritmaları için hesaplanarak, tüm aday anahtarların korelasyon profilleri sırasıyla Şekil 13, Şekil 14 ve Şekil 15'te sunulmuştur. Bu üç şekilde de doğru anahtarın korelasyon değerleri kırmızı renkte gösterilmiştir. AES ve S-kutuları değiştirilmiş PRESENT için verilen Şekil 14 ve Şekil 15'te doğru anahtarın korelasyon değerleri en yüksektir ve kolaylıkla belirlenebilmektedir. Buna karşın PRESENT için verilen Şekil 13'te bu durumun gerçekleşmediği ve dolayısıyla doğru anahtarın tespitinin zorlaştığı görülmektedir.



Şekil 13. PRESENT için korelasyon profilleri.




Şekil 14. AES için korelasyon profilleri.



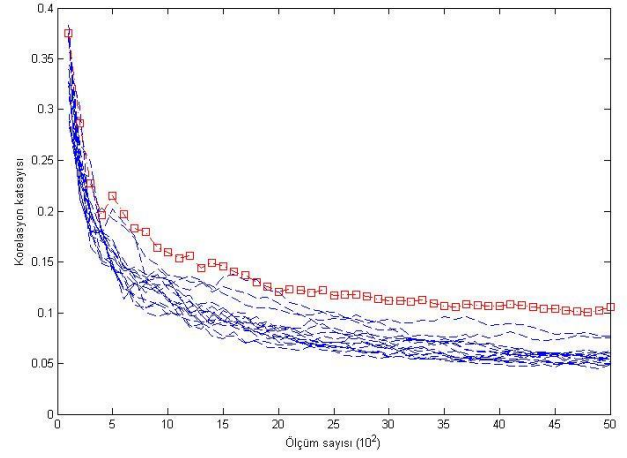
Şekil 15. Değiştirilmiş PRESENT için korelasyon profilleri.

Son olarak, PRESENT algoritması için gerçek güç ölçümleri kullanılmaksızın, MATLAB ortamında güç ölçümlerinin benzetimi ile KGA uygulanmıştır. Kriptografik donanımda oluşan gürültü, benzetimde toplanır Gauss gürültüsü olarak modellenmiştir. Bu benzetimi gerçekleyen

MATLAB kodu [32]'de verilmektedir. Örneğin gürültü varyansı 4 olarak alındığında, kodun çalıştırılması ile elde edilen tahmin entropisi grafiği ve korelasyon profilleri sırasıyla Şekil 16 ve Şekil 17'te verilmektedir. Bu grafiklerin her ikisinden de doğru anahtarın tespit edilebildiği açıkça görülmektedir.



Şekil 16. PRESENT için benzetim sonucu tahmin entropisi.



Şekil 17. PRESENT için benzetim sonucu korelasyon profilleri.

7. Sonuç

Bu çalışmada, PRESENT blok şifreleme algoritmasının SAKURA-X kriptografik kartı üzerinde FPGA gerçekleştirilmesi yapılarak, en etkili YKA yöntemlerinden birisi olan KGA bu donanımsal gerçeklemeye uygulanmıştır. Bunun sonucunda, az güç tüketiminin neden olduğu sinyal-gürültü oranının azalmasına bağlı olarak, doğru anahtarın tespitinin zorlaştığı görülmüştür. S-kutusu büyüklüğünün elde edilen sonuçlara etkisini gözlemlemek için, PRESENT algoritmasının 4x4 büyüklüğündeki S-kutusu yerine AES algoritmasının 8x8 büyüklüğündeki S-kutusu kullanılmış ve bu durumda doğru anahtarın tespit edilebildiği gösterilmiştir. Ayrıca bulunan sonuçlar, PRESENT için MATLAB benzetimi ve AES için SAKURA-X kartı üzerinde gerçekleştirilmesi ile elde edilen güç ölçümlerinin kullanıldığı KGA sonuçları ile karşılaştırılmıştır.

Kaynakça

- [1] A. Bogdanov, L. R. Knudsen, G. Leander, C. Paar, A. Poschmann, M. J. B. Robshaw, Y. Seurin, C. Vikkelsoe. PRESENT: An ultra-lightweight block cipher. In: *Cryptographic Hardware and Embedded Systems - CHES 2007*, LNCS, vol. 4727, pp. 450-466, Springer, 2007.
- [2] ISO. ISO/IEC 29192-2:2012 Information technology - Security techniques - Lightweight cryptography - Part 2: Block ciphers. URL: <https://www.iso.org/standard/56552.html> (Erişim tarihi: 10, 19, 2022)
- [3] P. Kocher. Timing attacks on implementations of Diffie-Hellmann, RSA, DSS, and other systems. In: *Advances in Cryptology - CRYPTO'96*, LNCS, vol. 1109, pp.104-113, Springer, 1996.
- [4] P. Kocher, J. Jaffe, B. Jun. Differential power analysis. In: *Advances in Cryptology - CRYPTO'99*, LNCS, vol. 1666, pp. 388-397, Springer, 1999.
- [5] B. Gierlichs, L. Batina, P. Tuyls, B. Preneel. Mutual information analysis. In: *Cryptographic Hardware and Embedded Systems - CHES 2008*, LNCS, vol. 5154, pp. 426-442, Springer, 2008.
- [6] E. Brier, C. Clavier, F. Olivier. Correlation power analysis with a leakage model. In: *Cryptographic Hardware and Embedded Systems - CHES 2004*, LNCS, vol. 3156, pp. 16-29 Springer, 2004.
- [7] O. Lo, W. J. Buchanan, D. Carson. 2016. Power analysis attacks on the AES-128 S-box using differential power analysis (DPA) and correlation power analysis (CPA). *Journal of Cyber Security Technology*, 1(2):88-107, 2016.
- [8] J. Doget, E. Prouff, M. Rivain, F.-X. Standaert. Univariate side channel attacks and leakage modeling. *Journal of Cryptographic Engineering*, 1(2):123-144, 2011.
- [9] A. Moradi, N. Mousavi, C. Paar, M. Salmasizadeh. A comparative study of mutual information analysis under a Gaussian assumption. In: *Information Security Applications - WISA 2009*, LNCS, vol. 5932, Springer, 2009.
- [10] S. Nikova, C. Rechberger, V. Rijmen. Threshold implementations against side-channel attacks and glitches. In: *Information and Communications Security - ICICS 2006*, LNCS, vol. 4307, pp. 529-545 Springer, 2006.
- [11] T. De Cnudde, O. Reparaz, B. Bilgin, S. Nikova, V. Nikov, V. Rijmen. Masking AES with $d+1$ shares in hardware. In: *Cryptographic Hardware and Embedded Systems - CHES 2016*, LNCS, vol. 9813, pp. 194-212 Springer, 2016.
- [12] T. Güneysu, A. Moradi. Generic side-channel countermeasures for reconfigurable devices. In: *Cryptographic Hardware and Embedded Systems - CHES 2011*, LNCS, vol. 6917, pp. 33-48, Springer, 2011.
- [13] S. Mangard, E. Oswald, T. Popp. *Power analysis attacks: revealing the secrets of smart cards*, Springer, US, 2007.
- [14] E. Biham, A. Shamir. Differential cryptanalysis of DES-like cryptosystems. *Journal of Cryptology*, 4(1):3-72, 1991.
- [15] M. Matsui. M. Linear cryptanalysis method for DES cipher. In: *EUROCRYPT'93*, LNCS, vol. 765, pp. 386-397, Springer, 1994.
- [16] M. Renaud, F.-X. Standaert. Algebraic side-channel attacks. In: *Information Security and Cryptology - Inscrypt 2009*. LNCS, vol. 6151, pp. 393-410, Springer, 2010.
- [17] L. Yang, M. Wang, S. Qiao. Side channel cube attack on PRESENT. *Cryptology and Network Security - CANS 2009*, LNCS, vol. 5888, pp. 379-391, Springer, 2009.
- [18] X.-J. Zhao, T. Wang, S.-Z. Guo. Improved side channel cube attacks on PRESENT. *Cryptology ePrint Archive*, URL: <https://eprint.iacr.org/2011/165> (Erişim tarihi: 10, 19, 2022).
- [19] X. Duan, Q. Cui, S. Wang, H. Fang, G. She. Differential power analysis attack and efficient countermeasures on PRESENT. In: *Proceedings of the 8th IEEE International Conference on Communication Software and Networks - ICCSN 2016*, pp. 8-12, IEEE, 2016.
- [20] R. Sadhukhan, S. Patranabis, A. Ghoshal, et al. An evaluation of lightweight block ciphers for resource-constrained applications: area, performance, and security. *Journal of Hardware and Systems Security*, 1:203-218, 2017.
- [21] L. Goubin, A. Martinelli, M. Walle. Impact of Sboxes size upon side channel resistance and block cipher design. In: *Progress in Cryptology - AFRICACRYPT 2013*, LNCS, vol. 7918, pp 240-259, Springer, 2013.
- [22] C. Carlet, E. de Chérisey, S. Guilley, S. Kavut, D. Tang. Intrinsic resiliency of s-boxes against side-channel attacks best and worst scenarios. *IEEE Transactions on Information Forensics and Security*, 16:203-218, 2021.
- [23] A. Heuser, S. Picok, S. Guilley, N. Mentens. Lightweight ciphers and their side-channel resilience. *IEEE Transactions on Computers*, 69(10):1434-1448, 2020.
- [24] J. Zhang, D. Gu, Z. Guo, L. Zhang. Differential power cryptanalysis attacks against PRESENT implementation. In: *Proceedings of the 3rd International Conference on Advanced Computer Theory and Engineering - ICACTE 2010*, vol. 6, pp. 61-65, IEEE, 2010.
- [25] C. Wang, M. Yu, J. Wang, P. Jiang, X. Tang. A more practical CPA attack against PRESENT hardware implementation. In: *Proceedings of the 2nd International Conference on Cloud Computing and Intelligence Systems - CCIS 2012*, pp. 1248-1253, IEEE, 2012.
- [26] O. Lo, W. J. Buchanan, D. Carson. Correlation power analysis on the PRESENT block cipher on an embedded device. In: *Proceedings of the 13th International Conference on Availability Reliability and Security - ARES 2018*, pp. 6-11, ACM, 2018.
- [27] Q. Fang, M. Alioto. Last-round and joint first/last-round power analysis attacks on PRESENT. In: *Proceedings of Asian Hardware Oriented Security and Trust Symposium - AsianHOST 2021*, pp. 1-6, IEEE, 2021.
- [28] N. A. Gunathilake, A. Al-Dubai, W. J. Buchanan, O. Lo. Electromagnetic side-channel attack resilience against PRESENT lightweight block cipher. In: *6th International Conference on Cryptography, Security and Privacy (CSP)*, pp. 51-55, IEEE, 2022.
- [29] SAKURA (SASEBO-GIII). URL: <https://satoh.cs.uec.ac.jp/SAKURA/hardware/SAKURA-X.html> (Erişim tarihi: 10, 19, 2022).
- [30] Y. Hori, T. Katashita, A. Sasaki, A. Satoh. SASEBO-GIII: A hardware security evaluation board equipped with a 28-nm FPGA. In: *Proceedings of the 1st IEEE Global Conference on Consumer Electronics*, pp. 657-660, IEEE, 2012.
- [31] F.-X. Standaert, T. G. Malkin, M. Yung. A unified framework for the analysis of side-channel key recovery attacks. In: *Advances in Cryptology - EUROCRYPT 2009*, LNCS, vol. 5479, pp 443-461, Springer, 2009.
- [32] GitHub. URL: https://github.com/Selcuk-kripto/cpa_present (Erişim tarihi: 10, 19, 2022).

Özgeçmişler



Selçuk Kavut, Ankara Üniversitesi Elektronik Mühendisliği Bölümü'nden lisans derecesini 1998 yılında, Orta Doğu Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik ve Elektronik Mühendisliği Anabilim Dalı'ndan yüksek lisans ve doktora derecelerini sırasıyla 2002 ve 2008 yıllarında almıştır. 2009-2014 yılları arasında Gebze Yüksek Teknoloji Enstitüsü'nde Öğr. Gör. Dr. olarak çalıştıktan sonra Balıkesir Üniversitesi'ne geçmiş olup, halen Bilgisayar Mühendisliği Bölümü'nde Doç. Dr. olarak çalışmaktadır. Çalışma alanları kriptoloji ve kodlama teorisi üzerinedir.



Yasin Reşit Yargıcı, lisans ve yüksek lisans derecelerini Balıkesir Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü'nden 2014 ve 2019 yıllarında almıştır. Özel sektörde ARGE uzmanı olarak çalışmaktadır. Çalışma alanları otomasyon, güç elektroniği ve kriptoloji alanlarıdır.

Akıllı Şebeke Uygulamalarında Derin Öğrenme Tekniklerinin Kullanımına İlişkin Kısa Bir İnceleme

A Brief Review on the Use of Deep Learning Techniques in Smart Grid Applications

 Reyhan Sağ Örnek¹, Zeynep Hasırcı Tuğcu² 

¹Elektrik-Elektronik Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
reyhansag@ktu.edu.tr

²Elektronik ve Haberleşme Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
zhasirci@ktu.edu.tr

Öz

Akıllı şebeke, elektrik şebekesinden yüksek boyutlu ve çeşitli yapılarıdaki verilerin sürekli olarak toplanması ve anlamlandırılması ile enerjinin üretiminden son kullanıcıya ulaşmasına kadar olan süreçlerin optimum şekilde yönetilmesi esasına dayanır. Bu nedenle çağın gereklerine uygun gelişmiş ölçüm altyapısının, kontrol teknolojilerinin ve bilgi ve iletişim teknolojilerinin şebekeye entegrasyonu oldukça önemli bir konudur. Fakat, geleneksel modelleme, optimizasyon ve kontrol teknolojilerinin şebeke üzerinden toplanan verilerin işlenmesinde bazı sınırlamaları bulunmaktadır. Bu nedenle, son zamanlarda akıllı şebekede derin öğrenme tekniklerinin kullanımı daha popüler hale gelmektedir. Bu çalışmada bazı yaygın derin öğrenme tekniklerinin akıllı şebekelerdeki kullanımına ilişkin yapılan mevcut araştırmaların yapılandırılmış bir incelemesi sunulmaktadır. İncelemede, özellikle yük tahmini ve kestirimi, mikro şebeke, talep yanıtı, hata tespiti ve durum tahmini, güç sistemi analizi ve kontrolü, siber güvenlik ve yenilenebilir enerji üretimi gibi akıllı şebeke problemlerine odaklanılmış ve ilgili literatür sunulmuştur. Bu çalışma, derin öğrenme teknikleri uygulamalarının hem akıllı şebeke sistemlerinde giderek artan oranda yer alacağını hem de şebekenin güvenilirliğini, güvenliğini ve dayanıklılığını iyileştirmede önemli katkılar sağlayacağını göstermektedir.

Anahtar Kelimeler: akıllı şebeke, yapay zeka, makine öğrenmesi, derin öğrenme

Absract

The smart grid is based on the principle of continuous collection and interpretation of high-dimensional and diverse data from the electricity grid, and optimum management of the processes from the generation of energy to its delivery to the end user. Therefore, the integration of advanced measurement infrastructure, control technologies, and information and communication technologies into the network is a quite crucial issue. However, traditional modeling, optimization, and control technologies have some limitations in processing data

collected over the grid. Therefore, the use of deep learning techniques in the smart grid is becoming more popular lately. In this study, a brief review of current research on the use of some common deep learning techniques in smart grids is presented. The review focuses on smart grid problems such as load forecasting and estimation, microgrid, demand response, fault detection and state prediction, power system analysis and control, cyber security and renewable energy generation, and related literature is presented. This study shows that the applications of deep learning techniques will be increasingly involved in smart grid systems and will make significant contributions to improving the reliability, security, and durability of the grid.

Keywords: Smart grid, artificial intelligence, machine learning, deep learning

1.Giriş

Akıllı şebekeler, geleneksel elektrik güç şebekesini elektromekanik olarak kontrol edilen bir sistemden elektronik olarak kontrol edilen bir şebekeye dönüştürmektedir. Elektrik şebekesi genel olarak birçok farklı alt bileşenden oluşan dinamik bir sistemdir. ABD Enerji Bakanlığı'nın Akıllı Şebeke Sistemi Raporuna [1] göre, akıllı şebeke sistemleri, bilgi yönetimi, kontrol teknolojileri, dijital tabanlı algılama, iletişim teknolojileri ve birden fazla elektriksel işlem sürecini koordine etme işlevi gören saha cihazlarından ve teknolojilerinden oluşmaktadır. Bu teknolojiler, temel olarak süreçleri izleme veya ölçme, verileri operasyon merkezlerine geri iletme ve genellikle bir süreci ayarlamak için otomatik olarak yanıt verme; cihazlar ve sistemler arasında veri paylaşımı ve operatörlerin şebeke genelinde dijital teknolojilerden gelen verilere erişmesi ve bunları uygulamasına yardımcı olmak, işlemek, analiz etmek ve yardımcı olmak gibi adımları içermektedir.

Akıllı şebekelerin gelişmesiyle birlikte enerjide sürdürülebilirliğe katkısı açısından oldukça önemli yere sahip olan rüzgar ve güneş enerjisi gibi yenilenebilir enerji

kaynaklarının üretimdeki değişken profilleri ve güç sistemine giderek artan oranda dahil oluşları; son kullanıcının yani müşterinin talep tarafı yönetimine ve üretimdeki aktif katılımı ile geleneksel şebeke yapısından daha belirsiz ve daha karmaşık bir yapı meydana gelmiştir. Ayrıca akıllı şebekelerdeki yük tahmini, güç şebekesi kararlılık değerlendirmesi, arıza tespiti ve şebeke güvenliğinin sağlanması da bir takım belirsizlikleri ve zorlukları da beraberinde getirmiştir. Belirsiz ve karmaşık bir ortamda, büyük ölçekli güç sistemlerinin güvenli ve istikrarlı bir şekilde çalışmasını sağlamak için kullanılan geleneksel yöntemler, bazı varsayımlara ve basitleştirmelere göre oluşturulmuştur. Ancak, güç sistemi kararlılık problemlerinin karmaşıklığı, belirsizlikler ve davranışta doğrusal olmama durumları, bu geleneksel yöntemlerin içerdiği fiziksel modelleri pratik ve uygulanabilir olmaktan çıkarıp hatalı ve uygulaması eksik bir duruma sokmaktadır [2]. Aynı zamanda bu sorunlar, elektrik enerjisi şebekeleri hakkında büyük miktarlarda yüksek boyutlu ve çok tipli verilerin toplanmasını ve işlenmesini gerektirmektedir. Burada geleneksel modelleme yöntemleri sahip olduğu sınırlamalardan dolayı, akıllı şebekelerin gelecekteki gelişiminin doğurduğu gereksinimlerini karşılayamama; belirsizlik ve kısmi gözlemlenebilirlik konularını ele aldığında ise bu veri kümelerini işlemede zorluk yaşama gibi kısıtlılıklar yaşamaktadır.

Bu durumlar ele alındığında akıllı şebekede geleneksel yöntemlerden ziyade derin öğrenme (*Deep Learning, DL*), pekiştirmeli öğrenme (*Reinforcement Learning, RL*) ve derin pekiştirmeli öğrenme (*Deep Reinforcement Learning, DRL*) gibi yapay zeka Artificial Intelligence, AI) tekniklerinin kullanımının karar ve kontrol problemlerini çözmede, talep yanıtı (*Demand Response, DR*) ile müşterileri yükü yoğun dönemlerden yoğun olmayan sürelerle kaydırmada veya yoğun saatlerde elektrik kullanımlarını azaltmada, ekipman denetimi ve görüntüleme, kötü niyetli saldırılar, yanlış veri istilaları ve elektrik hırsızlığı gibi anormalliklerin tespitinde daha uygun ve etkin çözümler olduğu düşünülmektedir [2][3].


2. Temel bilgiler

DL, insanların belirli bilgi türlerini kazanma şeklini taklit eden bir tür makine öğrenimi ve yapay zeka olup, istatistik ve tahmine dayalı modellemeyi içeren veri biliminin önemli bir unsurudur. Büyük miktarda veriyi toplamak, analiz etmek ve yorumlamakla görevli veri bilimcileri için son derece faydalı olan derin öğrenme, bu süreçleri çok daha hızlı, pratik ve kolay hale getirmektedir.

2.1. Gözetimli öğrenme

Denetimli makine öğrenimi olarak da bilinen gözetimli öğrenme, makine öğrenimi ve yapay zekanın bir alt kategorisidir. Verileri sınıflandırmak veya sonuçları doğru bir şekilde tahmin etmek için algoritmaları eğitmek için etiketlenmiş veri kümelerinin kullanılmasıyla tanımlanır. Girdi verileri modele beslendiğinde, çapraz doğrulama sürecinin bir parçası olarak gerçekleşen model uygun şekilde çalışana kadar ağırlıklarını ayarlar. Denetimli öğrenme, modellere istenen çıktıyı verecek şekilde öğretmek için bir eğitim seti kullanır. Bu eğitim veri seti, modelin zaman içinde öğrenmesini sağlayan girdileri ve doğru çıktıları içerir. Algoritma, hata yeterince minimize edilene kadar ayar yaparak, kayıp fonksiyonu aracılığıyla doğruluğunu ölçer.


Gözetimli öğrenmede kullanılan sınıflandırma teknikleri K-en yakın komşu algoritması (*K-Nearest Neighbor, KNN*), destek vektör makinesi (*Support Vector Machine, SVM*) ve karar ağacı (*Decision Tree, DT*) olup Şekil 1’de gösterilmektedir.



Şekil 1. Gözetimli öğrenmede kullanılan bazı sınıflandırma teknikleri

2.1.1. Derin öğrenme

DL, çok katmanlı bir yapay sinir ağı (*Artificial Neural Network, ANN*) kaynaklı makine öğreniminin bir alt kümesidir. Her ne kadar DL denilince sadece büyük bir derin sinir ağı, yani derin sinir ağları düşünülse de gerçekte çok daha geniş bir anlama sahiptir. Buradaki derin ifadesi, tipik olarak katman sayısını ifade etmektedir. DL' nin Şekil 2’de gösterildiği gibi Boltzman makinesi (*Boltzman Machine, BM*), derin inanç ağları (*Deep Belief Network, DBN*), ileri beslemeli sinir ağları (*Feedforward Neural Network, FDN*), evrimsel sinir ağları (*Convolutional Neural Network, CNN*), özyinelemeli sinir ağı (*Recurrent Neural Network, RNN*), uzun kısa süreli bellek (*Long Short-Term Memory, LSTM*) ve çekişmeli üretici ağı (*Generative Adversarial Networks, GAN*) gibi farklı yapıları vardır. Bunlar arasında uzamsal dağılım verileriyle ilgilenmek için uygun olan CNN ve zaman serisi verilerini yönetmede avantajlara sahip olan RNN en popüler yapılardandır.



Şekil 2. Derin öğrenme teknikleri


2.2. Gözetimsiz Öğrenme

Gözetimsiz öğrenme, etiketlenmemiş veri kümelerini analiz etmek ve kümelemek için insan müdahalesine ihtiyaç duymadan verileri sınıflandıran yapay öğrenme algoritmalarını kullanır. Burada gözlemlenen birimler benzer özelliklerine göre bir araya getirilir ve çıktılar çalışmanın içinde bulunmazlar.

2.3. Pekiştirmeli Öğrenme

RL temel olarak araç, ortam, ödül ve eylem olmak üzere dört temel bileşenden oluşup, temsilcinin dinamik bir ortama yanıt olarak bir dizi eylemde bulunarak ödülü en üst düzeye çıkarmasını amaçlamaktadır. Tipik bir RL algoritması,

yalnızca sınırlı çevre bilgisi ve kararların kalitesi hakkında sınırlı geri bildirim ile çalışır ve belirsizlik altında sıralı karar vermeyi destekleyebilmektedir. Şekil 3'te gösterildiği üzere Q-öğrenme, durum-eylem-ödül-durum-eylem (State-Action-Reward-State-Action, SARSA), derin Q net (Deep Q-Learning, DQN) ve derin deterministik politika gradyanları (Deep Deterministic Policy Gradient, DDPG) ise RL'nin en popüler algoritmalarından olup, normalize avantaj fonksiyonu (Normalized Advantage Functions, NAF) ve asenkron aktör-kritik ajanlar (Asynchronous Advantage Actor-Critic, A3C) gibi daha gelişmiş algoritmaları da mevcuttur [4][5]. Robotik, oyun ve navigasyon ise RL'nin en sık rastlanan uygulama alanlarından.



Şekil 3. Pekiştirmeli öğrenme teknikleri

2.4. Derin pekiştirmeli öğrenme

DL ile RL'nin birleşimi, DL algısını ve RL'nin karar vermesini birleştiren DRL adı verilen yeni bir araştırma alanına yol açmıştır. Bu nedenle, DRL hem yüksek boyutlu ham girdilerin zengin içeriğini hem de sistem kontrolünü gerektiren çeşitli görevleri uygulayabilmektedir [6]. DRL uygulamaları ile ilgili birçok araştırma halen yürütülmektedir. Örneğin, Google, kapıları açmak ve nesnelere kendi başlarına almak üzere robotik kolları eğitmek için DRL'den yararlanmaktadır. Başka bir örnek olarak Uber, Grand Theft Auto'ya gerçek yollarda gerçek arabaları kullanmayı öğretmek için yine DRL'yi kullanmaktadır. Makine öğreniminin temel algoritmaları olan DL ve RL, akademik araştırmalarda uzun yıllardır kullanılmış olsa da uygulama odaklı araştırmalar için yani endüstriyel sahaya ancak son zamanlarda girmeye başlamıştır. Son yıllarda oldukça popüler bir araştırma konusu haline gelmesinin başlıca nedenleri ise veri miktarının bir hayli artması, gelişmiş yapay zeka algoritmalarının ve güçlü bilgisayar donanımının ortaya çıkmasıdır.

3. Literatür araştırması

Akıllı şebekelerdeki DL, RL ve DRL tabanlı uygulamaları kapsayan birçok çalışma mevcuttur.



Şekil 4. Akıllı şebeke alt katmanları

Bu uygulama alanları ise Şekil 4'te gösterildiği gibi akıllı şebekelerin neredeyse tüm katmanlarını ve amaçlarını içermektedir.

3.1. Yük tahmini ve kestirimi

Güneş ve rüzgar enerjisi vb. yenilenebilir enerji kaynaklarının şebekedeki varlıklarının her geçen gün etkin bir şekilde artması, güç sistemlerinin işletilmesinde, kontrolünde ve arz-talep planlamasında birtakım zorlukları da beraberinde getirmektedir. Bu nedenle, farklı gerilim seviyelerindeki enerji taleplerinin doğru tahmin edilmesi oldukça önemli bir hale gelmiştir. Elektrik yükü yani enerji talebi tahmini için birçok yöntem olmasına rağmen, bunların çoğu akıllı sayaçların sağladığı büyük hacimli verilerinden ziyade daha küçük veri kümelerini kullanmışlardır. Akıllı şebekelerde yük tahmini ve kestirimi ile ilgili literatürdeki çalışmalar Tablo 1'de özetle verilmiştir [7-39]. [7]'de çeşitli istatistiksel ve AI modelleri kullanılarak belirli bir bölgenin yük tahmini doğruluğu iyileştirilmeye çalışılmıştır. Burada, farklı sayıda gizli katmanın seçildiği ileri beslemeli bir sinir ağı kullanılmıştır. Seçilen gizli katman sayısı arttıkça, eğitimin daha uzun sürdüğü ve fazladan uyum riskinin arttığı gözlemlenmiş, öte yandan da tahmin doğruluğunun arttığı da gösterilmiştir. Sonuç olarak 100 gizli katmanın en iyi seçim olduğu kararı verilmiştir.

Bir DL algoritmasını diğer yöntemlerle birleştirerek daha etkili çözümler elde etmek birçok durumda tercih edilmektedir. Akıllı şebeke kapsamında özellikle yük tahmini için bu tür ortak yöntemler çokça tercih edilmiştir. [8]'de, ilk olarak elektrik yüklerinin saatlik tahmini için CNN ve K-Means algoritmaları birlikte kullanılmıştır. Burada, K-Means algoritması ile çok fazla yük kaydı içeren büyük veri kümeleri alt kümelere bölünmüş, elde edilen bu alt kümeler ise CNN'yi eğitmek için kullanılmıştır. Diğer bir çalışma [9] olarak ise gün öncesi yük tahmini için derin inanç ağları (Deep Belief Network, DBN) uygulanmıştır. Deneysel sonuçlar ile de önerilen yöntemlerin etkili olduğunu gösterilmiştir. [10]'da ABD'de bir kentsel alandaki bir yıllık veriler kullanılarak saatlik yük tahmininde gömülü bir DNN önerilmiştir. Deneysel sonuçlar, önerilen yöntemin klasik ANN, destek vektör regresyonu (Support Vector Regression, SVR) ve aşırı öğrenme makinelerinden (Extreme Learning Machines, ELM) daha doğru tahminler verebildiğini göstermiştir.

Binalardaki talep tahmini, bölgesel olarak yük tahmininde ve talep yanıtının gerçekleştirilmesinde oldukça önemli bir konudur. Bina ve sitelerdeki enerji tüketimi verileri akıllı sayaçlar ile toplanarak DL tabanlı yük/talep tahmini yapılabilmektedir. [11] ve [12]'de binalardaki yük tahmini için koşullu kısıtlı Boltzmann makineleri (Restricted Boltzmann Machines, CRBM) ve faktörlü koşullu sınırlı Boltzmann makineleri (Factored Conditional Restricted Boltzmann Machines, FCRBM) yöntemleri kullanılmıştır. [13]'te ise bir saat ve bir dakikalık zaman adımlı yükleri tahmin etmek için LSTM tabanlı sinir ağı mimarisi önerilmiştir. Çalışma, standart bir LSTM mimarisinin bir dakikalık yükü doğru bir şekilde tahmin edemediğini gösterirken, Seq2Seq LSTM tabanlı mimarinin her iki durumda da mükemmel performans sağladığını ifade etmiştir. [14]'te bina düzeyinde yük tahmini için tarihsel yüklere dayalı olarak CNN kullanılmıştır. CNN'den elde edilen sonuçlar, aynı veri seti için S2S tabanlı LSTM, FCRBM, ANN ve SVM tarafından elde edilenlerle karşılaştırılmıştır. Sonuç olarak,

CNN, ANN ve DL metotları SVM' den daha iyi performans göstermişlerdir.

Hava durumu, enerji tüketimi üzerinde doğrudan bir etkiye sahip olduğundan, hava durumu verilerini öğrenme algoritmaları ile yorumlamak oldukça önemlidir. [15]' te hava tahmini sayısal benzetimi ile enerji tüketimini ve güç üretimini tahmin etmek için DL kullanılmıştır. Önerilen yöntem ve başarımı, üniversite kampüsü içinde inşa edilmiş küçük ölçekli merkezi olmayan bir sistem üzerinde doğrulanmıştır. [16]' da akıllı sayaç verilerine dayalı olarak kısa vadeli yük tahmini için DNN ve diğer makine öğrenimi teknikleri uygulanmıştır, [17] ve [18]' de ise yük tahmini için DBN yöntemi kullanılmıştır.

Genellikle kısa vadeli yük tahmininde, sonraki bir saat ile sonraki iki hafta arasındaki yük tahmin edilir. [19]' da, güç sisteminin güç talebinde büyük penetrasyonlar yüksek belirsizliğe yol açtığı için elektrikli araçların şarj yükü tahmin edilmeye çalışılmış ve eklentili elektrikli araçların yük tahmini için YSA ve LSTM tabanlı DL yaklaşımları kullanılmıştır. Hem geleneksel YSA yaklaşımını hem de LSTM yaklaşımını karşılaştırmak için bir şarj istasyonu şirketi kullanılmıştır. LSTM modelinin kısa vadeli elektrikli aracın yük tahmininde daha düşük hatalara ve daha yüksek doğruluğa sahip olduğu gözlemlenmiştir. [20]' de yük dizilerinin büyük zaman aralığı yarı periyodikliği incelenmiş ve otomatik gerileyen entegre hareketli ortalama (*Auto-Regressive Integrated Moving Average*, ARIMA) ile LSTM' yi birleştiren bir yöntem geliştirilmiştir. Bu yöntem, 737 haftalık yük tüketimi veri seti üzerinde değerlendirilmiş ve bu modelin popüler yük tahmini modellerine göre üstün olduğu gözlemlenmiştir. Akıllı şebekelerde dağıtık üretimin yaygın kullanımı, yük tahmininin doğruluğu oldukça önemli bir ihtiyaç haline gelmiştir. Bunu ele almak için, [21] çalışması ile sıralı güncelleme (*Rolling Update*, RU), dikkat mekanizması (*Attention Mechanism*, AM) ve iki yönlü uzun kısa süreli belleğe (*Bi-Directional Long Short-Term Memory*, Bi-LSTM) dayalı bir yöntem önerilmiştir. Farklı ülkelerden alınan gerçek veri setleri üzerinde çalışmalar yapılmış ve bu yöntemin hem daha yüksek doğruluğa sahip olduğu hem de diğer modellere göre daha az hesaplama süresi gerektirdiği kanıtlanmıştır.

Kısa vadede yük tahminini daha da geliştirmek için [22]' deki çalışmada, eğitim sırasında hem torbalamayı hem de güçlendirmeyi birleştiren YSA modeli verilmiştir. Bu model, YSA'ların paralel eğitim topluluklarından oluşmuş olup, her topluluk, sırayla eğitilen YSA'ların bütünü olarak değerlendirilmiştir. Gerçek veriler üzerinde yapılan istatistiksel analiz için bu modelin tekli YSA, torbalı YSA ve güçlendirilmiş YSA'dan daha düşük yanlılığa, varyansa ve tahmin hatasına sahip olduğunu göstermiştir. [23]' te YSA kullanılarak bir bölge binasında saat öncesi ve gün öncesi yük tahmini için bir çalışma sunulmuştur. Bu YSA'lar Levenberg-Marquardt (LM) ve Bayesian Regularization (BR) öğrenme algoritmalarını kullanarak oluşturulmuştur. Modelin hem gün öncesi hem de saat öncesi tahmin açısından farklı binalar üzerinde incelenmesi sonucunda, saat öncesi tahminlerin nispeten daha iyi performans verdiği görülmüştür. RNN'ler yük tahmininde iyi bir performansa sahip olsalar da tahmin edilen bir gelecek gizli durum vektörünü veya geçmiş bilgileri tam olarak kullanamazlar. Bu sorunun giderilmesi için, [24]' te RNN ve bir boyutlu CNN (*One-Dimensional CNN*, 1D-CNN) nin bir kombinasyonu olan tekrarlayan başlangıçlı bir CNN önerilmiştir. Deneyler, bu modelin günlük elektrik yükü tahmininde çok katmanlı algılayıcı sinir ağı (*Multi Layer Perceptron Artificial Neural Network*, MLP-NN), RNN ve

1D-CNN'den daha iyi performans gösterdiğini ispatlamıştır. Kısa vadeli elektrik yükü tahmininde SVR yaklaşımının yüksek hesaplama karmaşıklığı nedeniyle, tahminin daha verimli ve doğru olması için [25]'te sıralı yaklaşıma dayalı SVR kullanımı önerilmiştir. Kısa vadeli tahminler için yapılan deneyler, bu modelin normal SVR modeline kıyasla daha iyi performans ve doğruluğu olduğunu göstermiştir. [26] ise başka bir kısa vadeli elektrik yükü tahmini için yapılan çalışma olup hibrit parçacık sürü optimizasyonu-genetik algoritma-geri yayılım sinir ağları (*Hybrid Particle Swarm Optimization-Genetic Algorithm-Back Propagation Neural Network*, PSO-GA-BPNN) algoritmasına dayalı bir model verilmiştir. Burada PSO-GA algoritması, BPNN parametrelerini optimize etmede kullanılmıştır. Bu modeli analiz etmek için farklı kağıt üretim işletmelerinden veriler alınmış ve bu modelin PSO-BPNN ve GA-BPNN tabanlı modellerden üstün olduğu görülmüştür.

[27]'de yük tahmini doğruluğunu artırmak için, uygun bir yük veri analizi ve daha etkili bir özellik seçimi tercih edilmiştir. Yük verileri önce Bi-Secting K-Means algoritması ile kümelere dönüştürülmüş ve sonra ampirik mod ayrışımı ile içsel mod fonksiyonlarına ayrıştırılmıştır. Buna göre çift yönlü RNN'lere (Bi-RNN) ve DBN'e dayalı bir tahmin modeli geliştirilmiştir. En son aşamada bir elektrik şebekesi yük verileri üzerinde test edilmiş ve diğer yöntemlerden daha iyi olduğu sonucuna varılmıştır. DBN ayrıca [28]'de güç sisteminin saatlik yükünü tahmin etmek için kullanılmıştır. Ev aletlerinde ve birçok amaca hizmet eden cihazlarda ana sorunlardan biri olan enerji ayrışması konusu için yapılan çalışmada müdahaleci olmayan yük izleme sorununu çözmek için derin evrişimli sinir ağı (*Deep Convolutional Neural Network*, DCNN) tabanlı bir yöntem önerilmiştir [29]. [30]'da ise fotovoltaik (*photovoltaic*, PV) dağıtık üretim birimlerinin neden olduğu belirsizlikleri tespit etmek için yeni bir olasılıksal yük tahmin modeli önerilmiştir. Bu modelde bir Bayesian derin LSTM sinir ağı kullanılmıştır. [31]'de bir hafta öncesi yük tahmini için bulanık tabanlı bir model sunulmuş ve bu modelde YSA'ları ve topluluk tahminini birleştiren hibrit DL sinir ağlarını kullanılmıştır. Burada iki durum çalışması üzerinde test yapılmış ve geleneksel modellerden daha etkili olduğu kanıtlanmıştır. [32]'de gün öncesi toplam yükü tahmin etmek için DNN ve yüksek boyutluğun neden olduğu zorlukların üstesinden gelmek için kullanılan iki terminali seyrek kodlamanın birleşimine dayalı bir model önerilmiştir.

DL modelleme, her ne kadar etkin bir method olsa da zaman ve enerji gibi yüksek maliyet de gerektirmektedir. Eğitim maliyetlerini en aza indirerek gün öncesi konut yükünün tahmin edilmesinde kullanılmak için [33]'te LoadCNN adı verilen CNN'ye dayalı bir model önerilmiştir. [34]'te ise doğrudan çok adımlı ve yinelemeli yöntemler altında formüle edilmiş RNN ve CNN önerilmiştir. Geleneksel yük tahmin yöntemlerinden biri, bir zaman serisi tahmin yöntemi olan dışsal girdilerle otoregresif entegre hareketli ortalamadır (*Autoregressive Integrated Moving Average*, ARIMAX). Doğrulukları ve verimlilikleri geleneksel ARIMAX ile karşılaştırılmış ve önerilen modelin ARIMAX'a kıyasla %22,6 oranında geliştirilmiş doğrulukla daha iyi performansa sahip olduğu gösterilmiştir. [35]'te elektrik yükü tahmininde FDN' ye, diziden diziye (*seq2seq*) modellere, zamansal CNN'lere ve RNN'lere odaklanılmıştır. İki veri setine göre bu modeller analiz edilmiştir. Toplu yük tahmininde Elmann RNN'lerinin, kapılı tekrarlayan birimlere (*Gated Recurrent Unit*, GRU) ve LSTM'e göre daha az maliyetle daha iyi performans gösterdiği gözlemlenmiştir. [36]'da konut yükünü tahmin etmek için bir Bayes DL tabanlı

çoklu görev olasılıksal yük tahmini (*Probabilistic Load Forecasting*, PLF) modeli önerilmiştir. Bu modelin SVR, havuzlama tabanlı LSTM ve rastgele ormanlar (*Random Forest*, RF) gibi geleneksel yöntemlere kıyasla daha iyi performans gösterdiği gözlemlenmiştir. [37]'de dağıtım fiderlerinin yıllık yükünü tahmin etmek için bir model sunulmuş, çok yıllık verilerden yararlanmak için LSTM ve GRU modelleri kullanılmıştır. LSTM ve GRU ağları, bir kentsel şebekenin verilerini kullanarak ARIMA, aşağıdan yukarıya ve FDN yöntemleri ile karşılaştırılmıştır. Sonuçlar, çalışmadaki modelin performansının üstün olduğunu göstermiştir. [38]'de kısa vadeli gün öncesi yükü tahmin etmek için bir adanın güç sisteminin güç akışı yönetimi için ileri beslemeli YSA'lara dayalı bir algoritma oluşturulmuştur. Daha sonra bir örüntü tanıma algoritmasından geçirilmiş ve sınıflandırılmıştır. [39]'da PV güç çıkışı ve konut güç yükünü tahmin etmek için, LSTM ile derin bir RNN modeli önerilmiştir. Şebekeye bağlı mikro şebekenin yük dağıtımını optimize etmek için parçacık sürü optimizasyonu (*Particle Swarm Optimization*, PSO) algoritması kullanılmış ve iki veri setindeki sonuçlar, DRNN-LSTM modelinin SVM ve MLP-NN'den daha iyi performans gösterdiğini kanıtlamıştır.

Çalışma [40]'ta, yük ve iklim veri tahminlerini entegre ederek akıllı şebekeyi yönetmek için kullanılan üç AI tahmin yaklaşımının geliştirilmesi ve karşılaştırılması amaçlanmıştır.

Bu amaca ulaşmak için, öncelikle bazı AI metodolojilerinin tahmin doğruluğunu incelenmiştir. Burada bir sinir ağı, bir nöro-bulanık ve bir DL tahmin algoritması uygulanmış ve akıllı şebeke parametrelerinin (sıcaklık, güneş ışınması, rüzgar hızı, enerji tüketimi) tahmini için karşılaştırmalar yapılmıştır. Benzetim sonuçları, rüzgar hızı, sıcaklık, güneş ışınması ve tüketim verilerinin gerçek veritabanına dayalı olarak kontrol edilmiştir. [41]'de yıllık bina yükünü tahmin etmek için sembolik bir regresyon modeli olan QLattice önerilmiştir. QLattice basit ve şeffaf bir yapıya sahip olup doğası gereği yorumlanabilir olan farklı girdi değişkenlerinin etkileşimini doğrudan türetebilmektedir. [42]'de ise konut yükü tahmini için yorumlanabilir bir anımsatıcı LSTM modeli geliştirilmiştir. Bu model, yük tahmini için zaman serisi modelinin yorumlanabilirliğini geliştirerek, değişken ve zamansal önemi ortaya çıkarmak için karşım dikkat mekanizmasını kullanmaktadır.

Bu çalışmalar ile akıllı şebeke yük tahmininde her türlü DL algoritmasının geleneksel yöntemlerden daha doğru sonuçlar verebileceği sonucuna varılabilmektedir. DL algoritmaları, akıllı sayaçlardan ve diğer veri kaynaklarından gelen büyük hacimli verilerle rahatlıkla başa çıkabiliyorsa da performanslarının farklı veri kümelerine dayalı olarak daha fazla test edilmesi gerekmektedir.

Tablo 1. Akıllı şebekelerde yük tahmini ve kestirimi konularında yapılan çalışmalar

| Referans | Yıl | Teknik | İçerik | Katkı |
|----------|------|----------------------------------|--|--|
| [7] | 2014 | İstatistiksel ve AI modelleri | Belirli bir bölgenin yük tahmini doğruluğu iyileştirilmeye çalışılmıştır. Seçilen gizli katman sayısı arttıkça, eğitimin daha uzun sürdüğü ve fazladan uyum riskinin arttığı gözlemlenmiştir. | Yük tahmin doğruluğunun arttığı gösterilmiştir. |
| [8] | 2017 | CNN ve K-Means | K-Means algoritması ile çok fazla yük kaydı içeren büyük veri kümeleri alt kümelere bölünmüş, elde edilen bu alt kümeler ise CNN'yi eğitmek için kullanılmıştır. | Elektrik yüklerinin saatlik tahmini. |
| [9] | 2017 | DBN | Deneysel sonuçlar ile önerilen yöntemlerin etkili olduğu gösterilmiştir. | Gün öncesi yük tahmini |
| [10] | 2018 | DNN | Deneysel sonuçlar, önerilen yöntemin klasik ANN, SVR ve ELM'den daha doğru tahminler verebildiğini göstermiştir. | Saatlik yük tahmini. |
| [11][12] | 2011 | CRBM ve FCRBM | Bina ve sitelerdeki enerji tüketimi verileri akıllı sayaçlar ile toplanarak binalardaki yük tahmini yapılmaktadır. | Binalardaki yük tahmini. |
| [13] | 2016 | LSTM ve Seq2Seq LSTM | Çalışma, standart bir LSTM mimarisinin bir dakikalık yükü doğru bir şekilde tahmin edemediğini gösterirken, Seq2Seq LSTM tabanlı mimarinin her iki durumda da mükemmel performans sağladığını ifade etmiştir.. | Bir saat ve bir dakikalık zaman adımlı yüklerin tahmini. |
| [14] | 2017 | CNN, S2S LSTM, FCRBM, ANN ve SVM | CNN' den elde edilen sonuçlar, aynı veri seti için S2S tabanlı LSTM, FCRBM, ANN ve SVM tarafından elde edilenlerle karşılaştırılmıştır. Sonuç olarak, CNN, ANN ve DL metotları SVM' den daha iyi performans göstermişlerdir. | Tarihsel yüklere göre bina düzeyinde yük tahmini için. |
| [15] | 2016 | DL | Önerilen yöntem ve başarımı, üniversite kampüsü içinde inşa edilmiş küçük ölçekli merkezi olmayan bir sistem üzerinde doğrulanmıştır. | Hava tahmini sayısal benzetimi ile enerji tüketimi ve güç üretimi tahmini. |
| [16] | 2016 | DNN | Akıllı sayaç verilerine dayalı olarak kısa vadeli yük tahmini için DNN ve diğer makine öğrenimi teknikleri uygulanmıştır. | Kısa vadeli yük tahmini. |
| [17] | 2016 | DBN | Çalışmada çok sayıda sınırlı Boltzmann makinesi katmanından oluşan bir DBN kullanılmıştır. DBN modeli, 2008–2014 döneminde Makedonya'nın saatlik elektrik tüketimi verilerine dayalı olarak kısa vadeli elektrik yükü tahminine uygulanmıştır. | Elektrik yükü tahmini. |

| | | | | |
|------|------|-------------------------------|---|--|
| [18] | 2014 | DBN ve SVR | Önerilen yöntemin diğer kıyaslama yöntemlerine göre üç elektrik yükü talep veri seti, bir yapay zaman serisi veri seti ve üç regresyon veri seti üzerindeki avantajını gösterilmiştir. | İlk kez, regresyon ve zaman serisi tahmini için bir DBN önerilmiştir. Başka bir yeni katkı, çeşitli DBN'lerden gelen çıktılarının bir SVR modeliyle toplanmasıdır. |
| [19] | 2019 | ANN ve LSTM | Elektrikli taşıtların güvenlik testlerinin nedeniyle şarj yükünü tahmin etmek, güç sisteminin güç talebinde yüksek belirsizliğe yol açmıştır. | Kısa vadeli elektrikli taşıtlar yük tahmini. |
| [20] | 2019 | ARIMA ve LSTM | Belirli bir zamandaki yük tüketimi veri seti üzerinden değerlendirilmiş ve popüler kısa vadeli yük tahmini modellerine kıyasla bu modelin üstün performansı gözlemlenmiştir. | Yük dizilerinin büyük zaman aralığı yarı periyodikliği. |
| [21] | 2019 | AM, RU ve Bi-LSTM | Akıllı şebekelerde dağıtılmış nesillerin kapsamlı kullanımı, STLF'nin doğruluğu için ek ihtiyaç gerektirmiştir. | Geçerlilik, farklı ülkelerden gerçek veri setleri üzerinde ölçülmüştür. |
| [22] | 2020 | YSA eğitim toplulukları | Gerçek veriler üzerinde istatistiksel analiz, bu modelin tek ANN, torbalı ANN ve güçlendirilmiş ANN'den daha düşük yanlılık, varyans ve tahmin hatasına sahip olduğunu göstermiştir. | Güçlendirilmiş bir YSA modeli. |
| [23] | 2019 | YSA, BR ve LM | Elektrik faturalarını azaltmak amacıyla gün öncesi tahminlerinin daha iyi performansı için en iyi stratejiler geliştirilmiştir. | Gün öncesi ve saat öncesi yük tahmini bölge binası |
| [24] | 2019 | RNN ve 1D-CNN | Gizli durum vektöründe herhangi bir hata varsa, mevcut RNN modelleri tarafından düzeltilemez, böylece gelecekte daha iyi tahmin yapılması engellenir. | Öngörülen gelecek gizli durum vektörü |
| [25] | 2019 | SVR | Kısa vadeli elektrik yükü tahmininde SVR yaklaşımının yüksek hesaplama karmaşıklığı nedeniyle, SVR tabanlı sıralı bir şebeke yaklaşımı daha verimli ve doğru hale gelir. | Sıralı grid yaklaşımına dayalı SVR |
| [26] | 2019 | GA-PSO-BPNN | BPNN parametrelerinin optimize edilmesinde GA-PSO algoritması kullanılmış, veriler farklı kağıt yapım işletmelerinden alınmıştır. | Tahmin ve alt örnekleme arasındaki etkileşimin etkisi |
| [27] | 2019 | Bi-RNN, DBN | STLF'nin doğruluğunu artırmak için, uygun bir yük veri analizi ve daha etkili özellik seçimi yapılmıştır. | Yük veri analizi ve daha etkili özellik seçimi |
| [28] | 2019 | DBN | Tepe yük göstere değişkenlerini hesaplamak için Copula modellerini kullanmıştır. | Güç sisteminin saatlik yükünü tahmin etme |
| [29] | 2019 | DCNN | Ev aletlerinde, özellikle birden fazla amaca hizmet eden tip II cihazlarda, enerji ayrıştırması temel sorunlardan biri ele alınmıştır. | Müdahale etmeyen yük izleme sorununu çözme |
| [30] | 2019 | Bayesian derin LSTM sinir ağı | Dağıtılmış PV üretiminin neden olduğu belirsizlikleri yakalamak için yeni bir olasılıksal konut net yük tahmin modeli | Alt profillerdeki kümelenme ve PV görünürlüğü, modelin performansına önemli katkı sağlayan unsurlar |
| [31] | 2020 | Hibrit DL sinir ağları | Girdiyi kümelere bölmek için bir bulanık kümeleme fikri kullanılmış ve daha sonra bunlar bir RBF, bir evrişimli, bir havuzlama ve iki tam bağlantılı katmandan oluşan bir sinir ağına eğitilmiştir. | Hafta öncesi yük tahmini için bulanık tabanlı bir topluluk modeli |
| [32] | 2019 | DNN | Yüksek boyutlu verilerin neden olduğu zorlukların üstesinden DNN ile gelinmiştir. | Gün öncesi toplu yük tahmini için iki terminalli seyrek kodlama ve DNN füzyonu |
| [33] | 2019 | LoadCNN | Doğrulukta ödün vermeden eğitim maliyetini en aza indirmek | Eğitim maliyetlerini en aza indirerek gün öncesi konut yükünü tahmin etme |
| [34] | 2019 | RNN ve CNN | Doğruluk, verimlilik ARIMAX ile karşılaştırılmış ve doğrudan çok adımlı bir şekilde gerçekleştirilen CNN'nin en iyi performansa sahip olduğu kanıtlanmıştır. | RNN ve CNN, özyinelemeli ve doğrudan çok adımlı yöntemler altında formüle edilmiş |
| [35] | 2019 | Geçici CNN'ler ve RNN'ler | Elmann RNN'leri, toplu yük tahmininde daha az maliyetle GRU ve LSTM ile karşılaştırılabilir performans göstermiştir. | Elektrik yükü tahmininde ileri beslemeli sinir ağlarına, seq2seq modellerine, zamansal CNN'lere ve RNN'lere odaklanmıştır |

| | | | | |
|------|------|--|---|--|
| [36] | 2019 | Bayes DL | Model, sırasıyla her aşamada kümeleme, havuzlama ve çoklu görev öğrenmenin kullanıldığı üç aşamalı bir ardışık düzen izlemiştir. | Konut yükünü tahmin etmek için Bayesian DL tabanlı çok görevli bir PLF çerçevesi önermiş |
| [37] | 2019 | LSTM ve GRU | Çok yıllık verilerde gizlenmiş sıralı bilgilerden yararlanmak için gelişmiş dizi tahmin modelleri LSTM ve GRU'yu kullanmıştır. | Dağıtım besleyicilerinin yıllık yükünü tahmin etme. |
| [38] | 2019 | İleri Beslemeli YSA'lar | Kısa vadeli gün öncesi yük tahmini için ileri beslemeli YSA'lara dayalı bir model kullanmıştır. | Bir adanın güç sisteminin güç akışı yönetimi. |
| [39] | 2019 | DRNN-LSTM | Yük dağıtım optimizasyonu, elektrikli taşıtların ve enerji depolama sistemlerinin en yüksek yükü değiştirmesini ve günlük maliyetlerin azaltılmasını sağlamıştır. | Şebekeye bağlı topluluk mikro şebekesinin yük dağıtımını optimize etmek için PSO algoritması |
| [40] | 2022 | Sinir ağı, Nörobülank ve DL tahmin algoritması | Akıllı şebeke parametrelerini (sıcaklık, güneş ışınması, rüzgar hızı, enerji tüketimi) tahmin etmek için karşılaştırma yapılmıştır. | Yük ve iklim veri tahminlerini entegre ederek akıllı şebekeyi yönetme. |
| [41] | 2022 | QLattice | Sembolik bir regresyon modeli kullanılmıştır. | Yıllık bina yükünü tahmin etme. |
| [42] | 2022 | LSTM | Bu çalışmada yük tahmini için zaman serisi modelinin yorumlanabilirliğini geliştirerek, değişken ve zamansal önemi ortaya çıkarmak amaçlanmıştır. | Konut yükü tahmini. |

3.2. Mikro şebeke

Mikro şebekeler, şebekeden bağımsız ya da şebekeye bağlı olarak işletilebilen küçük ölçekli enerji şebekeleridir. Güç sistemlerinde artan enerji talepleri ve genişleyen hizmet ağı nedeniyle meydana gelen karmaşık yapıyı analiz etmek zorlu bir süreç haline gelmektedir. Yapay zeka ise bir mikro şebekedeki bu tür problemlerin çeşitli açılardan çözüme ulaşmasında hayati bir rol oynamaktadır. Bu nedenle DL, RL ve DRL algoritmalarının bir kombinasyonu gibi dallar geliştirilmektedir. Bu algoritmalar, karmaşık bir ağ yapısında karar vermede daha yüksek önceliğe ulaşmak için kullanılmaktadır. Akıllı şebekelerde mikro şebeke ile ilgili literatürdeki çalışmalar Tablo 2'de özetlenmiştir [43-46].

Mikro şebekelerde enerji depolamanın planlanması ve işletilmesi zor bir süreçtir. [43] ve [44]'te lokal fotovoltaik

sistemi enerji üretiminin öz tüketimini en üst düzeye çıkarmak, elektrik maliyetini ve yerel şebekeye olan bağımlılığı en aza indirmek için bir mikro şebekedeki bir enerji depolama cihazının kontrolünde RL yöntemi uygulanmıştır. Bir mikro şebekede bazı durumlarda şebeke esnekliğini artırabilmek amacıyla aynı anda farklı operasyonel özelliklere sahip çeşitli enerji depolama sistemleri kullanılmaktadır. [45]'te ise sistem verimliliğini artırmak için farklı pil sistemlerinin şarj ve deşarj sürelerini kontrol etmek için yine bir RL stratejisi önerilmiştir.

Çalışma [46]'da, akıllı invertör tabanlı mikro şebekelerde, anormallik azaltma kontrol modelleri için doğrusal olmayan bir otoregresif eksojen (*Nonlinear Autoregressive Exogenous*, NARX) modeli önerilmiştir. Özelliklerin ağ çıkışı üzerindeki etkisini hesaba katmak için ise kısmi bağımlılık grafiği (*Partial Dependence Plot*, PDP) kullanılmıştır.

Tablo 2. Akıllı şebekelerde mikro şebeke konularında yapılan çalışmalar

| Referans | Yıl | Teknik | İçerik | Katkı |
|----------|------|-----------|---|--|
| [43] | 2017 | RL | Önerilen yaklaşım, Belçikalı konut tüketicilerinden alınan veriler kullanılarak bir konut ortamında simülasyon yoluyla test edilmiştir. | Mikro şebekelerde enerji yönetiminde toplu RL'nin uygulanması. |
| [44] | 2017 | Q-Öğrenme | Yerel bir tüketici, yenilenebilir bir jeneratör (güneş fotovoltaik sistemi) ve bir depolama tesisi (batarya) içeren şebekeye bağlı bir güneş enerjisi mikro şebeke sistemi düşünülerek gerçek sayısal verileri kullanan simülasyon sonuçları, sistemin güvenilirlik testi için sunulmuştur. | Güç tüketimini azaltma. |
| [45] | 2016 | RL | Sistem verimliliğini artırmak için farklı pil sistemlerinin şarj ve deşarj sürelerini kontrol etmek için yine bir RL stratejisi önerilmiştir. | Sistem verimliliğini artırma. |
| [46] | 2022 | NARX | Kontrol modelleri için NARX modeli önermiştir. Özelliklerin ağ çıkışı üzerindeki etkisini hesaba katmak için PDP kullanılmıştır. | Akıllı invertör tabanlı mikro şebekelerde anormallik azaltma. |

3.3. Talep yanıtı

Talep tarafında enerji esnekliğinin belirlenmesi ve tahmin edilmesi, talep yanıtını uygulamak için çok önemlidir. Aynı zamanda, en yeni akıllı sayaç uygulamaları, müşteri tarafındaki güç tüketim seviyelerini gerçek zamanlı olarak rahatça izlenmesine ve müdahaleci olmayan yük izleme veya müdahalesiz cihaz yük izleme (*Nonintrusive Load Monitoring*, NILM) aracılığıyla müşterilerin tüketim davranışlarını analiz etmemize olanak tanıyabilmektedir. NILM kullanılarak hangi cihazların kullanıldığı ve bireysel tüketimlerinin ne olduğu belirlenebilmektedir. Akıllı şebekelerde talep yanıtı ile ilgili literatürdeki çalışmalar Tablo 3'te detaylı olarak verilmiştir [47-55]. [47]'de yüklerin esnekliğini belirlemek ve talep yanıtı için referanslar sağlamada DL uygulanmıştır. [48]'de esnekliği gerçek zamanlı olarak belirlemek ve tahmin etmek için Koşullu Kısıtlı Boltzmann Makinelerini kullanılmış, [49]'da ise tüketicileri sınıflandırmak için RNN kullanılmış ve önerilen algoritmaların mevcut yöntemlerden daha iyi performansla sahip olabildiği gösterilmiştir. Aslında, doğrudan yük kontrolü ve talep yanıtı, kısmi gözlenebilirlik ve

rastgelelik zorluklarıyla karşı karşıya kalan yüksek boyutlu kontrol problemleridir. [50] ve [51]'de, cihaz düzeyinde konut talep yanıtının ayarlanması için RL uygulanırken, [52] ve [53]'te RL, termostatik olarak kontrol edilen yük verilerinin toplanması ve gönderilmesini ayarlama kullanılmıştır. Talep yanıtının geleneksel kapsamı, enerji entegrasyon teknolojilerinin sağladığı teknolojik gelişmişlikten yararlanılarak entegre talep yanıtı içerecek şekilde genişletildi. Bu makale, entegre talep yanıtı programındaki hizmet sağlayıcılar ile son kullanıcılar arasındaki ilişkiyi incelemektedir. Burada talep yanıtının amacı, müşteri tüketim fiyatlarını en aza indirirken ve sistemi sabit tutarken, gaz ve elektrik dağıtım şirketleri için karı maksimize etmektir. Hiyerarşik karar verme çerçevesi, derin pekiştirmeli öğrenme kullanılarak gösterilmektedir [54]. DR mekanizmaları, tüketicilerin talebini modüle ederek ve elektrik fiyatını güç tüketim modellerine ve tahminlerine göre ayarlayarak akıllı şebekelerdeki güç arzı ve talebini dengelemeyi amaçlar. DL ağlarının, bu tür DR sistemlerinde yanlış veri enjeksiyonu (*False Data Injection*, FDI) saldırılarını geleneksel istatistiksel yöntemlerden daha iyi tespit ettiği kanıtlanmıştır [55].

Tablo 3. Akıllı şebekelerde talep yanıtı konusunda yapılan çalışmalar

| Referans | Yıl | Teknik | İçerik | Katkı |
|-----------|--------------|--------|--|--|
| [47] | 2016 | DL | Talep yanıtı konusunda referanslar elde etmek için DL uygulanmıştır. | Yüklerin esnekliğini belirleme. |
| [48] | 2016 | BM | Esnekliği gerçek zamanlı olarak belirlemek ve tahmin etmek için Koşullu Kısıtlı Boltzmann Makinelerini kullanılmıştır. | Esnekliği gerçek zamanlı olarak belirleme. |
| [49] | 2017 | RNN | Önerilen algoritmaların mevcut yöntemlerden daha iyi performansla sahip olabildiği gösterilmiştir. | Tüketicileri sınıflandırma. |
| [50] [51] | 2015 2016 | RL | Cihaz düzeyinde konut talep yanıtının ayarlanması için RL uygulanmıştır. | Talep yanıtının ayarlanması. |
| [52] [53] | 2014 2012 | RL | Termostatik olarak kontrol edilen yük verilerinin toplanması ve gönderilmesini ayarlama kullanılmıştır. | Yük verilerinin toplanması ve gönderilmesi. |
| [54] | 2022 | DRL | Entegre talep yanıtı programındaki hizmet sağlayıcılar ile son kullanıcılar arasındaki ilişkiyi incelemektedir. | Müşteri fiyatlandırmasını minimum, dağıtım fiyatlarını maksimum olarak ayarlama. |
| [55] | 2022 | DL | FDI saldırılarını, DL ile geleneksel istatistiksel yöntemlerden daha iyi tespit ettiği kanıtlanmıştır | Şebekelerde güç arzı ve talebini dengeleme. |

3.4. Hata tespiti ve durum tahmini

Güç sistemlerinin güvenilirliğini sağlamak için elektrikli ekipmanların arıza/kusur tespiti hayati derecede önemlidir. Tipik bir güç sisteminde birçok sensör ve izleme sistemi mevcuttur ve buralardaki kademeli değişiklikler analiz edilmektedir. Ancak, güç sistemindeki algılayıcılardan alınan kaydedilen verilerin karmaşıklığı nedeniyle, kusurlar veya hatalar erken bir aşamada kolayca fark edilememektedir. Literatürdeki birçok çalışmada güç ağlarındaki yalıtkanlar, transformatörler ve iletim hatları olmak üzere üç önemli bileşenin durumlarını izlemek için DL kullanılmıştır. DL, akıllı şebekelerde ekipman hatası tespiti için etkili bir yöntem olup, Tablo 4' te konuya ilişkin literatür sunulmuştur [56-69].

[56]' da yalıtkanların özelliklerini çıkarmak ve kusurlarını belirlemek için üst düzey ayrımcı CNN' lerden yararlanılması önerilmiştir. Deneysel sonuçlar, önerilen yöntemin %93 oranında bir doğruluk elde edebileceğini göstermiştir. [57]' de, derin sinir ağına dayalı bir güç transformatörü arıza teşhis

yöntemi önerilmiştir. Test sonuçları, CNN'nin, BP sinir ağı ve SVM' den daha iyi olduğunu göstermiştir. Güç hattı arıza tespiti performansını iyileştirmek için, [58]'de dalgacık ayrışmasının normalize edilmiş alt bant enerjisinin DL sinir ağı için karakteristik parametreler olarak kullanıldığı, kendi kendini kodlayan seyrek sinir ağına dayalı bir modelleme yöntemi önerilmiştir. Burada arıza sinyalinin özellikleri DL yapısını oluşturmak için eğitilmiş ve benzetim sonucu olarak hata tanıma oranının %99' u aştığını göstermiştir.

Bir güç sisteminde doğru bir çözüme ulaşmak için durum değişkenlerinin tahmini gereklidir. Durum değişkenlerinin tahminindeki düşük doğruluk sorununun üstesinden gelmek için [59]'da veri güdümlü en küçük kareler SVM'yi ve model tabanlı kokusuz parçacık filtresini kullanan ortak bir lityum-iyon pil durumu tahmin yaklaşımı gösterilmiştir. [60]'ta ise akıllı şebekelerde dinamik durum tahmininde veri enjeksiyonlu siber saldırıları tespit etmek için yeni bir

çevrimiçi tabanlı yöntem önerilmiştir. Bu çalışmada, kalman filtresinin durum değişkenlerine yönelik kusurlu bir veri enjeksiyon saldırısı ele alınmış, hedeflenen durum değişkenlerini seçmek için yeni bir metodoloji tasarlanmış ve ardından PSO algoritması ile ilgili ideal bir modeli çözerek optimum değerler belirlenmiştir. Yapılan sayısal deneyler, önerilen tespit yönteminin uygulanabilirliğini ve sağlamlığını göstermiştir. [61]'de dengesiz 3 fazlı güç dağıtım sistemlerini kullanarak harmonik gerilimlerin dağılımını tahmin etme ve harmonik kaynakları bulma zorlukları incelenmiştir. Dağıtım seviyeli güç yönetim biriminden (*Distribution-Level PMU*, DPMU) ve akıllı sayaçlardan iki farklı ölçüm türü kullanan durum tahmini için bir model geliştirilmiştir. Bu model, dağıtım şebekeleri için daha az DPMU'ya ihtiyaç duymuştur.[62]'de gözlemlenemeyen dağıtım sistemleri için durum tahmininin zorlukları ele alınarak; gerçek zamanlı uygulamalar için, bir DL yaklaşımı kullanarak Bayes durum tahminine göre bir model uygulanmıştır. Deneysel benzetimler, gözlemlenemeyen sistemler için Bayes durumu tahmininin etkinliğini göstermiştir. [63]'teki çalışmada yanlış durum tahminine neden olan PMU ölçümlerini değiştirmeyi amaçlayan FDI incelenmiştir. Her durum tahmini döngüsünden önce üretim ve yük dalgalanmaları, hat arızaları ve açmaları, şönt bağlantı kesilmeleri ve FDI gibi çeşitli olaylarla ilgili fazör verilerinin elde edildiği toplayıcılarda, PMU verilerini kontrol etmek ve kanıtlamak için, bir CNN veri filtresi önerilmiştir. Bu CNN tabanlı filtre, diğer tüm sınıflandırıcılara kıyasla kayda değer bir doğruluk göstermiştir. [64]'te güç sistemlerini izlemek için DNN tabanlı bir model önerilmiştir. Sayısal testler, önerilen DNN tabanlı yaklaşımların geleneksel yöntemlerle karşılaştırıldığında üstünlüğünü ortaya açıkça koymuştur. DNN tabanlı güç sistemi durum tahmini (*Power System State Estimation*, PSSE) şemasının yaygın olarak kullanılan Gauss-Newton PSSE çözücü gibi mevcut yöntemlerden daha iyi performans gösterdiğini kanıtlamıştır.

Tüm güç akışı ve voltaj büyüklüğü ölçümlerinin kullanılabilirliği gibi varsayımlar üzerine [65]'te güç akışlarını birinci derece ölçümlere dönüştürmek için genel bir cebirsel yöntem önerilmiş ve bileşik optimizasyona dayalı bir yakınsaldogrusal algoritma geliştirilmiştir. [66]'da akıllı sayaçlar ve azaltılmış denetleyici kontrol ve veri toplama (*Supervisory Control And Data Acquisition*, SCADA) ölçüm birimleri kullanarak dağıtım sistemi durum tahmininin zorlukları ele alınmıştır. Bu çalışmada sınırlı ölçüm engelini üstesinden gelmek için DL kullanan bir Bayes durum tahminci belirlenmiştir. Benzetim sonuçları, yöntemin doğruluğunun yanı sıra hesaplama maliyetinin var olan tekniklerle karşılaştırıldığında dikkate değer bir iyileşme olduğunu göstermiştir. [67]'de bir Alman dağıtım şebekesinde yatırımları azaltmak ve tahmin doğruluğunu iyileştirmek için çeşitli sayaç yerleştirme şemaları kullanılmıştır. Yerleştirme şemalarının tahmin doğruluğu üzerindeki etkinliği bu çalışmada hesaplama verimliliği açısından kıyaslanmıştır.

[68]'de, yanlış veri enjeksiyon saldırıları konum tabanlı tespitindeki etkinliğini test etmek için çeşitli derin öğrenme yaklaşımlarının karşılaştırmalı bir analizi sunulmuştur. Ayrıca, CNN ve LSTM ağına dayalı çok özellikli bir mimari inşa edilerek derin bir öğrenme yaklaşımı geliştirilmiştir. IEEE test durumları üzerinde yapılan kapsamlı testler, önerilen yaklaşımın, farklı saldırı senaryoları altında küçük ve büyük sistemler için saldırıların yerini belirlemede mevcut derin öğrenme yaklaşımlarından daha iyi performans elde edildiğini göstermiştir. [69]'da DL modellerinin bir ofis binasının elektrik enerjisi tüketimini tahmin ederken talep yanıtını karşılama yeteneği vurgulanmıştır. Enerji tüketim tahmini, akıllı şebeke ortamında DR programlarında önemli bir rol oynar. Bu çalışmada Portekiz'de bulunan bir ofis binasının 3 farklı iklim gününe (yaz, kış ve bulutlu günler) ait 10 saniye aralıklarla tarihsel enerji tüketimi ve ortam sıcaklığı verileri alınmıştır. Gelecekteki tüketim tahmini için DL tekniği tabanlı bir derin sinir ağı modeli önerilmiştir. Bu yazıda, tüm ofis binasının enerji tüketim öngörülebilirliği analiz edilmiştir.

Tablo 4. Akıllı şebekelerde hata tespiti ve durum tahmini konularında yapılan çalışmalar

| Referans | Yıl | Teknik | İçerik | Katkı |
|----------|------|--------------------------------|---|--|
| [56] | 2016 | CNN | Deneysel sonuçlar, önerilen yöntemin %93 oranında bir doğruluk elde edebileceğini göstermiştir. | Yalıtkanların özelliklerini çıkarmak ve kusurlarını belirleme. |
| [57] | 2011 | CNN, BP ve SVM | Test sonuçları, CNN'nin, BP sinir ağı ve SVM' den daha iyi olduğunu göstermiştir. | Güç transformatörü arıza teşhisi. |
| [58] | 2017 | DL | Arıza sinyalinin özellikleri DL yapısını oluşturmak için eğitilmiş ve benzetim sonucu olarak hata tanıma oranının %99' u aştığını göstermiştir. | Güç hattı arıza tespiti performansını iyileştirme |
| [59] | 2020 | SVM, Kokusuz partikül filtresi | Karmaşık çalışma koşullarında parametrelerin tanımlanmasını ve güncellemeyi içeren doğrudan haritalama modelleri | Veri odaklı en küçük kare SVM ve model tabanlı kokusuz parçacık filtresi |
| [60] | 2019 | Kalman filtresi | Konvansiyonel veri sızıntısı saldırısı için Kalman filtresi kullanımı | Akıllı şebekede dinamik durum tahminine karşı veri sızıntısı siber saldırıları |
| [61] | 2019 | DPMU | Dengesiz üç fazlı güç dağıtım sistemlerini kullanarak harmonik kaynakları bulma ve harmonik gerilimlerin dağılımını tahmin etme zorlukları | Harmonik durum tahmini için bir model |
| [62] | 2020 | DNN | DL sinir ağlarını kullanan doğrudan Bayes durumu tahminin, sözde ölçüm teknikleri ile karşılaştırılması | Bir DL yaklaşımı kullanarak Bayes durumu tahmini |

| | | | | |
|------|------|-----------------------------|--|--|
| [63] | 2019 | CNN | Her durum tahmini döngüsünden önce hat arızaları ve açmalar, üretim ve yük dalgalanmaları, şönt bağlantı kesilmeleri gibi çeşitli olaylarla ilgili fazör veri yoğunlaştırıcılarında toplanan veri paketlerinden çıkarılan çok değişkenli zaman serisi sinyalleri | Yanlış durum tahmini çözümleriyle sonuçlanan ölçümleri değiştirme |
| [64] | 2019 | DNN | Gürültü olmadığında, PSSE, aynı zamanda güç akışının analizine de karşılık gelen ikinci dereceden bir denklem sistemini çözmeye eşdeğer olduğunu gösterme | Yalnızca çevrimdışı eğitime ve daha az ayar çabasına ihtiyaç duyan gerçek zamanlı PSSE için modele özel yeni bir DNN uygulanmış |
| [65] | 2019 | Yakınsal-doğrusal algoritma | Kompozit optimizasyona dayalı önerilen yöntemin mükemmel kurtarma ve ikinci dereceden yakınsaması için kayıp fonksiyonu üzerinde farklı koşullar uygulanmış | Güç akışlarını birinci derece ölçümlere dönüştürmek için genel bir cebirsel yöntem |
| [66] | 2019 | SCADA | Yüklerde net güç enjeksiyonlarının dağılımını öğrenmek için, derin bir üretici ağı eğitilmiş ve ardından, sistem durumunun MMSE tahminini elde etmek için üretici ağıdan elde edilen örnekler kullanılarak, bir derin regresyon ağı eğitilmiş. | Sınırlı ölçüm engelini üstesinden gelmek için DL kullanan bir Bayesian durum tahmincisi belirleme |
| [67] | 2019 | Yakın optimum yerleştirme | Bir Alman dağıtım şebekesine daha az yatırımla tahmin doğruluğunu geliştirmek amacıyla çeşitli sayaç yerleştirme şemaları kullanılmış. | Şebeke durumunu tahmin etmek için, PV üretim tahminleriyle birlikte standart yük profillerine dayalı sahte ölçümler kullanılmış. |
| [68] | 2022 | CNN ve LSTM | Önerilen yaklaşımın, farklı saldırı senaryoları altında küçük ve büyük sistemler için saldırıların yerini belirlemede mevcut derin öğrenme yaklaşımlarından daha iyi performans elde edildiğini göstermiştir | Yanlış veri enjeksiyon saldırıları konum tabanlı tespitindeki etkinliğini test etme. |
| [69] | 2022 | DL ve DR | Bu çalışmada Portekiz'de bulunan bir ofis binasının 3 farklı iklim gününe ait 10 saniye aralıklarla tarihsel enerji tüketimi ve ortam sıcaklığı verileri alınmıştır. | Bir ofis binasının elektrik enerjisi tüketimini tahmin ederken talep yanıtını karşılama yeteneği. |

3.5. Güç sistemi analizi ve kontrolü

Son yıllarda rüzgar/güneş enerjisi, esnek yükler ve elektrikli araçlar gibi daha fazla yeni unsurun sisteme dahil olması ile güç sistemleri daha da karmaşık hale gelmektedir. Tüm bu unsurlar, güç sisteminde yüksek belirsizliğe neden olmaktadır. DL, güçlü veri analizi, tahmin ve sınıflandırma yeteneği nedeniyle güç sistemi frekans analizi ve kontrolü gibi karmaşık sorunları çözmeye belirgin avantajlara sahiptir. Akıllı şebekelerde bu konu ile ilgili literatür Tablo 5'te özetlenmiştir [70-73].

[70]'te birbirine bağlı bir sistemin alçak gerilim şebekesine kurulu birkaç PMU'dan alınan bir dizi ölçüm verisi

kullanılmış ve otomatik bozulma sınıflandırması yapmak için Çok Katmanlı Algular, DBN ve CNN dahil DL algoritmalarının uygulanması önerilmiştir. Elde edilen sonuçlar, CNN' nin sınıflandırma doğruluğu açısından diğerlerinden daha iyi performans elde ettiğini göstermiştir. [71]' de, küresel optimizasyon ile kontrol girdisi oluşturmak için değiştirilmiş gizli Markov modelini kullanan güç sistemi acil durum yönetimini desteklemek için çok seviyeli bir DL modeli kullanılmıştır. [72]' de ise acil durum kontrol stratejileri için karar vermede DRL kullanılmıştır.

Tablo 5. Akıllı şebekelerde güç sistemi analizi ve kontrolü konularında yapılan çalışmalar

| Referans | Yıl | Teknik | İçerik | Katkı |
|----------|------|-----------------------|--|---|
| [70] | 2017 | DBN, CNN | Elde edilen sonuçlar, CNN' nin sınıflandırma doğruluğu açısından diğerlerinden daha iyi performans elde ettiğini göstermiştir. | Otomatik bozulma sınıflandırması yapma. |
| [71] | 2016 | DL | Küresel optimizasyon ile kontrol girdisi oluşturmak için değiştirilmiş gizli Markov modelini kullanılmıştır. | Güç sistemi acil durum yönetimini destekleme. |
| [72] | 2018 | DRL | DL ile RL birleştirilerek DRL modeli oluşturulmuş ve Q-Learning ile ilgili performansı artırmak ve Q değerini hesaplamak için double Q modeli ve dueling Q modeli kullanılmış ve karşılaştırılarak kontrol stratejisi elde edilebilmiştir. | Acil durum kontrol stratejileri için karar verme. |
| [73] | 2022 | SGD tabanlı DNN ve ML | Algoritmaları çalıştırmak için harcanan süre ve elde edilen sonuçların doğruluğu açısından karşılaştırmalı sonuçlar sunulmuştur. | Güç sistemi arıza tipi ve konum tahmin problemi. |

Güç sistemi kararlılığını normal çalışmaya geri döndürmek için arızayı olabildiğince çabuk tanımlamak ve sınıflandırmak önemlidir. ML ve DL yöntemleri, hızlı ve verimli algoritmalar kullanarak büyük arıza gerilimleri ve akım verilerinin analizine olanak tanır. Bu yöntemler büyük miktarda veri gerektirir, ancak güç sistemi alanındaki son gelişmeler, akıllı sayaçlar ve PMU kullanılarak veri toplama, arıza tipi sınıflandırması ve konum tahmini problemini analiz etmek için sistem çapında büyük miktarda veri kullanılabilir hale getirilebilir. Bu makale, güç sistemi arıza tipi ve konum tahmin problemlerine uygulanan Stokastik Gradient Descent (SGD) tabanlı DNN ve ML'nin karşılaştırmalı bir çalışmasını sunmaktadır [73].

3.6. Yenilenebilir enerji üretimi tahmini

Yenilenebilir enerji üretim çıktısının tahmini, bu kaynakların belirsiz ve kesintili özelliklerini dikkate alarak elektrik şebekesine entegrasyonlarını geliştirmede oldukça önemlidir. Akıllı şebekelerde yenilenebilir enerji üretimi tahmini ile ilgili literatür Tablo 6' da özet olarak verilmiştir [74-78]. [74]'te, Kanada Saskatchewan'daki Regina bölgesinde kısa vadeli rüzgar hızı tahmini için çok amaçlı bir genetik algoritma ile MLP-NN ve en yakın komşular yaklaşımıyla birleştirilmiş ELM kullanılmıştır. Her iki yaklaşım da iyi bir tahmin hassasiyetine sahiptir. Öte yandan rüzgar rampalarını tahmin etmek için de çok sayıda araştırma yapılmaktadır. Ancak, mevcut rüzgar enerjisi tahmin

metodolojilerinin farklı hava koşullarında birtakım dezavantajları mevcuttur.

[75]'te girdi olarak bir hava durumu araştırma ve tahmin modeli (*Weather Research and Forecasting Model*, WRF) modeli kullanarak rüzgar tahminleri için MLP-NN kullanılmıştır. [76]' da ise rüzgar gücü tahmini alanında gelişmiş ve pratik olan LSTM tabanlı bir rüzgar gücü tahmin modeli önerilmiştir. Tüm bu çalışmalar, DL yöntemlerinin yenilenebilir üretim tahmininde giderek daha da fazla uygulandığını göstermektedir. DL yöntemlerinin esneklik, kendi kendini uyarlayan öğrenme yetenekleri sayesinde daha fazla veri kaynağıyla birleştirilmesiyle tahmin doğruluğunun artırılacağı düşünülmektedir. sayıda şebekeye bağlı dağıtılmış güç üretimi ve spot ticaret piyasasının ikili arka planı altında kısa vadeli net yük tahmin modeli üzerine araştırma yürütmektedir. [77]'de CNN-LSTM modeli, piyasa mekanizması altında yeni enerji güç sisteminin kısa vadeli net yükünün tahmini için kullanılmaktadır. [78]'de ise dalgacık dönüşümlü ve LSTM tabanlı bir DL yöntemi ile binalar için enerji talebi ve arzının entegre modellemesi ve yönetimi için bir programlama çerçevesi önerilmiştir. Bu yöntem, elektrik fiyatı, iklim faktörlerindeki belirsizlik, yenilenebilir enerji kaynaklarının mevcudiyeti (rüzgar, güneş, vb.), binalardaki enerji tüketim kayıpları ve bu parametreler arasındaki doğrusal olmayan ilişkileri saatlik, günlük, haftalık ve aylık aralıklarla analiz eder. Yöntem, yenilenebilir enerji üretiminin, şebekeden enerji ithalatının payının izlenmesini ve kontrol edilmesini sağlamaktadır.

Tablo 6. Akıllı şebekelerde yenilenebilir enerji üretimi tahmini konularında yapılan çalışmalar

| Referans | Yıl | Teknik | İçerik | Katkı |
|----------|------|---------------|--|--|
| [74] | 2016 | MLP-NN ELM | Çalışmada Kanada Saskatchewan'daki Regina bölgesinde kısa vadeli rüzgar hızı tahmini için yapılan uygulamalar anlatılmıştır. | Kısa vadeli rüzgar hızı tahmini. |
| [75] | 2016 | MLP-NN | Girdi olarak bir WRF modeli kullanarak rüzgar tahminleri için çalışma yapılmıştır. | Rüzgar tahminleri. |
| [76] | 2016 | LSTM | Gelişmiş ve pratik olan bir rüzgar gücü tahmin modeli önerilmiştir. | Rüzgar gücü tahmini. |
| [77] | 2022 | CNN- LSTM | Piyasa mekanizması altında yeni enerji güç sisteminin kısa vadeli net yükünün tahmini için kullanılmaktadır. | Kısa vadeli net yükünün tahmini. |
| [78] | 2021 | LSTM | Yöntem, yenilenebilir enerji üretiminin, şebekeden enerji ithalatının payının izlenmesini ve kontrol edilmesini sağlamaktadır. | Binalar için enerji talebi ve arzının entegre modellemesi ve yönetimi. |

3.7. Siber güvenlik

Bilgi ve iletişim teknolojilerinin (*Information and Communication Technologies*, ICT) güç sistemi altyapısına entegrasyonu, akıllı şebekelerin izlenmesi ve kontrol edilmesindeki kaliteyi etkin bir şekilde iyileştirebilirken öte yandan güç sistemlerinin kötü niyetli saldırılara karşı savunmasızlığını da artırmıştır. ICT ile yanlış veri girdisi, güç sistemleri için ciddi bir tehdit haline gelmektedir. Bu güvenlik sorununun nasıl çözüleceği ise oldukça önemli bir araştırma bir konusudur. Tablo 7' de siber güvenlik konusundaki literatür çalışmaları ve detayları özetle verilmiştir [79-113].

[79]' da topoloji değişikliklerini izlemek için Q-öğrenme kullanmış ve sıralı topolojik saldırılarda elektrik güç şebekelerinin savunmasızlığı analiz edilmiştir. [80]' de ise DYY ve güç hırsızlığını gerçek zamanlı olarak tespit etmek

için DL tabanlı algoritmalar önerilmiştir. Bu bağlamda gözlemlenemeyen DYY saldırılarının yüksek boyutlu zamansal davranışları, gerçek zamanlı ölçümlere dayalı olarak potansiyel DYY saldırılarını tespit etmek için rekabetçi derin inanç ağları (*Competitive Deep-Belief Network*, CDBN) kullanılarak belirlenmiştir. [81]' de, coğrafi olarak dağıtılmış PMU' lara gelen gerçek zamanlı ölçüm verilerini analiz ederek veri bozulmasını araştırmak ve tespit etmek için DL kullanılmıştır. Gerçek zamanlı algılama, veri işleme ve uyarlanabilir senaryoları içermektedir. Derinlemesine bilgi akışı ise güç sisteminin diğer zorlukları çözmesine yardımcı olabilir ve elektrik şebekesine izinsiz girişi tespit etmek ya da uzun süre devre dışı bırakmak ise önemli bir durumdur. Bu kapsamda DL teknolojileri, güvenlik açıklarını otomatik olarak tanımlayabilmekte, bir ağa saldırıp buradan elde ettiği bilgileri ağ güvenliğini artırmak için kullanabilmektedir [82].

[83]'te akıllı şebekelerde güvenlik durum analizini gerçekleştirmek için bulanık mantık (*Fuzzy Logic*, FL), oyun teorisi ve RL algoritmalarını entegre eden bir farkındalık mekanizması kullanılmıştır. [84]'te dağıtım şebekesindeki kötü amaçlı gerilim kontrol eylemlerini keşfetmek için YSA tabanlı bir model kullanılmıştır. [85]'te akıllı şebeke güvenliği için birkaç makine öğrenimi tabanlı yöntemi karşılaştırılmış, [86]'da ise akıllı şebeke verilerinin tüm yaşam döngüsündeki güvenlik açıkları ve çözümleri etrafında toplanan bir çalışma yapılmıştır. [87]'de akıllı şebekedeki saldırıyı %96'ya varan bir doğrulukla belirlemek ve sınıflandırmak için kümelenmiş bir gürültü giderici otomatik kodlayıcı (*Stacked Denoising Autoencoder*, SDAE) sinir ağı modeli oluşturulmuştur. [88]'de akıllı şebekede gizli siber aldatma saldırısı adı verilen yeni bir saldırı türünü tespit etmek için SVM tabanlı bir algoritma kullanılmış, [89]'da ise artan miktarda veri ve daha karmaşık sorunları çözmeye ihtiyacıyla yönlendirilen, güçlü bilgisayar donanımının desteğiyle yeni AI algoritmalarının önemli bir şekilde ortaya çıkması sağlanmıştır. [90]'da saldırı tespiti için bir RL yöntemi kullanılmıştır.

[91]'de yeni nesil güç sistemi olan akıllı şebekenin ortaya çıkmasıyla tanıtılan elektrik enerjisi şebekesinde büyük veri ve makine öğreniminin uygulanmasına ilişkin kapsamlı bir çalışma yürütülmüştür. [92]'de siber bir saldırıyı daha iyi performansla tespit etmek için bir izolasyon ormanı yöntemi kullanılmış olup [93]'te otomatik elektrik hırsızlığı tespiti için güç kaynağı kalitesini ve işletme kârını önemli ölçüde etkileyen yeni bir hibrit CNN-rastgele orman modeli geliştirilmiştir. Akıllı şebekelerde güvenlik yönünden geniş hedefleri ve ciddi etkileri olan büyük bir tehdit olan yanlış veri saldırıları, bu sistemleri çok çeşitli güvenlik sorunlarına maruz bırakmıştır. Bu tehdidi etkili bir şekilde tespit etmek için son birkaç yılda makine öğrenme (*Machine Learning*, ML) tabanlı geliştirilen yöntemler [94]'te detaylı bir şekilde tartışılmıştır. Dağıtılmış enerji yönetimi, üretim tahmini, şebeke sağlığı izleme, arıza tespiti, ev enerji yönetimi vb. gibi akıllı şebekedeki çeşitli uygulamaları desteklemek için çok büyük miktarda veri üretmektedir. Bu nedenle de yeni bileşenler ve bilgilerle birlikte yapay zeka, akıllı şebekenin performansını otomatikleştirmek ve daha da iyileştirmek için uygulanabilir. [95]'te, dağıtılmış bir akıllı şebekedeki çeşitli uygulamaları desteklemek için en gelişmiş AI tekniklerinin kapsamlı bir incelemesi sunulmuştur. [96]'da akıllı şebekelerde izinsiz giriş tespiti için tek bir gizli katmana sahip, balina optimizasyonu ile eğitilmiş YSA algoritmasına dayanan bir saldırı tespit modeli kullanılmıştır. [97]'de farklı saatlerde ve yük düzenlerinde geri dönen tehditleri tespit etmek ve bilinen saldırı olaylarının bilgisini aktarmak için etki alanı-düşman eğitimine dayalı yarı denetimli bir tekniğin üstünlüğünü gösterilmiştir. Tespit için ayrıca DVM yöntemi de kullanılmıştır.

[98]'de mikro şebeke kablosuz sensörler veri setinde farklı şiddetteki saldırı aşamalarının kümelenmesi için bir alt ve üst sınır eşikleme algoritması önerilmiştir. Gerçekçi saldırı senaryolarını temsil eden bu veri seti, üç mahalle ve 114 evden oluşan pratik bir konut mikro şebekesinin belirli bir ölçüm altyapısı tarafından toplanmaktadır. ML modeli mimarisi, modifiye simbiyotik organizma arama (*Modified Symbiotic Organisms Search*, MSOS) algoritması ile optimize edilmiş sıradan birçok katmanlı algılayıcıdan (yani YSA) oluşur. MSOS, akıllı bir mikro şebekeye kurulu kablosuz sensörlerden elde edilen verileri kullanarak gizli FDI saldırılarının denetimli sınıflandırması için kullanılmıştır. YSA içindeki eşikleme algoritmalarının bu kombinasyonu, algoritmik karmaşıklıkla

belirli bir düzeye indirerek bilgi işlem kaynaklarının kullanılabilirliğini sağlamaya yardımcı olmuştur.

Kimlik sahtekarlığı saldırıları ve gizli FDI'lar, geleneksel ML modellemesine de konu olan yaygın gizlilik saldırılarıdır. [99]'da karmaşık bir topluluk öğrenme mimarisi geliştirmiştir. Modeller, bir tür ön işleme olarak veri eşleme için kullanılan bir dizi denetimli yaklaşımları ve denetimsiz öğrenme modellerine dayanmaktadır. Çalışma [100]'de boyut azaltma için çekirdek temel bileşen analizinde ve sınıflandırmada aşırı rastgele ağaç algoritması kullanan bir mimariye sahip akıllı şebeke ağları için bir siber saldırı tespit modeli oluşturmuştur.[101]'de güç sistemlerindeki çeşitli saldırı türlerini tespit etmek için Bi-RNN kullanılmıştır. Öğrenme modelinin değerlendirilmesi, kötü amaçlı yazılım, FDI ve devre dışı bırakma yeniden birleştirme saldırıları benzetim ile yapılmıştır. Bu amaçla IEEE 1815.1 standardını ana karar kriteri olarak kullanmışlardır. Bu standart, dağıtılmış ağ protokolü ile elektrik tesisatı otomasyonu (IEC 61.850) için iletişim ağları ve sistemleri arasındaki eşlemeyi açıklamaktadır. Bu çalışmada, çalışan bir Kore trafo merkezinden yaklaşık üç günlük ağ paketi toplama işlemi gerçekleştirilmiştir.

[102]'de hem blockchain hem de derin öğrenmeye dayalı bir gizliliği koruma stratejisi önerilmiştir. Blockchain teknolojisi belirli bir şifreleme şemasını izleyerek gerçek verileri toplarken, devreye giren DL modeli ile özellik çıkarma ve yaklaşıklıklaştırma işlemlerini yapar. Özellik çıkarımı, varyasyonel otokodlayıcı (*Variational AutoEncoder*, VAE) aracılığıyla yapılmıştır. Yaklaştırma işlemi bir LSTM kullanılarak gerçekleştirilmiştir.[103]'te ise gerilim kontrol algoritmasını (yani kötü amaçlı kontrol) bozabilecek gerilim düzenlemesinde saldırıların tespiti üzerine bir çalışma yapılmıştır. Bu nedenle, bir akıllı şebeke ağındaki iletim hatlarını teşhis etmek için RF ve lojistik regresyon (*Logistic Regression*, LR) algoritmalarını içeren küçük ölçekli ML mimarisinin eğitimini araştırmışlardır. Bu çalışmaya iki veri seti/sistemi dahil edilmiştir. Bir bütünlük saldırısı tespitine dayalı hizmet reddi saldırısı (*Denial-of-Service Attack*, DoS), çalışma [104]'te tartışılmıştır ve geniş alanlı bir güç sistemi için bir sönümlenme kontrol hafifletme algoritması önerilmiştir. [105]'te darbe, rampa, röle açma ve tekrarlama saldırıları gibi koordineli ve ilkel saldırılar ana bütünlük saldırıları olarak ele alınmış ve incelenmiştir.

[106]'da ML araçlarıyla geniş alanlı güç sistemlerinde siber saldırı tespiti üzerine çalışılmıştır. Özellik çıkarımı için varyasyon modu ayrıştırma (*Variational Mode Decomposition*, VMD) gibi sinyal işleme teknikleri kullanılırken sınıflandırma için karar ağaçları kullanılmıştır. [107]'de DC mikro şebekelerin teşhisi ve FDI saldırılarını tespit etmek için bir dalgacık serisi ve tekil değer ayrıştırması (*Singular Value Decomposition*, SVD) içindeki DL yöntemleri birleştirilmiştir. Modeli gerçekleştirmek için küçük bir elektrik şebekesinden kaydedilen veriler kullanılmıştır. Derin ağlar, üretici modelleri (otokodlayıcılar) ve ayırt edici modelleri bir terim altında birleştiren bir tür DBN içinde inşa edilmiştir. [108]'de FDI tespiti için bir mevsimsel otoregresif entegre hareketli ortalama (*Seasonal AutoRegressive Integration Moving Average*, SARIMA) modelini dinamik olarak ayarlanmış bir eşik ve LSTM ile bütünlük sağlayan hibrit bir ML modeli önerilmiştir. Algoritma, siber saldırılar, kötü niyetli çalışma davranışı ve ağ anormallikleri dahil olmak üzere bir dizi senaryo için güç üretim sistemleri, gaz boru hattı sistemleri ve kentsel raylı sistemler olmak üzere üç tipik sistem ile doğrulanmıştır.

[109]'da akıllı şebekelerin siber saldırısı ve/veya anormallikleri için bir topluluk öğrenme algoritması önerilmiştir. Tüm tahmin algoritması, farklı öğrenme birimlerinden alınan sonuçları birleştirmiştir. Her birim LSTM, RNN ve GRU olmak üzere üç farklı DL algoritması tarafından tanımlanmıştır.[110]'da DC-DC ve DC-AC dönüştürücüler dahil olmak üzere akıllı şebekelerdeki PV sistemlerine yönelik veri bütünlüğü saldırıları için derin sıralı öğrenmeye dayalı bir teşhis çözümü önerilmiştir. Çok katmanlı LSTM, PV sistemlerindeki akım ve gerilim sensörlerinden gelen elektrik verilerinden yararlanmak için kullanılmış ve kapsamlı nicel analiz ile bir PV akıllı şebeke kıyaslama modelinde değerlendirilmiştir. Önerilen algoritmayı analiz etmek için bir güneş enerjisi çiftliği elektrik şebekesinin benzetim modeli oluşturulmuştur. [111]'de temel olarak tüketim tarafını inceleyen önceki çalışmalara kıyasla tamamen yeni olan dağıtık üretim tarafında elektrik hırsızlıkları araştırılmıştır. [112]'de şiddetli FDI siber saldırılarının varlığı altında bile akıllı güç şebekelerinde hat derecelendirmesini dinamik olarak tespit edebilen bir öğrenme algoritması önerilmiştir. Bu çalışmada Ghadamgah ve Binalood rüzgar santrallerini araştırılmış ve tahmin modelinin ana mimarisi olarak bir karar ağacı topluluğu kullanılmıştır.[113]'te ise akıllı şebekelerde enerji santrallerinin kötü niyetli kontrolünde saldırı tespiti için yeni bir hibrit yöntem tanımlanmış olup FDI enjeksiyonu ve DoS olmak üzere iki tür saldırıyı belirlemek için denetimsiz bir hiyerarşik kümeleme süreci benimsenmiştir.

Tablo 7. Akıllı şebekelerde siber güvenlik konularında yapılan çalışmalar

| Referans | Yıl | İçerik | Kullanılan Teknik |
|----------|------|---|------------------------|
| [79] | 2017 | Elektrik güç şebekelerinin savunmasızlığı | Q-öğrenme |
| [80] | 2017 | DYY ve güç hırsızlığını gerçek zamanlı olarak tespit etmek | DL CDBN |
| [81] | 2016 | Gerçek zamanlı ölçüm verilerini analiz ederek veri bozulmasını araştırmak | DL |
| [82] | 2018 | Ağ güvenliğini artırmak | DL |
| [83] | 2016 | Saldırı tespiti | FL, oyun teorisi, RL |
| [84] | 2016 | Kötü niyetli gerilim kontrol eylemlerini tespit etme | ANN |
| [85] | 2016 | Saldırı tespiti | KNN, SVM |
| [86] | 2016 | Araştırma | Veriye dayalı yaklaşım |
| [87] | 2018 | Saldırı algılama | SDAE |
| [88] | 2018 | Gizli siber aldatma saldırısı | SVM |

| | | | |
|-------|------|---|--|
| [89] | 2018 | Araştırma | DL, RL |
| [90] | 2018 | Saldırı algılama | RL |
| [91] | 2019 | Araştırma | Büyük veri, ML |
| [92] | 2019 | Gizli siber aldatma saldırısı | İzolasyon |
| [93] | 2019 | Elektrik hırsızlığı tespiti | CNN, rastgele forest |
| [94] | 2020 | Araştırma | ML |
| [95] | 2020 | Araştırma | AL |
| [96] | 2020 | Saldırı tespiti | ANN |
| [97] | 2020 | Saldırı tespiti | Etki Alanı-Çekişmeli Öğrenme |
| [98] | 2020 | Farklı şiddetteki saldırı aşamalarının kümelmesi | MSOS |
| [99] | 2020 | Karmaşık bir topluluk öğrenme mimarisi | Denetimli yaklaşımlayıcı ve denetimsiz öğrenme modelleri |
| [100] | 2020 | Çekirdek temel bileşen analizi ve sınıflandırma | Aşırı rastgele ağaç algoritması |
| [101] | 2020 | Siber saldırı tespit modeli | Bi-RNN |
| [102] | 2019 | Blockchain teknolojisi gizliliği | LSTM |
| [103] | 2021 | Voltaj kontrol algoritmasını | RF ve LR |
| [104] | 2020 | Hizmet reddi saldırısı | SVM gömülü katmanlı DT |
| [105] | 2020 | Koordineli ve ilkel saldırılar | Sönümlenme kontrol hafifletme algoritması |
| [106] | 2021 | Güç sistemlerinde siber saldırı tespiti | VMD ve DT |
| [107] | 2021 | DC mikro şebekelerin ve FDI saldırı teşhisi | Dalgacık serisi, tekil değer ayrıştırması, DBN |
| [108] | 2021 | FDI tespiti | SARIMA, LSTM |
| [109] | 2022 | Siber saldırısı ve/veya anormallikleri | LSTM, RNN ve GRU |
| [110] | 2021 | PV sistemlerde olası bir veri bütünlüğü saldırısı | Çok katmanlı LSTM |
| [111] | 2020 | Dağıtık üretim tarafında elektrik hırsızlıkları | Araştırma |

| | | | |
|-------|------|---|---------------|
| [112] | 2022 | Şiddetli FDI siber saldırıları | DT topluluğu |
| [113] | 2021 | Enerji santrallerinin kötü niyetli kontrolü | Hibrit yöntem |

4. Sonuç

DL, RL ve DRL son yıllarda birçok farklı alanda büyük ilgi görmekte ve çeşitli uygulama alanları bulmaktadır. Akıllı şebekeler de DL, RL ve DRL' nin en önemli potansiyel uygulama alanlarından biridir. Bu alanda pek çok sayıda makale ve tez çalışmaları yayımlanmıştır. Bu çalışmada DL tekniklerinin akıllı şebeke uygulamalarında kullanımına ilişkin bir literatür araştırılması yapılmış, teknolojik açıdan tahmin, hata tespiti, kontrol, karar verme desteği gibi alanlarda uygulanabilirliği konusunda ümit vadeden bir noktada oldukları sonucuna varılmıştır. Yapılan çalışmalar, akıllı şebekelerde ekipman kusur/arıza tespiti, güvenlik değerlendirmesi ve kontrolü, siber güvenlik, savunma, talep yanıtı ve yük tahmini gibi kritik ve önemli birçok alanı kapsamaktadır.

Yapılacak çalışmalarda, özellikle siber güvenlik alanında bu yöntemlerin geliştirilmesinde ve etkin kullanımında esas dayanak nokta olan gerçek verilerin toplanmasındaki zorlukların giderilmesi problemi önemli bir yer bulacaktır. Bu bağlamda sanal gerçeklik tabanlı siber saldırı benzetimlerinin yapılması gerçeğe benzer önemli özelliklerin toplanmasına yardımcı olabilecek bir öneri olabilir. İlaveten, GAN'lar gibi güçlü üretken modeller dahil edilerek verilerden yeni örnekler çıkarılması da sağlanabilir. Özellikle derin ağırlı eğitirken, geleneksel geri yayılım algoritmalarından daha basit ve daha etkili eğitim araçları geliştirerek hesaplama maliyetinin azaltılması da önemli bir hedef olacaktır. Şebeke koşullarının daha gerçekçi olarak irdelenebilmesine katkıda bulunmak için iyi bilinen endüstriyel kontrol protokollerinin yanı sıra günümüzde önemli bir uygulama alanı bulan nesnelerin interneti konusu üzerinde değerlendirmeler ve öneriler yapılabilir. Tüm bu geliştirmelerde kritik nokta yine büyük veri setlerinin oluşturulması olacaktır.

Sonuç olarak, akıllı şebeke problemlerinde AI ve DL tabanlı yaklaşımların kullanımının şebeke güvenilirliği ve dayanıklılığındaki birtakım iyileştirmeler gibi pek çok alanda avantajlar sağladığı görülmüş, bu teknolojilerin uygulanabilirliklerinin artırılması ve elde edilen performansların daha da iyileştirilmesi için yeni araştırmaların da literatüre kazandırılması gerektiği sonucuna varılmış, bu çalışmaların hangi noktalarda odaklanması gerektiği ile ilgili önerilerde bulunulmuştur.

5. Kaynaklar

- [1] Smart Grid System Report, U.S. Department of Energy, Çevrimiçi: https://www.energy.gov/sites/prod/files/2019/02/f59/Smart%20Grid%20System%20Report%20November%202018_1.pdf (erişim 25 Eylül 2022).
- [2] D. Zhang, X. Han and C. Deng, "Review on the research and practice of deep learning and reinforcement learning

in smart grids," in CSEE Journal of Power and Energy Systems, vol. 4, no. 3, pp. 362-370, September 2018, doi: 10.17775/CSEEJPES.2018.00520.

- [3] Q. V. Pham, M. Liyanage, N. Deepa, , M. VVSS, S. Reddy, P. K. R. Maddikunta, and W. J. Hwang, Deep Learning For Intelligent Demand Response And Smart Grids: A Comprehensive Survey, Arxiv Preprint Arxiv:2101.08013, 20 Jan, 2021, doi: <https://doi.org/10.48550/arXiv.2101.08013>
- [4] R. S. Sutton, and A. G. Barto, Reinforcement Learning an Introduction, Cambridge, MA: MIT Press, 1998.
- [5] X. S. Chen, and Y. M. Yang, "Reinforcement Learning: Survey of Recent Work," Application Research of Computers, vol. 27, no. 8, pp. 2834–2838, Chinese, August, 2010.
- [6] D. Zhang, X. Han and C. Deng, "Review on the Research and Practice of Deep Learning and Reinforcement Learning in Smart Grids," in CSEE Journal of Power and Energy Systems, vol. 4, no. 3, pp. 362-370, September 2018, doi: 10.17775/CSEEJPES.2018.00520.
- [7] I. Voynichka, Machine learning for the smart grid, Erişim: <http://cs229.stanford.edu/proj2014/Iliana%20Voynichka,%20Machine%20Learning%20for%20the%20Smart%20Grid.pdf>.
- [8] Xishuang Dong, Lijun Qian and Lei Huang, "Short-term load forecasting in smart grid: A combined CNN and K-means clustering approach," 2017 IEEE International Conference on Big Data and Smart Computing (BigComp), 2017, pp. 119-125, doi: 10.1109/BIGCOMP.2017.7881726.
- [9] Y. He, J. Deng and H. Li, "Short-Term Power Load Forecasting with Deep Belief Network and Copula Models," 2017 9th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2017, pp. 191-194, doi: 10.1109/IHMSC.2017.50.
- [10] T. Hossen, A. S. Nair, R. A. Chinnathambi and P. Ranganathan, "Residential Load Forecasting Using Deep Neural Networks (DNN)," 2018 North American Power Symposium (NAPS), 2018, pp. 1-5, doi: 10.1109/NAPS.2018.8600549.
- [11] V. Mnih, H. Larochelle, and G. Hinton, "Conditional restricted Boltzmann machines for structured output prediction," in Proceedings of the International Conference on Uncertainty in Artificial Intelligence, Barcelona, Spain, Jul. 14–17, 2011.
- [12] G. W. Taylor, G. E. Hinton, and S. T. Roweis, "Two distributed-state models for generating high dimensional time series," Journal of Machine Learning Research, vol. 12, pp. 1025–1068, Mar. 2011.
- [13] D. L. Marino, K. Amarasinghe and M. Manic, "Building energy load forecasting using deep neural networks," in IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society, Yokohama, Japan, Oct. 23–26, 2016.

- [14] K. Amarasinghe, D. L. Marino, and M. Manic, "Deep neural networks for energy load forecasting," in The 26th IEEE International Symposium on Industrial Electronics (ISIE), Edinburgh, Scotland, UK, Jun. 19–21, 2017.
- [15] T. Sogabe, H. Ichikawa et al., "Optimization of decentralized renewable energy system by weather forecasting and deep machine learning techniques," in The 2016 IEEE Innovative Smart Grid Technologies-Asia (ISGT-Asia), Melbourne, Australia, Nov. 28–Dec.1, 2016.
- [16] S. Hosein and P. Hosein, "Load forecasting using deep neural networks," presented at 2017 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT). Erişim: Available: <http://www.rndrepository.com/smartgriduwi/files/smartgridcomm2016.pdf>.
- [17] A. Dedinec, S. Filiposka, A. Dedinec, and L. Kocarev, "Deep belief network based electricity load forecasting: An analysis of the Macedonian case," *Energy*, vol. 115, part 3, pp. 1688–1700, Nov. 2016.
- [18] X. Qiu, L. Zhang, Y. Ren, P. N. Suganthan, and G. Amaratunga, "Ensemble deep learning for regression and time series forecasting," in 2014 IEEE Symposium on Computational Intelligence in Ensemble Learning (CIEL), 2014, pp. 1–6.
- [19] J. Zhu, Z. Yang, Y. Chang, Y. Guo, K. Zhu, and J. Zhang, "A novel LSTM based deep learning approach for multi-time scale electric vehicles charging load prediction," in 2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia). IEEE, 2019, pp. 3531–3536.
- [20] L. Tang, Y. Yi, and Y. Peng, "An ensemble deep learning model for short-term load forecasting based on ARIMA and LSTM," in 2019 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm). IEEE, 2019, pp. 1–6.
- [21] S. Wang, X. Wang, S. Wang, and D. Wang, "Bi-directional long shortterm memory method based on attention mechanism and rolling update for short-term load forecasting," *International Journal of Electrical Power & Energy Systems*, vol. 109, pp. 470–479, 2019.
- [22] A. Khwaja, A. Anpalagan, M. Naeem, and B. Venkatesh, "Joint bagged-boosted artificial neural networks: Using ensemble machine learning to improve short-term electricity load forecasting," *Electric Power Systems Research*, vol. 179, p. 106080, 2020.
- [23] H. Dagdougui, F. Bagheri, H. Le, and L. Dessaint, "Neural network model for short-term and very-short-term load forecasting in district buildings," *Energy and Buildings*, vol. 203, p. 109408, 2019.
- [24] J. Kim, J. Moon, E. Hwang, and P. Kang, "Recurrent inception convolution neural network for multi short-term load forecasting," *Energy and Buildings*, vol. 194, pp. 328–341, 2019.
- [25] Y. Yang, J. Che, C. Deng, and L. Li, "Sequential grid approach based support vector regression for short-term electric load forecasting," *Applied energy*, vol. 238, pp. 1010–1021, 2019.
- [26] Y. Hu, J. Li, M. Hong, J. Ren, R. Lin, Y. Liu, M. Liu, and Y. Man, "Short term electric load forecasting model and its verification for process industrial enterprises based on hybrid GA-PSO-BPNN algorithm A case study of papermaking process," *Energy*, vol. 170, pp. 1215–1227, 2019.
- [27] X. Tang, Y. Dai, Q. Liu, X. Dang, and J. Xu, "Application of bidirectional recurrent neural network combined with deep belief network in short-term load forecasting," *IEEE Access*, vol. 7, pp. 160 660–160 670, 2019.
- [28] T. Ouyang, Y. He, H. Li, Z. Sun, and S. Baek, "Modeling and forecasting short-term power load with copula model and deep Belief network," *IEEE Transactions on Emerging Topics in Computational Intelligence*, vol. 3, no. 2, pp. 127–136, 2019.
- [29] W. Kong, Z. Y. Dong, B. Wang, J. Zhao, and J. Huang, "A practical solution for non-intrusive type II load monitoring based on deep learning and post-processing," *IEEE Transactions on Smart Grid*, vol. 11, no. 1, pp. 148–160, 2019.
- [30] M. Sun, T. Zhang, Y. Wang, G. Strbac, and C. Kang, "Using bayesian deep learning to capture uncertainty for residential net load forecasting," *IEEE Transactions on Power Systems*, vol. 35, no. 1, pp. 188–201, 2019.
- [31] G. Sideratos, A. Ikononopoulos, and N. D. Hatzigiorgiou, "A novel fuzzy-based ensemble model for load forecasting using hybrid deep neural networks," *Electric Power Systems Research*, vol. 178, p. 106025, 2020.
- [32] H. Chen, S. Wang, S. Wang, and Y. Li, "Day-ahead aggregated load forecasting based on two-terminal sparse coding and deep Neural network fusion," *Electric Power Systems Research*, vol. 177, p. 105987, 2019.
- [33] Y. Huang, N. Wang, T. Hao, W. Gao, C. Huang, J. Li, and J. Zhan, "Load CNN: A efficient green deep learning model for day-ahead individual resident load forecasting," *arXiv preprint arXiv:1908.00298*, 2019.
- [34] M. Cai, M. Pipattanasomporn, and S. Rahman, "Day-ahead buildinglevel load forecasts using deep learning vs. traditional time-series techniques," *Applied energy*, vol. 236, pp. 1078–1088, 2019.
- [35] A. Gasparin, S. Lukovic, and C. Alippi, "Deep learning for time series forecasting: The electric load case," *arXiv preprint arXiv:1907.09207*, 2019.
- [36] Y. Yang, W. Li, T. A. Gulliver, and S. Li, "Bayesian deep learning based probabilistic load forecasting in smart grids," *IEEE Transactions on Industrial Informatics*, 2019.
- [37] M. Dong and L. Grumbach, "A hybrid distribution feeder long-term load forecasting method based on sequence prediction," *IEEE Transactions on Smart Grid*, vol. 11, no. 1, pp. 470–482, 2019.

- [38] S. Chapaloglou, A. Nesiadis, P. Iliadis, K. Atsonios, N. Nikolopoulos, P. Grammelis, C. Yiakopoulos, I. Antoniadis, and E. Kakaras, "Smart energy management algorithm for load smoothing and peak shaving based on load forecasting of an island's power system," *Applied energy*, vol. 238, pp. 627–642, 2019.
- [39] L. Wen, K. Zhou, S. Yang, and X. Lu, "Optimal load dispatch of community microgrid with deep learning based solar power and load forecasting," *Energy*, vol. 171, pp. 1053–1065, 2019.
- [40] F. B. Naceur, A. J. Telmoudi and M. A. Mahjoub, "A Comparative study of three AI prediction algorithms based on measured databases for an optimal Smart Grid," 2022 8th International Conference on Control, Decision and Information Technologies (CoDIT), 2022, pp.1597-1602, doi:10.1109/CoDIT55151.2022.9804155.
- [41] C. Li et al., "Interpretable Memristive LSTM Network Design for Probabilistic Residential Load Forecasting," in *IEEE Transactions on Circuits and Systems I: Regular Papers*, vol. 69, no. 6, pp. 2297-2310, June 2022, doi: 10.1109/TCSI.2022.3155443.
- [42] Khan, A.A.; Beg, O.A.; Jin, Y.; Ahmed, S. An Explainable Intelligent Framework for Anomaly Mitigation in Cyber-Physical Inverter-based Systems. *arXiv 2022*, arXiv:17912006.v1.
- [43] B. V. Mbuwir, F. Ruelens, F. Spiessens et al., "Battery energy management in a microgrid using batch reinforcement learning," in *International workshop of Energy-Open 2017*, Enschede, the Netherlands, May 18–19, 2017.
- [44] B. V. Mbuwir, F. Ruelens, F. Spiessens et al. (2017, Nov.). Reinforcement learning-based battery energy management in a solar microgrid. *Energies*. [Online]. Available: <https://energy-open.nl/local/abstracts/012mbuwir.pdf>.
- [45] X. Qiu, T. A. Nguyen and M. L. Crow, "Heterogeneous Energy Storage Optimization for Microgrids," in *IEEE Transactions on Smart Grid*, vol. 7, no. 3, pp. 1453-1461, May 2016, doi: 10.1109/TSG.2015.2461134.
- [46] Wenninger, S.; Kaymakci, C.; Wiethe, C. Explainable long-term building energy consumption prediction using QLatice. *Appl. Energy* 2022, 308, 118300.
- [47] Pedro Paulo Marques do Nascimento, "Application of deep learning techniques on HILM," M.S. thesis, COPPE/UFRJ, Brazil, 2016.
- [48] D. C. Mocanu, E. Mocanu, P. H. Nguyen et al., "Big IoT data mining for real-time energy disaggregation in buildings," in *IEEE International Conference on Systems, Man, and Cybernetics, SMC 2016*, Budapest, Hungary, Oct. 9–12, 2016.
- [49] K. Tornai, A. Olah, R. Drenyovszki et al., "Recurrent neural network based user classification for smart grids," in *IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*, Arlington, VA, Washington D.C., 2017.
- [50] Z. Wen, D. O' Neill, and H. Maei, "Optimal demand response using device-based reinforcement learning," *IEEE Transactions on Smart Grid*, vol. 6, no. 5, pp. 2312–2324, Sep. 2015.
- [51] G. Costanzo, S. Iacovella, F. Ruelens, T. Leurs, and B. Claessens, "Experimental analysis of data-driven control for a building heating system," *Sustainable Energy Grids and Networks*, vol. 6, pp. 81–90, 2016.
- [52] F. Ruelens, B. J. Claessens, S. Vandael, S. Iacovella, P. Vingerhoets, and R. Belmans, "Demand response of a heterogeneous cluster of electric water heaters using batch reinforcement learning," in *2014 Power Systems Computation Conference*, Wroclaw, Poland, Aug. 18–22, 2014.
- [53] E. C. Kara, M. Berges, B. Krogh, and S. Kar, "Using smart devices for system-level management and control in the smart grid: A Reinforcement learning framework," in *2012 IEEE Third International Conference on Smart Grid Communications (SmartGridComm)*, Taiwan, China, Nov. 5–8, 2012.
- [54] G. Almannonny, S. Bu and J. Yang, "Dynamic Pricing Integrated Demand Response for Multiple Energy Carriers with Deep Reinforcement Learning," 2022 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe), 2022, pp. 1-6, doi: 10.1109/ISGT-Europe54678.2022.9960326.
- [55] G. Zhang and B. Sikdar, "Ensemble and Transfer Adversarial Attack on Smart Grid Demand-Response Mechanisms," 2022 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm), 2022, pp.53-58,doi: 10.1109/SmartGridComm52983.2022.9960966.
- [56] Z. B. Zhao, X. Q. Fan, G. Z. Xu et al., "Multi-patch deep features for power line insulator status classification from aerial images," *IEEE International Joint Conference on Neural Networks (IJCNN)*, New Delhi, India, Jul. 24–29, 2016.
- [57] P. P. Reddy and M. M. Veloso, "Strategy learning for autonomous agents in smart grid markets," *Proceedings of the Twenty-Second international joint conference on Artificial Intelligence*, vol. 2, pp. 1446–1451, Jul. 2011.
- [58] X. Peng, F. L. Pan, Y. C. Liang et al., "Fault detection algorithm for power distribution network based on sparse self-encoding neural network," in *2017 International Conference on Smart Grid and Electrical Automation (ICSGEA)*, Changsha, China, May 27–28, 2017.
- [59] Y. Song, D. Liu, H. Liaob, and Y. Penga, "A hybrid statistical data-driven method for on-line joint state estimation of lithium-ion batteries," *Energy for Sustainable Development*, vol. 261, p. 114408, 2020.
- [60] R. Chen, X. Li, H. Zhong, and M. Fei, "A novel online detection method of data injection attack against dynamic state estimation in smart grid," *Neurocomputing*, vol. 344, pp. 73–81, 2019.

- [61] T. Liu and T. Shu, "Adversarial false data injection attack against nonlinear AC state estimation with ANN in smart grid," arXiv:1906.11328, 2019.
- [62] W. Zhou, O. Ardakanian, H.-T. Zhang, and Y. Yuan, "Bayesian learning-based harmonic state estimation in distribution systems with smart meter and DPMU data," IEEE Transactions On Smart Grid, vol. 11, no. 1, pp. 832–845, 2020.
- [63] K. R. Mestav, J. Luengo-Rozas, and L. Tong, "Bayesian state estimation for unobservable distribution systems via deep learning," IEEE Transactions On Power Systems, vol. 34, no. 6, pp. 4910–4920, 2019.
- [64] S. Basumallik and S. Ma, Rui Eftekharijad, "Packet-data anomaly detection in PMU-based state estimator using convolutional Neural network," Electrical Power and Energy Systems, vol. 107, pp. 690–702, 2019.
- [65] L. Zhang, G. Wang, and G. B. Giannakis, "Real-time power system state estimation and forecasting via deep unrolled neural networks," IEEE Transactions On Signal Processing, vol. 67, no. 15, pp. 4069–4077, 2019.
- [66] G. Wang, H. Zhu, G. B. Giannakis, and J. Sun, "Robust power system state estimation from rank-one measurements," IEEE Transactions On Control of Network Systems, vol. 6, no. 4, pp. 1391–1403, 2019.
- [67] K. R. Mestav and L. Tong, "State estimation in smart distribution systems with deep generative adversary networks," IEEE International Conference on Smart Grid Communications (SmartGridComm), 2019.
- [68] H. I. Hegazy, A. S. T. Eldien, M. M. Tantawy, M. M. Fouda and H. A. TagEldien, "Online Location-based Detection of False Data Injection Attacks in Smart Grid Using Deep Learning," 2022 IEEE International Conference on Internet of Things and Intelligence Systems (IoTaIS), 2022, pp. 153-159, doi: 10.1109/IoTaIS56727.2022.9975951.
- [69] R. Panigrahi, N. R. Patne, S. Pemmada and A. D. Manchalwar, "Prediction of Electric Energy Consumption for Demand Response using Deep Learning," 2022 International Conference on Intelligent Controller and Computing for Smart Power (ICICCCSP), 2022, pp.1-6, doi: 10.1109/ICICCCSP53532.2022.9862353.
- [70] P. E. A. Cardoso, "Deep learning applied to PMU data in power systems," Ph.D. thesis, Faculdade De Engenharia Da Universidade Do Porto, 2017.
- [71] X. Z. Wang, J. Zhou, Z. L. Huang et al., "A multilevel deep learning method for big data analysis and emergency management of power system," IEEE International Conference on Big Data Analysis (ICBDA), Hangzhou, China, Mar. 12–14, 2016:.
- [72] W. Liu, D. X. Zhang, X. Y. Wang et al., "A decision making strategy for generating unit tripping under emergency circumstances based on deep reinforcement learning," Proceedings of the CSEE, vol. 38, no. 1, pp.109–119, Jan. 2018. (in Chinese).
- [73] S. Bodda, A. Thawait and P. Agnihotri, "Comparative Analysis of Deep Learning and Machine Learning Techniques for Power System Fault type Classification and Location Prediction," 2022 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS), 2022, pp. 1-9, doi: 10.1109/IEMTRONICS55184.2022.9795781.
- [74] B. Ak, O. Fink and E. Zio, "Two machine learning approaches for short-term wind speed time-series prediction," IEEE Transactions on Neural Networks and Learning Systems, vol. 27, no.8, pp.1734–1747, Aug. 2016.
- [75] Y. Q. Li, C. B. Dai, T. X. Wang, Z. Zhou et al., "Separate wind power and ramp predictions based on meteorological variables and clustering method," in 2016 IEEE 6th International Conference on Power Systems (ICPS), New Delhi, India, Mar. 4–6, 2016.
- [76] X. Y. Qu, X. N. Kang, C. Zhang et al., "Short-term prediction of wind power based on deep long short-term memory," in 2016 IEEE PES Asia- Pacific Power and Energy Conference, Xi'an, China, Oct. 25–28, 2016.
- [77] Z. Yang, X. Li, X. Kong, Z. Li, N. Yuan and G. Li, "A Method of Short-Term Load Prediction of Renewable Energy Power System Based on CNNLSTM," 2022 25th International Conference on Electrical Machines and Systems (ICEMS), 2022, pp. 1-5, doi: 10.1109/ICEMS56177.2022.9983344.
- [78] S. A. Nabavi, N. H. Motlagh, M. A. Zaidan, A. Aslani and B. Zakeri, "Deep Learning in Energy Modeling: Application in Smart Buildings With Distributed Energy Generation," in IEEE Access, vol. 9, pp. 125439-125461, 2021, doi: 10.1109/ACCESS.2021.3110960.
- [79] J. Yan, H. B. He, X. N. Zhong and Y. F. Tang, "Q-learning-based vulnerability analysis of smart grid against sequential topology attacks," IEEE Transactions on Information Forensics and Security, vol. 12, no.1, pp.200–210, Jan. 2017.
- [80] Y. B. He, G. J. Mendis, and J. Wei, "Real-time detection of false data injection attacks in smart grid: a deep learning-based intelligent mechanism," IEEE Transactions on Smart Grid, vol. 8, no. 5, pp. 2505–2516, Sep. 2017.
- [81] J. Wei and G. J. Mendis, "A deep learning-based cyber-physical strategy to mitigate false data injection attack in smart grids," Joint Workshop on Cyber-Physical Security and Resilience in Smart Grids (CPSR-SG), Vienna, Austria, Apr. 12, 2016.
- [82] H. Sugiyama, "Pulsed Power Network with Scalable Operating Procedure Based on Potential Gradient," 2018 IEEE 61st International Midwest Symposium on Circuits and Systems (MWSCAS), 2018, pp. 552-553, doi: 10.1109/MWSCAS.2018.8624105.
- [83] J. Wu, K. Ota, M. Dong, J. Li and H. Wang, "Big Data Analysis-Based Security Situational Awareness for Smart Grid," in IEEE Transactions on Big Data, vol. 4, no. 3, pp. 408-417, 1 Sept. 2018, doi: 10.1109/TBDDATA.2016.2616146.

- [84] A. M. Kosek, "Contextual anomaly detection for cyber-physical security in Smart Grids based on an artificial neural network model," 2016 Joint Workshop on Cyber-Physical Security and Resilience in Smart Grids (CPSR-SG), 2016, pp. 1-6, doi: 10.1109/CPSRSG.2016.7684103.
- [85] M. Ozay, I. Esnaola, F. T. Yarman Vural, S. R. Kulkarni and H. V. Poor, "Machine Learning Methods for Attack Detection in the Smart Grid," in IEEE Transactions on Neural Networks and Learning Systems, vol. 27, no. 8, pp. 1773-1786, Aug. 2016, doi: 10.1109/TNNLS.2015.2404803.
- [86] S. Tan, D. De, W. -Z. Song, J. Yang and S. K. Das, "Survey of Security Advances in Smart Grid: A Data Driven Approach," in IEEE Communications Surveys & Tutorials, vol. 19, no. 1, pp. 397-422, Firstquarter 2017, doi: 10.1109/COMST.2016.2616442.
- [87] L. Zhou, X. Ouyang, H. Ying, L. Han, Y. Cheng, T. Zhang, Cyber-attack classification in smart grid via deep neural network. In Proceedings of the 2nd International Conference on Computer Science and Application Engineering, Hohhot, China, 22–24 October 2018; pp. 1–5, doi : doi/10.1145/3207677.3278054.
- [88] S. Ahmed, Y. Lee, S. -H. Hyun and I. Koo, "Feature Selection-Based Detection of Covert Cyber Deception Assaults in Smart Grid Communications Networks Using Machine Learning," in IEEE Access, vol. 6, pp. 27518-27529, 2018, doi: 10.1109/ACCESS.2018.2835527.
- [89] D. Zhang, X. Han and C. Deng, "Review on the research and practice of deep learning and reinforcement learning in smart grids," in CSEE Journal of Power and Energy Systems, vol. 4, no. 3, pp. 362-370, September 2018, doi: 10.17775/CSEEJPES.2018.00520.
- [90] Z. Ni and S. Paul, "A Multistage Game in Smart Grid Security: A Reinforcement Learning Solution," in IEEE Transactions on Neural Networks and Learning Systems, vol. 30, no. 9, pp. 2684-2695, Sept. 2019, doi: 10.1109/TNNLS.2018.2885530.
- [91] E. Hossain, I. Khan, F. Un-Noor, S. S. Sikander and M. S. H. Sunny, "Application of Big Data and Machine Learning in Smart Grid, and Associated Security Concerns: A Review," in IEEE Access, vol. 7, pp. 13960-13988, 2019, doi: 10.1109/ACCESS.2019.2894819.
- [92] S. Ahmed, Y. Lee, S. H. Hyun and I. Koo, "Unsupervised Machine Learning-Based Detection of Covert Data Integrity Assault in Smart Grid Networks Utilizing Isolation Forest," in IEEE Transactions on Information Forensics and Security, vol. 14, no. 10, pp. 2765-2777, Oct. 2019, doi: 10.1109/TIFS.2019.2902822.
- [93] S. Li, Y. Han, X. Yao, S. Yingchen, J. Wang, Q. Zhao, Electricity theft detection in power grids with deep learning and random forests, Journal of Electrical and Computer Engineering, Volume 2019, Article ID 4136874, 12 pages, doi: https://doi.org/10.1155/2019/4136874
- [94] L. Cui, Y. Qu, L. Gao, G. Xie, S. Yu, Detecting false data attacks using machine learning techniques in smart grid: A survey, Journal of Network and Computer Applications, Volume 170, 15 November 2020, 102808, doi: <https://doi.org/10.1016/j.jnca.2020.102808>.
- [95] S. S. Ali, B.J. Choi, State-of-the-Art Artificial Intelligence Techniques for Distributed Smart Grids: A Review, Electronics 2020, 9, 1030, doi: <https://doi.org/10.3390/electronics9061030>.
- [96] L. Haghnegahdar, Y. A Wang, Whale optimization algorithm-trained artificial neural network for smart grid cyber intrusion detection, Neural Comput. Appl. 2020, 32, 9427–9441, doi: <https://doi.org/10.1007/s00521-019-04453-w>.
- [97] Y. Zhang and J. Yan, "Semi-Supervised Domain-Adversarial Training for Intrusion Detection against False Data Injection in the Smart Grid," 2020 International Joint Conference on Neural Networks (IJCNN), 2020, pp. 1-7, doi: 10.1109/IJCNN48605.2020.9207525.
- [98] A. Kavousi-Fard, W. Su and T. Jin, "A Machine-Learning-Based Cyber Attack Detection Model for Wireless Sensor Networks in Microgrids," in IEEE Transactions on Industrial Informatics, vol. 17, no. 1, pp. 650-658, Jan. 2021, doi: 10.1109/TII.2020.2964704.
- [99] M. Ashrafuzzaman, S. Das, Y. Chakhchoukh, S. Shiva, F.T. Sheldon, Detecting stealthy false data injection attacks in the smart grid using ensemble-based machine learning, Comput. Secur. 97 (2020), 101994, <https://doi.org/10.1016/j.cose.2020.101994>.
- [100] M. R. Camana Acosta, S. Ahmed, C. E. Garcia and I. Koo, "Extremely Randomized Trees-Based Scheme for Stealthy Cyber-Attack Detection in Smart Grid Networks," in IEEE Access, vol. 8, pp. 19921-19933, 2020, doi: 10.1109/ACCESS.2020.2968934.
- [101] S. Kwon, H. Yoo and T. Shon, "IEEE 1815.1-Based Power System Security With Bidirectional RNN-Based Network Anomalous Attack Detection for Cyber-Physical System," in IEEE Access, vol. 8, pp. 77572-77586, 2020, doi: 10.1109/ACCESS.2020.2989770.
- [102] M. Keshk, B. Turnbull, N. Moustafa, D. Vatsalan and K. -K. R. Choo, "A Privacy-Preserving-Framework-Based Blockchain and Deep Learning for Protecting Smart Power Networks," in IEEE Transactions on Industrial Informatics, vol. 16, no. 8, pp. 5110-5118, Aug. 2020, doi: 10.1109/TII.2019.2957140.
- [103] N. Bhusal, M. Gautam and M. Benidris, "Detection of Cyber Attacks on Voltage Regulation in Distribution Systems Using Machine Learning," in IEEE Access, vol. 9, pp. 40402-40416, 2021, doi: 10.1109/ACCESS.2021.3064689.
- [104] P. Wang and M. Govindarasu, "Multi-Agent Based Attack-Resilient System Integrity Protection for Smart Grid," in IEEE Transactions on Smart Grid, vol. 11, no. 4, pp. 3447-3456, July 2020, doi: 10.1109/TSG.2020.2970755.

- [105]G. Ravikumar and M. Govindarasu, "Anomaly Detection and Mitigation for Wide-Area Damping Control using Machine Learning," in IEEE Transactions on Smart Grid, doi: 10.1109/TSG.2020.2995313.
- [106]V. K. Singh and M. Govindarasu, "A Cyber-Physical Anomaly Detection for Wide-Area Protection Using Machine Learning," in IEEE Transactions on Smart Grid, vol. 12, no. 4, pp. 3514-3526, July 2021, doi: 10.1109/TSG.2021.3066316.
- [107]M. Dehghani, T. Niknam, M. Ghiasi, N. Bayati, M. Savaghebi, Cyber-attack detection in DC microgrids based on deep machine learning and wavelet Singular values approach, Electronics (Basel) 10 (16) (2021) 1914, <https://doi.org/10.3390/electronics10161914>.
- [108]W. Hao, T. Yang and Q. Yang, "Hybrid Statistical-Machine Learning for Real-Time Anomaly Detection in Industrial Cyber-Physical Systems," in IEEE Transactions on Automation Science and Engineering, doi: 10.1109/TASE.2021.3073396.
- [109] A. Albarakati et al., "Security Monitoring of IEC 61850 Substations Using IEC 62351-7 Network and System Management," in IEEE Transactions on Industrial Informatics, vol. 18, no. 3, pp. 1641-1653, March 2022, doi: 10.1109/TII.2021.3082079.
- [110]F. Li et al., "Detection and Diagnosis of Data Integrity Attacks in Solar Farms Based on Multilayer Long Short-Term Memory Network," in IEEE Transactions on Power Electronics, vol. 36, no. 3, pp. 2495-2498, March 2021, doi: 10.1109/TPEL.2020.3017935.
- [111] M. Ismail, M. F. Shaaban, M. Naidu and E. Serpedin, "Deep Learning Detection of Electricity Theft Cyber-Attacks in Renewable Distributed Generation," in IEEE Transactions on Smart Grid, vol. 11, no. 4, pp. 3428-3437, July 2020, doi: 10.1109/TSG.2020.2973681.
- [112] A. Ahmadi, M. Nabipour, B. Mohammadi-Ivatloo and V. Vahidinasab, "Ensemble Learning-Based Dynamic Line Rating Forecasting Under Cyberattacks," in IEEE Transactions on Power Delivery, vol. 37, no. 1, pp. 230-238, Feb. 2022, doi: 10.1109/TPWRD.2021.3056055.
- [113] A. Aflaki, M. Gitizadeh, R. Razavi-Far, V. Palade, A.A. Ghasemi, A hybrid framework for detecting and eliminating cyber-attacks in power grids, Energies 14 (18) (2021) 5823, <https://doi.org/10.3390/en14185823>.

6. Kısaltmalar

| | |
|-------|---|
| ANN | <i>Artificial Neural Network</i> Yapay Sinir Ağları (YSA) |
| AI | <i>Artificial Intelligence</i> Yapay Zeka |
| A3C | <i>Asynchronous Advantage Actor-Critic</i> Asenkron Aktör-Kritik Ajanlar |
| AM | <i>Attention Mechanism</i> Dikkat Mekanizması |
| ARIMA | <i>Auto Regressive Integrated Moving Average</i> Bütünleşik Otoregresif Hareketli Ortalama |

| | |
|---------|--|
| ARIMAX | <i>Autoregressive Integrated Moving Average</i> Otoregresif Entegre Hareketli Ortalama |
| Bi-LSTM | <i>Bi-Directional Long Short-Term Memory</i> İki Yönlü Uzun Kısa Süreli Bellek |
| BM | <i>Boltzman Machine</i> Boltzman Makinesi |
| BPNN | <i>Back-Propagation Neural Network</i> Geri Yayılım Sinir Ağları |
| BR | <i>Bayesian Regularization</i> |
| CDBN | <i>Competitive Deep-Belief Network</i> Rekabetçi Derin İnanç Ağları |
| CNN | <i>Convolutional Neural Network</i> Evrişimsel sinir ağları |
| CRBM | <i>Restricted Boltzmann Machines</i> Koşullu Kısıtlı Boltzmann Makineleri |
| DBN | <i>Deep Belief Network</i> Derin İnanç Ağları |
| DCNN | <i>Deep Convolutional Neural Network</i> Derin Evrişimli Sinir Ağları |
| DDPG | <i>Deep Deterministic Policy Gradient</i> Derin Deterministik Politika Gradyanları |
| DL | <i>Deep Learning</i> Derin Öğrenme |
| DNN | <i>Deep Neural Network</i> Derin Sinir Ağları |
| DoS | <i>Denial-Of-Service Attack</i> Hizmet Reddi Saldırısı |
| DPMU | <i>Distribution-Level PMU</i> Dağıtım Seviyeli Güç Yönetim Birimi |
| DQN | <i>Deep Q-Learning</i> Derin Q Net |
| DR | <i>Demand Response</i> Talep Yanıtı |
| DT | <i>Decision Tree</i> Karar Ağacı |
| DRL | <i>Deep Reinforcement Learning</i> Derin Pekiştirmeli Öğrenme |
| ELM | <i>Extreme Learning Machines</i> Aşırı Öğrenme Makineleri |
| FCBRM | <i>Factored Conditional Restricted Boltzmann Machines</i> Faktörlü Koşullu Sınırlı Boltzmann Makineleri |
| FDI | <i>False Data Injection</i> Yanlış Veri Enjeksiyon Saldırılarını |
| FDN | <i>Feedforward Neural Network</i> İleri Beslemeli Sinir Ağları |
| FL | <i>Fuzzy Logic</i> Bulanık Mantık |
| GA | <i>Genetic Algorithm</i> Genetik Algoritma |
| GAN | <i>Generative Adversarial Networks</i> Çekişmeli Üretici Ağ |
| GRU | <i>Gated Recurrent Unit</i> Kapılı Tekrarlayan Birim |
| ICT | <i>Information and Communication Technologies</i> Bilgi ve İletişim Teknolojileri |
| KNN | <i>K-Nearest Neighbor</i> K-En Yakın Komşu Algoritması |
| LM | <i>Levenberg-Marquardt</i> |

| | | | |
|--------|--|--------|--|
| LR | <i>Logistic Regression</i> Lojistik Regresyon | RL | <i>Reinforcement Learning</i> Pekiştirmeli Öğrenme |
| LSTM | <i>Long Short-Term Memory</i> Uzun Kısa Süreli Bellek | RNN | <i>Recurrent Neural Network</i> Özyinelemeli Sinir Ağı |
| ML | <i>Machine Learning</i> Makine Öğrenmesi | RU | <i>Rolling Update</i> Sıralı Güncelleme |
| MLP-NN | <i>Multi Layer Perceptron Artificial Neural Network</i> Çok Katmanlı Algılayıcı Sinir Ağı | SARIMA | <i>Seasonal AutoRegressive Integration Moving Average</i> Mevsimsel Ototregresif Entegre Hareketli Ortalama |
| MSOS | <i>Modified Symbiotic Organisms Search</i> Modifiye Simbiyotik Organizma Arama | SARSA | <i>State–Action–Reward–State–Action</i> Durum–Eylem–Ödül–Durum–Eylem |
| NAF | <i>Normalized Advantage Functions</i> Normalize Avantaj Fonksiyonu | SCADA | <i>Supervisory Control and Data Acquisition</i> Merkezi Denetim ve Veri Toplama Sistemi |
| NARX | <i>Nonlinear Autoregressive Exogenous</i> Doğrusal Olmayan Bir Ototregresif Eksojen | SDAE | <i>Stacked Denoising Autoencoder</i> Yığılanmış Özdevinimli Kodlayıcılar |
| NILM | <i>Nonintrusive Load Monitoring</i> Müdahalesiz Yük İzleme | SGD | <i>Stochastic Gradient Descent</i> |
| PDP | <i>Partial Dependence Plot</i> Kısmi Bağımlılık Grafiği | SVD | <i>Singular Value Decomposition</i> Tekil Değer Ayrıştırması |
| PLF | <i>Probabilistic Load Forecasting</i> Olasılıksal Yük Tahmini | SVR | <i>Support Vector Regression</i> Destek Vektör Regresyonu |
| PMU | <i>Power Management Unit</i> Güç Yönetim Birimi | SVM | <i>Support Vector Machine</i> Destek Vektör Makineleri |
| PSO | <i>Particle Swarm Optimization</i> Parçacık Sürü Optimizasyonu | VAE | <i>Variational AutoEncoder</i> Varyasyonel Otokodlayıcı |
| PSSE | <i>Power System State Estimation</i> Güç Sistemi Durum Tahmini | VMD | <i>Variational Mode Decomposition</i> Varyasyon Modu Ayrıştırma |
| PV | <i>Photovoltaic</i> Fotovoltaik | WRF | <i>Weather Research and Forecasting Model</i> Hava Durumu Araştırma ve Tahmin Modeli |
| RF | <i>Random Forest</i> Rastgele Ormanlar | | |

Özgeçmişler



Reyhan Sağ Örnek, Lisans ve Yüksek Lisans derecelerini sırasıyla 2017 ve 2022 yıllarında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nden almıştır. Aynı bölümde 2019 yılından itibaren Araştırma Görevlisi olarak çalışmakta ve halen Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü Elektronik Anabilim Dalı'nda Doktora çalışmalarını sürdürmektedir. Başlıca çalışma alanları elektronik ve haberleşme sistemleri, FPGA kodlama ve akıllı şebekelerdir.



Zeynep Hasırcı Tuğcu, Lisans, Yüksek Lisans ve Doktora derecelerini sırasıyla 2008, 2011 ve 2017 yıllarında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nden almıştır. 2008-2009 yılları arasında Turkcell İletişim Hizmetleri A.Ş.'de Samsun Bölge, Radyo Şebeke, Hücre Planlama ve Optimizasyon biriminde, 2009-2017 yılları arasında KTÜ Elektrik-Elektronik Mühendisliği Elektronik Anabilim Dalı'nda Araştırma Görevlisi olarak, 2017- 2018 yılları arasında EAE Elektrik A.Ş.' de Proje Danışmanı olarak görev yapmış, 2018 yılından beri de Karadeniz Teknik Üniversitesi Elektronik ve Haberleşme Mühendisliği Bölümü Elektronik Anabilim Dalı'nda Doktor Öğretim Üyesi olarak mesleki hayatına devam etmektedir. Başlıca çalışma alanları mobil ve uydu iletişimi, yayılım modelleme, elektromanyetik alan, araç-arac haberleşmesi, enerji hatları üzerinden haberleşme (PLC) ve akıllı şebekelerdir.