

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 ağ (*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 biridir.



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. Deneyle, 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-Sectioning 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 çıktıların 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 problemine 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 yaklaşımlayıcıya 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. Amarantunga, "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 (ICICCSP), 2022, pp.1-6, doi: 10.1109/ICICCSP53532.2022.9862353.
- [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/TBDA.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 Otoregresif 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 Otoregresif 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.