

ELECTRICITY GRID PREDICTION SYSTEM USING ARTIFICIAL NEURAL NETWORKS AND MACHINE LEARNING METHODS

Ramazan YEŞİLDALLAR*

*Yüksek Lisans Öğrencisi, Nişantaşı Üniversitesi, Lisansüstü Eğitim Enstitüsü, yesildallar@gmail.com,
Orcid: 0009-0004-4158-920X

Received Date: 10.03.2025 Revised Date: 13.04.2025 Accepted Date: 06.05.2025

Copyright © 2025 Ramazan YEŞİLDALLAR. This is an open access article distributed under the Eurasian Academy of Sciences License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

ABSTRACT

The aim of this study is to enable network energy demand forecasting through efficient methods such as machine learning (ML) and artificial neural networks (ANN), which have achieved significant success in prediction tasks in recent years, by leveraging electric vehicles (EVs) and vehicle-to-grid (V2G) systems. With the rapid increase in the adoption of electric vehicles and their integration into grid systems, this study aims to help electric vehicle users generate additional income by using the vehicle-to-grid (V2G) system, which is dependent on the grid's energy demand. At the same time, it seeks to assist energy supply companies in making more efficient and sustainable energy procurement plans by accurately forecasting these demand fluctuations. The integration of electric vehicles with network energy demands presents new opportunities for grid management, and managing this integration effectively is critical to balancing energy supply and demand. The accuracy of energy demand forecasting not only improves energy management but also offers significant opportunities for sustainable energy production and consumption. In this thesis, the impact of electric vehicles on network energy demands will be analyzed comprehensively using ANN and ML methods, and how electric vehicle users can benefit from demand fluctuations through V2G will be explored in detail. Furthermore, the strategic advantages this system can offer to energy supply companies and the potential optimizations that can be achieved in energy management will be discussed. Ultimately, this study aims to develop a model that contributes to grid management through electric vehicles, thereby enhancing both efficiency and sustainability in the energy sector.

Keywords: Artificial Neural Network, Machine Learning, Method, Electricity Grid Forecast System

YAPAY SINİR AĞLARI VE MAKİNE ÖĞRENME YÖNTEMLERİ KULLANARAK ELEKTRİK ŞEBEKE TAHMİN SİSTEMİ

ÖZET

Bu çalışmanın amacı, makine öğrenmesi (ML) ve yapay sinir ağları (ANN) gibi tahminleme konusunda son yıllarda büyük başarılar elde etmiş olan yöntemlerden faydalanarak elektrikli araçlar (EV) ve araçtan ağı (V2G) sistemleri üzerinden şebeke enerji talep tahminlerinin yapılmasını mümkün kılmaktır. Elektrikli araçların hızla artan kullanım oranları ve şebeke sistemlerine entegrasyonunun önem kazanmasıyla, bu çalışma, elektrikli araç kullanıcılarının şebekedeki enerji talebine bağlı olarak araçtan şebekeye (V2G) sistemini kullanarak şebekenin rahatlatılması ve kullanıcı için en uygun zamanın ve optionun belirlenmesini sağlamak. Aynı zamanda, enerji tedarik şirketlerinin bu talep değişimlerini daha doğru şekilde öngörerek, talebe dayalı olarak daha verimli ve sürdürülebilir enerji tedarik planlaması yapmalarını sağlamayı amaçlamaktadır. Elektrikli araçların şebeke enerji talepleri ile entegrasyonu, şebeke yönetiminde yeni fırsatlar yaratmakta ve bu entegrasyonun doğru bir şekilde yönetilmesi, enerji arzı ve talebi arasındaki dengeyi sağlamak açısından kritik öneme sahiptir. Enerji talep tahminlerinin doğruluğu, sadece enerji yönetimini iyileştirmekle kalmaz, aynı zamanda sürdürülebilir enerji üretimi ve tüketimi için de büyük fırsatlar sunar. Bu makale çalışmada, ANN ve ML yöntemleri kullanılarak elektrikli araçların şebeke enerji talepleri üzerindeki etkisi kapsamlı bir şekilde analiz edilecek, V2G aracılığıyla elektrikli araç kullanıcılarının, şebeke talep değişimlerinden nasıl fayda sağlayabileceği ve ekonomiye katkıda bulunabilecekleri detaylı bir



biçimde incelenecektir. Bunun yanı sıra, bu sistemin enerji tedarik şirketleri için nasıl stratejik bir avantaj yaratabileceği ve enerji yönetiminde ne tür optimizasyonlar sağlanabileceği de ele alınacaktır. Sonuç olarak, bu çalışma, elektrikli araçların şebeke yönetimine katkı sağlayarak, enerji sektörü için hem verimliliği hem de sürdürülebilirliği artırmaya yönelik bir model geliştirir

Anahtar Kelimeler: Yapay Sinir Ağı, Makine Öğrenme, Yöntem, Elektrik Şebeke Tahmin Sistemi

1. GİRİŞ

Dünya genelinde enerji üretim ve tüketiminde büyük bir kısmı fosil yakıtlara dayanmaktadır. International Energy Agency (IEA) tarafından sunulan verilere göre, fosil yakıtlar birçok faaliyette birincil enerji kaynağı olarak kullanılmakta ve bu oran dünya genelinde yaklaşık %85 civarındadır. Fosil yakıtların en yaygın kullanım alanları arasında sanayi, elektrik üretimi, ulaşım ve ısınma yer almaktadır. Ancak, fosil yakıtların sınırlı kaynaklar olması ve çevreye verdiği zararlar, enerji üretimi ve tüketim alışkanlıklarında köklü değişiklikleri zorunlu kılmaktadır. Fosil yakıtlar, sera gazı emisyonlarının ana kaynağı olup, küresel ısınma ve çevresel felaketler gibi önemli sorunlara yol açmaktadır. IEA'nın verilerine göre, taşıma sektörü, küresel CO2 emisyonlarının %23'ünü, küresel sera gazı emisyonlarının ise %14'ünü oluşturmaktadır (IEA, 2019). Bu durum, hem çevre kirliliğini artırmakta hem de fosil yakıt kaynaklarının tükenme riskini beraberinde getirmektedir. Bu noktada, insanlık alternatif enerji kaynakları ve çevre dostu teknolojilere yönelmek zorunda kalmıştır (Popov, 1990).

Elektrikli araçlar (EV) ve yenilenebilir enerji sistemleri, fosil yakıtların olumsuz etkilerini azaltabilecek ve sürdürülebilir enerji kullanımını mümkün kılacak önemli alternatifler olarak öne çıkmaktadır. Elektrikli araçlar, enerji verimliliği açısından içten yanmalı motorlara sahip araçlara kıyasla önemli avantajlar sunmaktadır. Elektrikli araçların teknolojileri, özellikle son birkaç on yılda büyük bir gelişim göstermiştir. Bu teknolojinin temelleri, 19. yüzyılın sonlarına kadar gitmekte olup, elektrikli araçların gelişimi fosil yakıtlı araçlarla birlikte paralel bir şekilde ilerlemiştir. Ancak, fosil yakıtların daha ucuz olması ve şarj altyapısının yetersizliği gibi nedenlerle elektrikli araçların yaygın kullanımı, ancak 21. yüzyılda mümkün olabilmektedir (Rizzo, Dougherty, 1994).

Elektrikli araçların çevresel faydaları oldukça dikkat çekicidir. Elektrikli araçlar, sıfır emisyonlu araçlar olarak doğrudan atmosfere zararlı gaz salınımını engeller. Bununla birlikte, elektrikli araçların gürültü kirliliğini azaltma potansiyeli de oldukça yüksektir. İçten yanmalı motorlara sahip araçlar, hem hava kirliliği hem de ses kirliliği açısından çevreye ciddi zararlar vermektedir. Elektrikli araçlar ise, bu sorunları büyük ölçüde ortadan kaldırarak daha temiz ve sessiz bir çevre sağlar. Ayrıca, elektrikli araçlar enerji verimliliği açısından da büyük bir avantaja sahiptir. İçten yanmalı motorlu araçlarla kıyaslandığında, elektrikli araçlar daha az enerjiyle daha uzun mesafeler kat edebilmektedir. Bu özellik, elektrikli araçların enerji tüketiminde önemli tasarruflar sağlamasına olanak tanır.

Bunun yanı sıra, elektrikli araçlar, şebeke sistemlerine entegre edilebilme özellikleri ile de büyük bir potansiyele sahiptir. Bu entegrasyon, elektrikli araçların sadece taşıma aracı olarak değil, aynı zamanda enerji depolama ve enerji arzı sağlayan birim olarak kullanılabilmesini sağlar. Elektrikli araçların şebekeye entegre edilmesi, elektrikli araçlardan elde edilen enerjinin şebekeye geri verilmesi (Vehicle-to-Grid - V2G) teknolojisi ile mümkün olmaktadır. V2G sistemi, elektrikli araçların akülerindeki fazla enerjinin, şebeke talebine bağlı olarak geri verilmesini sağlar. Bu sistem sayesinde, elektrikli araçlar, sadece bir tüketici değil, aynı zamanda enerji sağlayıcıları haline gelir. Bu durum, şebeke dengesini sağlamak ve enerji arzını optimize etmek açısından önemli fırsatlar sunmaktadır.



Elektrikli araçların yaygınlaştırılması, aynı zamanda enerji tedarik şirketleri için de yeni iş modelleri geliştirilmesine olanak tanımaktadır. Enerji tedarik şirketleri, elektrikli araçların şebekeye entegre olmasıyla birlikte, daha esnek ve talep odaklı bir enerji tedarik stratejisi geliştirebilirler. Elektrikli araçlar, şebeke talebine göre enerji sağlayarak, enerji tüketiminin daha verimli ve sürdürülebilir bir şekilde yönetilmesine katkı sağlar. Bu durum, özellikle enerji arzının ve talebinin sürekli değişkenlik gösterdiği bir dünyada oldukça önemlidir. Elektrikli araçların şebekeye entegrasyonu, enerji yönetiminde önemli bir rol oynamaktadır ve bu entegrasyon, enerji talep tahminlerini daha doğru bir şekilde yapmayı mümkün kılmaktadır (Rumelhart, 1986).

Bu makale çalışmasında, elektrikli araçlar ve V2G teknolojilerinin enerji talep tahminlerinde nasıl kullanılabileceğini incelemeyi amaçlamaktadır. Makine öğrenmesi (ML) ve yapay sinir ağları (ANN) gibi ileri düzey tahminleme yöntemleri, enerji talep tahminlerinde yüksek doğruluk oranları sağlamak için kullanılmaktadır. Bu makale çalışmasında, elektrikli araçların enerji talep değişimlerini tahmin etmek için ANN ve ML yöntemlerinden faydalanılacaktır. Ayrıca, elektrikli araç kullanıcılarının şebeke talep değişimlerine göre nasıl fayda sağlayabileceği ve bu teknolojilerin ekonomik etkileri de analiz edilecektir. Enerji tedarik şirketlerinin bu tür teknolojilerden nasıl faydalanabilecekleri ve daha verimli bir enerji tedarik planlaması yapabilecekleri de ele alınacaktır. Bu doğrultuda, elektrikli araçların şebeke yönetimi açısından sunduğu potansiyel faydalar ve uygulamalar detaylı bir şekilde tartışılacaktır (Schmidt, 1993).

Elektrikli araçların yaygınlaşması, enerji sektörü için büyük fırsatlar yaratmaktadır. Elektrikli araçlar, sadece çevresel sürdürülebilirlik açısından değil, aynı zamanda ekonomik açıdan da önemli katkılar sağlamaktadır. Elektrikli araç kullanıcıları, şebekeye enerji sağlayarak ek gelir elde edebilirken, enerji tedarik şirketleri de daha verimli ve sürdürülebilir bir enerji tedarik süreci oluşturabilirler. Bu makale çalışmasında, elektrikli araçların şebeke sistemlerine entegrasyonunun, enerji talep tahminleri ve yönetimi açısından sağladığı faydaları inceleyerek, enerji sektörü için uygulanabilir bir model önerisi sunmayı hedeflemektedir (Son, Kim, 2017).

1.1. Makine Öğrenimi (ML)

Google'un Makine Öğrenimi el kitabının başlangıcında, "Eğer makine öğrenimine gerek duymayan basit bir kural tabanlı sistem oluşturabilirseniz, onu yapın" yazmaktadır. Bu iki şekilde yorumlanabilir: İlk olarak, bir tür sezgisel algoritma olarak, makine öğrenimi henüz tam olarak yorumlanabilir bir performans elde edememektedir; ve ikinci olarak, ML, belirli senaryolarda kural tabanlı yöntemlerin ulaşamayacağı tatmin edici bir performansa sahip olabilir (ancak yine de garantili performans değil). Son derece karmaşık problemler için tüm kuralları ve adımları çıkarmakta büyük zorluklar vardır. Yalnızca insan zekasıyla tasarlanan yapay zeka olmayan şemalar, çözümlerde veya karar mantığındaki önemli kusurlara yol açacaktır. Aynı şekilde, uzman sistemler insanların düşünme biçimini taklit eder ve aşırı derecede alan bilgisine ve insan deneyimine çok fazla bağımlıdır. Ayrıca, uzman bir sistemin tasarımının anahtarı, metodoloji yerine uzmanlığı kullanılmaktadır. Bu yöntemler, yetersiz genelleme yeteneği ve düşük sağlamlık nedeniyle geniş çapta uygulamalarda çıkmaza girmiştir (Stein, 1993). Girişler ve insan tarafından tanımlanan algoritmaları çıktıları elde etmek yerine, karmaşık problemleri çözmek için alternatif bir yol, girişleri ve beklenen çıktıları seçmek ve makinelerin bunlar arasındaki desenleri otomatik olarak bulmasına ve böylece algoritmaları "öğrenmesine" izin vermektir. Bu, (denetimli) makine öğreniminin nasıl çalıştığının genel fikridir. Makine öğrenimi aşağıdaki yönlerde üstünlük gösterir: İlk olarak, ML, insanların sınırlı bellek ve beyin kapasitesi nedeniyle yapamayacağı kadar büyük miktarda yapılandırılmış veriden öğrenme



konusunda iyidir. İkinci olarak, yeterli sayıda eğitim örneğini "gördükten" sonra, elde edilen ML çözümleri iyi genelleme yeteneği gösterir. Üçüncü olarak, her yeni mevcut veri, giriş-çıkış projeksiyonlarını ayarlamaya katkıda bulunur. Öğrenme süreci aşamalı olarak gerçekleştirilebilir, bu da çevrimiçi ve sürekli öğrenmeyi mümkün kılar (Sun, 2020). Denetimsiz öğrenme için de pratik gereksinimler bulunmaktadır. Birçok durumda, eğitim verileri için etiketler, yüksek iş yükü ve alan uzmanlarına olan ihtiyaç nedeniyle mevcut değildir. Bir yöntem, kümeleme tabanlı yaklaşımlar, verileri özellik uzayına tam olarak belirtmeden gruplara otomatik olarak bölebilir. Ancak, tahmin ve öngörü görevleri için uygun kodlama/çözme prosedürleri gereklidir (Swingler, 1996). Benzer bir fikir, takviyeli öğrenmeye de uygulanır. Yarı-denetimli bir öğrenme şeması olarak, özne sürekli olarak eylemler alır ve geri bildirimini ("ödülleri") değerlendirmesine dayanarak eylemle ilişkili kuralları ("politikaları") ayarlar ve öğrenir. Sınırlı bir süre içinde eylem değerlendirmesi için uygulanabilir olması için, eylem alanının genellikle sonlu elemanlarla genişletilmiş olması gerekir. Tipik bir örnek, işbirlikçi robot kontrolünün uygulanmasıdır. (Andrew, 1991).

Karmaşık problemlerle başa çıkmak ve geniş veri koleksiyonlarından içgörüler elde etmek için derin yapılar gereklidir. Bir yönüyle, sinir ağı model yapısını belirleyerek, bir dizi fonksiyon parametrelendirir. Sonuç olarak, öğrenilebilirlik üst sınırı belirlenmiştir. Bir örnek olarak, tüm doğrusal fonksiyonlar kümesinden herhangi bir örnek, hangi parametrelerin seçildiğine bakılmaksızın hiçbir zaman bir ikinci derece ilişkiyi tanımlayamaz. Bu nedenle, aynı sayıda nötron verildiğinde, derin yapıların, yüzeysel ve düz yapılarla karşılaştırıldığında, girişlerle çıkışlar arasındaki daha karmaşık doğrusal olmayan ilişkileri yakalayabileceği umut vericidir. Başka bir açıdan, öğrenilmiş ağırlıklar, hangi tek fonksiyonun kayıp fonksiyonunu en aza indirebileceğini belirler, bunların ne kadar iyi öğrenildiği ise performansın üst sınırını belirler (Taylor, McSharry, 2008). Derin Öğrenme, bir parça deneyim, belirli bir senaryo veya diğer etkinliklerden transfer edilen beceriler gibi yapılandırılmamış verilerle başa çıkmada güçlü bir performans sergilemiştir. Girişler uygun şekilde kodlanabilen her şey olabilir, örneğin bir resim, bir video klibi, bir ses dalgası, metinler veya çeşitli sensörlerden gelen okumalar. Problem formülasyonu aşamasında, yapılandırılmamış verileri yapılandırılmış hale dönüştürmek için kuralları belirlenir. Çıkışlar, önceden tanımlanmış bir kategori kümesinden alınan göstergeler olabilir veya sonsuz sayıda değere sahip değişkenlerin örnekleri olabilir. Algoritmik gelişim açısından, birçok araştırmacı geniş bir spektrumdan teknikleri denemiştir, daha yakın zamanda büyük veri ve bilgi tabanlı iş otomasyonu tekniklerinin desteği ile ML/DL tabanlı teknikleri içeren bir yelpazeye genişletmiştir (Basheer, 2000). Yardımcı bilginin yayılmış ve geniş bir yelpazede çeşitli ham veri veya bilgi parçacıklarında dağıldığı söylenebilir. Zorluk, farkedilmesi zor ayrıntılarda gizlenen kanıtları ortaya çıkarmaktır, bu nedenle ML/DL teknik yolu üzerinde mantıksal akıl yürütme/çıkarım ve bilinçaltı veya deneyime dayalı kritik yönler üzerinde ince dikkat gereklidir. Bu tür bir araştırma yolunun geniş kabulü ile ilgili olarak, ana akım araştırma alanları arasında bilgisayarlı görü ve desen tanıma, robotik ve otomasyon, doğal dil işleme, bilgi keşfi ve veri madenciliği, strateji ve karar verme vb. yer alır (Baum, Haussler, 1989).

Makine öğrenimi, bilgisayar bilimlerinin önemli bir alanıdır ve bilgisayarların öğrenme yeteneğini artırmak için geliştirilen bir dizi teknik ve yöntemi içerir. Arthur Samuel'in 1959'da belirttiği gibi, makine öğrenimi bilgisayarları, belirli bir şekilde programlanmamış olmalarına rağmen öğrenme yeteneği kazanabilir hale getirir. Bu, insanların açık talimatlarla belirli bir görevi gerçekleştirmek yerine verilerden öğrenme yoluyla model oluşturma yeteneğine dayanır (Birleştirici, 2015).



1.2. Makine Öğrenme Yöntemleri

Yaygın olarak benimsenen iki makine öğrenme yönteminden bir denetimli makine öğrenme diğeri ise denetimsiz makine öğrenme yöntemidir. Makine öğreniminin yaklaşık %70'i denetimli öğrenmeden oluşurken, denetimsiz öğrenme %10 ila %20 arasında bir paya sahiptir. Yarı denetimli ve pekiştirme öğrenme ise bazen kullanılan diğeri iki teknolojidir (Budde-Meiwes, 2013).

- Denetimli öğrenme algoritmaları, istenen çıktının bilindiği, etiketlenmiş özelliklerden faydalanılarak eğitim işleminin yapıldığı algoritmalar. Mesala bir makinenin parçaları "F" (arızalı) veya "R" (çalışıyor) olarak etiketlenmiş veri sütunlarına sahip olsunlar. Oluşturulan makine öğrenme algoritması doğru çıktılarla birlikte bir dizi giriş alır ve gerçek çıktısını hataları bulmak için doğru çıktılarla karşılaştırarak öğrenir. Daha sonra modeli buna göre değiştirir. Sınıflandırma, regresyon, tahmin ve gradyan artırma gibi yöntemler aracılığıyla, denetimli öğrenme, etiketsiz ek verilerdeki etiket durumunu doğru tahmin etmek amacıyla desenleri kullanır. Denetimli Makine öğrenmesi, tarihsel verilerden faydalanarak muhtemel gelecek durumların tahmin edildiği uygulamalarda çok sık kullanılmaktadır. Örneğin, Bir mailin spam olup olmayacağı veya herhangi bir ürünün tarih boyunca artışına bakılarak gelecekteki fiyatı ile ilgili çıkarım yapabilir (Cluzel, Douglas, 2012).

- Denetimsiz makine öğrenme yöntemleri, tarihsel etiketler içermeyen verilerle kullanılan yöntemdir. Sisteme "doğru cevap" söylenmez. Algoritmanın ne ile karşı karşıya olduğunu anlaması gerekir. Amaç, verinin ayrımlarını saptamak ve içindeki bazı yapıları keşfetmektir. Denetimsiz öğrenme, işlem verileri üzerinde iyi çalışır. Örneğin, benzer özelliklere sahip müşteri segmentlerini tanımlayabilir ve ardından pazarlama kampanyalarında benzer şekilde işleme alınabilir. Yada müşteri segmentlerini birbirinden ayıran ana özellikleri bulabilir. Popüler teknikler arasında öz- örgütleyen haritalar, en yakın komşu eşleme, k-ortalama kümeleme ve tekil değer ayrışımı bulunmaktadır.

Yarı denetimli öğrenme, denetimli öğrenmeyle aynı uygulamalar için kullanılır. Ancak eğitim için hem etiketli hem de etiketlenmemiş veriler kullanılır - genellikle az miktarda etiketli veriyle birlikte büyük miktarda etiketlenmemiş veri (çünkü etiketlenmemiş veriler daha az maliyetlidir ve elde edilmesi daha az çaba gerektirir). Bu tür bir öğrenme, sınıflandırma, regresyon ve tahmin gibi yöntemlerle kullanılabilir. Yarı denetimli öğrenme, etiketlemenin maliyetinin tam olarak etiketlenmiş bir eğitim sürecine izin vermek için çok yüksek olduğu durumlarda faydalıdır. Bunun örnekleri arasında bir web kamerasında bir kişinin yüzünü tanımlama bulunmaktadır (Copelan, 1993).

- Pekiştirme öğrenme sıklıkla robotik, oyunlar ve navigasyon için kullanılır. Pekiştirme öğrenme ile algoritma, hangi eylemlerin en büyük ödülleri verdiğini deneme yanılma yoluyla keşfeder. Bu tür öğrenmenin üç temel bileşeni vardır: ajan (öğrenen veya karar verici), çevre ve eylemler Amaç, ajanın belirli bir süre boyunca beklenen ödülü maksimize edecek eylemleri seçmesidir. İyi bir politikayı takip ederek temsilci, hedefe çok daha hızlı ulaşır. Bu nedenle, pekiştirme öğrenmede amaç, en iyi politikayı öğrenmektir (Dikmen, Karadag, 2021).

1.3. Derin Öğrenme

Derin öğrenme (ayrıca derin yapılandırılmış öğrenme, hiyerarşik öğrenme veya derin makine öğrenimi olarak da bilinir), birden fazla gizli katmana sahip yapay sinir ağlarının ve ilgili makine öğrenme algoritmalarının incelenmesidir. Bu derin ağlar (Dikmen, Karadag, 2021):

- Özellik çıkarımı ve dönüşümü için birçok katmanlı bir kademeyi kullanan derin öğrenme yöntemlerin katmanları kendinden önceki katmanın çıktısını giriş verisi



olarak kullanılmaktadır. Derin öğrenmede de kullanılan algoritmalar denetimsiz veya denetimli olabilmektedir ve uygulamalar desen analizi (denetimsiz) ve sınıflandırma (denetimli) içerebilir.

- Verilerin çok seviyeli özelliklerinin veya temsil biçimlerinin (denetimsiz olarak) öğrenimine dayanır. Daha yüksek seviye özellikler, daha düşük seviye özelliklerden türetilerek hiyerarşik bir temsil oluşturur.
- Veri temsillerini öğrenme alanında daha geniş makine öğrenme alanının bir parçasıdır.
- Farklı soyutlama seviyelerine karşılık gelen birden fazla temsil seviyesini öğrenir; seviyeler bir kavram hiyerarşisi oluşturur.

Basit bir durumda, iki set sinir olabilir: bir set giriş sinyali alır ve bir set çıkış sinyali gönderir. Giriş katmanı bir giriş aldığı anda, değiştirilmiş bir sürümünü bir sonraki katmana iletir. Derin bir ağda, giriş ile çıkış arasında birçok katman bulunur (katmanlar sinirlerden oluşmaz ancak bunu düşünmek faydalı olabilir), algoritmanın birden çok işlem katmanı kullanmasına izin verir, bu katmanlar çoklu doğrusal ve doğrusal olmayan dönüşümlerden oluşur (Dowla, Rogers, 1995).

Derin öğrenme, veri temsillerinin öğrenimine dayalı daha geniş bir makine öğrenme yöntemi ailesinin bir parçasıdır. Bir gözlem (örneğin, bir görüntü), piksel başına bir yoğunluk değeri vektörü olarak veya daha soyut bir şekilde kenarlar, belirli şekil bölgeleri vb. bir küme olarak birçok farklı şekilde temsil edilebilir (Ülkü, Yalpir, 2021). Bazı temsiller, öğrenme görevini basitleştirmede diğerlerinden daha iyidir (örneğin, yüz tanıma veya yüz ifadesi tanıma). Derin öğrenmenin vaatlerinden biri, el yapımı özelliklerin denetimsiz veya yarı denetimli özellik öğrenimi ve hiyerarşik özellik çıkarımı için etkili algoritmalarla değiştirilmesidir (Eaton, Olivier, 1992).

Bu alandaki araştırmalar, daha iyi temsiller oluşturmayı ve bu temsilleri büyük ölçekli etiketlenmemiş verilerden öğrenmeyi amaçlar. Bazı temsiller, nörobilimdeki ilerlemelerden esinlenmiştir ve sinir sistemindeki bilgi işleme ve iletişim desenlerinin yorumlamasına dayanır. Örneğin, sinirsel kodlama, çeşitli uyarıcılar ve beyindeki ilişkili nöronal yanıtlar arasında bir ilişki tanımlamaya çalışır (Ecker, 2012).

1.4. Yapay Sinir Ağları (ANN)

Yapay Sinir Ağı (YSB), biyolojik sinir ağlarının yapılarını ve işlevselliğini taklit etmeye çalışan bir matematiksel modeldir. Her yapay sinir ağının temel yapı taşı, yapay sinir hücresi olarak adlandırılan, basit bir matematiksel modeldir. Bu model üç basit kural setine sahiptir: çarpma, toplama ve aktivasyon (Van den Bossche, 2006). Yapay sinir hücresinin girişinde, her giriş değeri ayrı ağırlıkla çarpılarak ağırlıklı hale getirilir. Yapay sinir hücresinin orta bölümünde, tüm ağırlıklı girişlerin ve sapmanın toplandığı bir toplama işlevi bulunur. Yapay sinir hücresinin çıkışında, önceden ağırlıklı girişlerin ve sapmanın toplamı, ayrıca transfer işlevi olarak da adlandırılan aktivasyon işlevinden geçirilir (Fahlman, 1988).

Yapay sinir ağlarının çalışma prensipleri ve basit kural seti her ne kadar özel bir şey gibi görünse de, bu modellerin tam potansiyeli ve hesaplama gücü, onları yapay sinir ağlarına entegre etmeye başladığımızda ortaya çıkar. Bu yapay sinir ağları, karmaşıklığın sadece birkaç temel ve basit kuraldan türeyebileceği basit bir gerçeği kullanır (Genesereth, Nilsson, 1985).

Bireysel yapay sinir hücrelerinin birbirine bağlanmasıyla elde edilebilecek matematiksel karmaşıklığın faydalarını tam olarak elde edebilmek ve sistemi sadece karmaşık veya yönetilmez hale getirmemek için genellikle bu yapay sinir hücrelerini rastgele bir şekilde birbirine bağlamayız. Geçmişte, araştırmacılar birkaç "standartlaştırılmış"



yapay sinir ağı topografyası geliştirmişlerdir. Bu önceden tanımlanmış topografyalar, problem çözme için daha kolay, daha hızlı ve daha verimli hale getirebilir. Farklı türdeki yapay sinir ağı topografyaları, farklı türdeki problemleri çözmek için uygundur. Verilen problemin türünü belirledikten sonra, kullanacağımız yapay sinir ağı topolojisine karar vermemiz ve onu ayarlamamız gerekir. Topolojiyi ve parametrelerini ayarlamamız gerekmektedir (Gerssen-Gondelach, Faaij, 2012).

Yapay sinir ağı topolojisinin iyi ayarlanmış olması, yapay sinir ağıımızı kullanmaya başlayabileceğimiz anlamına gelmez, bu yalnızca bir önkoşuldur. Yapay sinir ağıımızı kullanmadan önce, verilen problemin türünü çözmeyi öğretmemiz gerekir. Biyolojik sinir Yapay sinir ağlarının en büyük avantajlarından biri, çevrelerinden öğrenebilme yetenekleridir. Çevreden öğrenme, çevrenin (veri veya görev) karmaşıklığı, diğer tür çözümlerin uygulanmasını pratik olmayan hale getirdiği uygulamalarda faydalı olur. Bu nedenle yapay sinir ağları, sınıflandırma, fonksiyon yaklaşımı, veri işleme, filtreleme, kümeleme, sıkıştırma, robotik, düzenlemeler, karar alma vb. gibi çeşitli görevler için kullanılabilir (Vidyanandan, 2019). Doğru yapay sinir ağı topolojisini seçmek, uygulamanın türüne ve belirli bir problemin veri temsiline bağlıdır. Yapay sinir ağlarını seçerken ve kullanırken yapay sinir ağı modeli ve öğrenme algoritmalarının teorisine hakim olmamız gerekir. Seçilen modelin karmaşıklığı çok önemlidir; belirli bir görev için çok basit bir model kullanmak genellikle zayıf veya yanlış sonuçlara yol açar ve belirli bir görev için aşırı karmaşık bir model, öğrenme sürecinde sorunlara neden olabilir (Wessels, Barnard, 1992). Karmaşık model ve basit görev, ezberlemenin ve öğrenmenin gerçekleşmemesine yol açar. Birçok öğrenme algoritması vardır ve bunlar arasında birçok ticari değişim vardır ve neredeyse hepsi her tür yapay sinir ağı modeli için uygun olabilir. Belirli bir görev için doğru öğrenme algoritmasını seçmek, belirli bir probleme ve veri setine deneyimler ve deneyler gerektirir. Yapay sinir ağı modeli ve öğrenme algoritması uygun şekilde seçildiğinde, verilen bir problemi çözmek için sağlam bir araç elde ederiz (Hamzaçebi, 2007).

1.5. Yapay Sinir Ağlarının Mimarisi

Temel mimari, üç tür sinir hücresi katmanını içerir: giriş, gizli ve çıkış katmanları. Besleme-yönlü ağlarda, sinyal akışı girişten çıkış birimlerine, sıkı bir şekilde besleme-yönlü bir yönde gerçekleşir. Veri işleme, birden fazla birim (katman) üzerinde uzanabilir, ancak geri bildirim bağlantıları bulunmamaktadır. Rekürrent ağlar geri bildirim bağlantıları içerir. Besleme-yönlü ağların aksine, ağın dinamik özellikleri önemlidir. Bazı durumlarda, birimlerin aktivasyon değerleri, ağın artık değişmeyen kararlı bir duruma evrileceği bir gevşeme sürecine girer. Diğer uygulamalarda, çıkış nöronlarının aktivasyon değerlerindeki değişiklikler önemlidir, böylece dinamik davranış, ağın çıkışını oluşturur. Uygulamanın özelliklerine ve gereksinimlerine bağlı olarak çeşitli diğer sinir ağı mimarileri (Elman ağı, adaptif rezonans teorisi haritaları, rekabetçi ağlar vb.) bulunmaktadır. Okuyucu, farklı sinir ağı mimarileri ve öğrenme algoritmalarının kapsamlı bir genel bakışı için Bishop (1995)'a başvurabilir (Han, 1996).

Bir sinir ağı, bir dizi girişin istenen bir dizi çıktıyı üretmesini sağlayacak şekilde yapılandırılmalıdır. Bağlantıların güçlerini ayarlamak için çeşitli yöntemler mevcuttur. Bir yol, ağırlıkları önceden bilgi kullanarak açıkça ayarlamaktır. Başka bir yol, sinir ağını öğretici desenlerle besleyerek ve onun ağırlıklarını belirli bir öğrenme kuralına göre değiştirmesine izin vererek sinir ağını eğitmektir. Sinir ağlarındaki öğrenme durumları üç farklı türe ayrılabilir. Bunlar, denetimli öğrenme, denetimsiz öğrenme ve pekiştirme öğrenmedir (Young, 2013). Denetimli öğrenmede, her biri için bir giriş vektörü girişlere ve çıkış katmanındaki her düğüm için bir dizi istenen yanıtla birlikte sunulur. Bir ileri geçiş



yapılır ve çıkış katmanındaki her düğüm için istenen ve gerçek yanıt arasındaki hatalar veya uyumsuzluklar bulunur. Bunlar daha sonra, ağırlık değişikliklerini belirlemek için mevcut öğrenme kuralına göre ağda kullanılır. Denetimli terimi, bireysel çıkış düğümlerindeki istenen sinyallerin dış bir öğretmenden sağlandığı gerçeğinden gelir (Hecht-Nielsen, 1990).

Bu tekniklerin en iyi bilinen örnekleri, geri yayılım algoritması, delta kuralı ve perceptron kuralında görülür. Denetimsiz öğrenmede (veya kendi kendine örgütlenme), bir (çıkış) birimi, girişteki desen kümelerine yanıt vermesi için eğitilir. Bu paradigma içinde, sistem giriş popülasyonunun istatistiksel olarak belirgin özelliklerini keşfetmesi beklenir. Denetimli öğrenme paradigmasından farklı olarak, desenlerin sınıflandırılacağı önceden belirlenmiş bir kategori seti yoktur; bunun yerine, sistem kendi giriş uyarıcılarının temsiliğini geliştirmelidir. Pekiştirme öğrenmesi, ne yapılacağını öğrenmek - durumları eylemlere nasıl eşleyeceğini - bir sayısal ödül sinyalini maksimize etmek için öğrenmektir. Öğrenen, hangi eylemlerin en çok ödülü sağladığını deneyerek keşfetmelidir, çoğu makine öğrenme türünde olduğu gibi hangi eylemlerin alınacağı söylenmez. En ilginç ve zorlu durumlarda, eylemler sadece anlık ödülü etkilemekle kalmaz, aynı zamanda bir sonraki durumu ve dolayısıyla tüm sonraki ödülleri de etkileyebilir. Bu iki özellik, deneme yanılma arayışı ve gecikmiş ödül, pekiştirme öğrenmenin en önemli iki ayırt edici özelliğidir (Henseler, 1995).

1.6. Yapay Sinir Ağlarında Öğrenme

Üç ana öğrenme paradigması vardır: denetimli öğrenme, denetimsiz öğrenme ve pekiştirme öğrenme. Genellikle, herhangi bir yapay sinir ağı mimarisi tarafından kullanılabilirler. Her öğrenme paradigmasının birçok eğitim algoritması bulunmaktadır. Bu algoritmalar, ağın türüne ve öğrenme hedeflerine bağlı olarak seçilir ve uygulanır (IEC 62196. 2014).

Bunlardan ilki olan denetimli öğrenme, bir yapay sinir ağının eğitim verilerinden parametrelerini ayarlamasını sağlayan bir makine öğrenme tekniğidir. Öğrenme sürecinde yapay sinir ağının görevi, girdi değerlerine karşılık gelen çıktı değerlerini gördükten sonra parametrelerinin değerlerini belirlemektir. Eğitim verileri genellikle veri vektörleri şeklinde temsil edilen girdi ve istenilen çıktı değerlerinin çiftlerinden oluşur. Denetimli öğrenme, sınıflandırma olarak da adlandırılabilir, burada geniş bir yelpazede sınıflandırıcılar bulunur, her birinin kendi güçlü ve zayıf yönleri vardır. Verilen bir problemi çözmek için denetimli öğrenme adımları şunları içerir: İlk adımda, eğitim örneklerinin türünü belirlememiz gerekir (Zupan, Gasteiger, 1993). İkinci adımda, verilen bir problemi tatmin edici bir şekilde açıklayan bir eğitim veri seti toplamamız gerekir. Üçüncü adımda, toplanan eğitim veri setini seçilen yapay sinir ağı tarafından anlaşılabilir bir formda açıklamamız gerekir. Dördüncü adımda ise öğrenme işlemi gerçekleştiririz ve öğrenme sonrasında elde edilen yapay sinir ağının performansını test veri setiyle test ederiz. Test veri seti, öğrenme sürecinde ağa sunulmamış verilerden oluşur ve öğrenme sonrasında ağın performansını objektif bir şekilde değerlendirmek için kullanılır. Denetimli öğrenme, yapay sinir ağının giriş verilerini istenilen çıktıya doğru eşleştirmesini sağlayarak öğrenme verimliliğini artırır. Ancak, bu süreçte doğru eğitim verilerinin seçilmesi ve ağın parametrelerinin doğru şekilde ayarlanması önemlidir. Doğru eğitim verileri seçilmediğinde veya ağın parametreleri yanlış ayarlandığında, ağın performansı düşebilir ve istenilen çıktıları üretme yeteneği azalabilir. Bu nedenle, denetimli öğrenme sürecinde dikkatlice planlanmış ve yönetilmiş bir veri toplama, model eğitimi ve değerlendirme süreci gereklidir (Karaca, Karacan, 2016).

Pekiştirmeli öğrenme, uzun vadeli ve kısa vadeli ödül arasında bir denge bulunan problemler için özellikle uygundur. Robot kontrolü, telekomünikasyon ve satranç gibi



oyunlar ve diğer ardışık karar alma görevleri gibi çeşitli problemlere başarıyla uygulanmıştır (Kheirkhah, 2013).

1.7. Yapay Sinir Ağlarının Problem Çözümleri

Genel olarak, yapay sinir ağları (YSA), yedi farklı kategorideki çeşitli problemleri çözmede diğer hesaplama araçlarına göre daha sağlam ve sıkça daha iyi performans gösterir. Kategoriler aşağıda sıralanmıştır (Kilic, 2023).

Desen sınıflandırma; denetimli öğrenme kullanarak bilinmeyen bir giriş desenini, belirli bir sınıfı temsil eden bir veya daha fazla özelliğe dayanarak birkaç önceden belirlenmiş sınıftan birine atama ile ilgilidir. Bu uygulamalardan bazıları, mikrobiyoloji alanından gelir ve mikrobiyolojik özelliklerine dayanarak ürünlerin sınıflandırılmasını veya piroliz kütle spektrometresi verilerini kullanarak mikroorganizmaların karakterizasyonunu içerir. İstatistikteki ayırt edici analizin aksine, YSAs lineer varsayım gerektirmez ve lineer olarak ayrılabilir olmayan sınıflara uygulanabilir (Kilic, 2024).

Kümeleme; giriş desenlerinin benzerliklerini veya farklılıklarını keşfederek, denetimsiz öğrenme yoluyla gerçekleştirilir. Ağ, "benzer" desenleri aynı kümeye atar. Mikrobiyolojiden örnek uygulamalar, piroliz kütle spektrometrisi ve Kohonen ağları kullanarak alt tür ayırımı içerir (Kisacikoglu, 2012).

Fonksiyon yaklaşımı (modelleme); giriş-çıkış verileri üzerinde yapay sinir ağlarını eğitmeyi içerir, böylece girişleri çıkışlara ilişkilendiren temel kuralları yaklaşık olarak bulabilir. Çok katmanlı yapay sinir ağları, herhangi bir keyfi fonksiyonu herhangi bir doğruluk derecesine kadar yaklaştıran evrensel yaklaşımcılar olarak kabul edilir ve bu nedenle genellikle bu uygulamada kullanılır. Fonksiyon yaklaşımı, teorik bir modelin mevcut olmadığı, yani deneylerden veya gözlemlerden elde edilen verilerin kullanıldığı veya analitik olarak hesaplanması zor olan teorik modellerin yerine geçmek için bu tür modellerden elde edilen verilerin kullanıldığı problemlere uygulanır. Bu kategoriden örnekler mikrobiyolojide yaygındır, örneğin mikrobiyal büyümeyi tahmin etme (Lee, 1991).

Tahmin; belirli bir senaryoda belirli bir olgunun temsil edildiği bir zaman serisinden örneklerle bir yapay sinir ağının eğitilmesini içerir ve ardından bu ağı diğer senaryolarda kullanarak sonraki zamanlardaki davranışı tahmin etmek için kullanır (Masters, 1994).

1.8. ANN Proje Geliştirme Adımları

Başarılı bir yapay sinir ağı (ANN) projesinin geliştirilmesi altı aşamalı bir döngüyü içerir. Sorun tanımı ve formülasyonu (aşama 1), sorunu anlamının ve özellikle "neden-sonuç" ilişkilerinin yeterli bir şekilde anlaşılmasına dayanır (Nelson, Illingworth, 1990). Diğer tekniklerle karşılaştırıldığında ANN'lerin avantajları (mevcutsa) modelleme tekniğinin son seçimi öncesinde değerlendirilmelidir. Sistem tasarımı (aşama 2), probleme uygun bir ANN türünü belirlemede ilk adımdır. Bu aşama aynı zamanda veri toplama, verilerin ANN tipine uyacak şekilde ön işleme, veri istatistiksel analizi ve veriyi üç farklı alt kümeye (eğitim, test ve doğrulama alt kümeleri) ayırma işlemlerini içerir. Sistem gerçekleştirme (aşama 3), ağın eğitim ve test alt kümelerini kullanarak eğitilmesini ve aynı zamanda tahmin hatasını analiz ederek ağın performansını değerlendirir. Ağın nihai tasarımını ve performansını etkileyen çeşitli parametrelerin (örneğin, ağ boyutu, öğrenme oranı, eğitim döngüsü sayısı, kabul edilebilir hata vb.) optimal seçimi önemlidir. Problemi mümkünse daha küçük alt problemlere bölmek ve bir ağ ansamblı tasarlamak, genel sistem doğruluğunu artırabilir. Sistem doğrulama (aşama 4), ağın test verilerine karşı test edilmesini içerir ve geliştirme aşamasında yapılan eğitim sırasında genellemenin yeteneğini doğrulamayı amaçlar (Nabiyev, 2012). Doğrulama ayrıca diğer yaklaşımların (örneğin, istatistiksel regresyon ve uzman sistemler) performansı ile ANN tabanlı modelin



performansını karşılaştırmayı içerir. Sistem uygulaması (aşama 5), elde edilen ağın uygun bir çalışma sistemi içinde yerleştirilmesini içerir. Entegre sistemin nihai testi, kullanıma sunulmadan önce yapılmalıdır. Sistem bakımı (aşama 6), çevre veya sistem değişkenlerinde (örneğin, yeni veri) meydana gelen değişikliklerde sistemi güncelleme işlemini içerir, bu da yeni bir geliştirme döngüsünü gerektirebilir (Moody, Yarvin, 1992).

2. YÖNTEM

Bu çalışmada, Vehicle-to-Grid (V2G) sistemlerinin enerji verimliliği ve şebeke dengesi üzerindeki etkilerini incelemek amacıyla makine öğrenimi ve derin öğrenme teknikleri kullanılmıştır. Çalışmada, EV'lerin şebekeye enerji geri besleme süreci, şebeke talebinin öngörülmesi ve EV batarya durumlarının tahmin edilmesi için çeşitli algoritmalar uygulanmıştır. Araştırma, farklı algoritmalar ve optimizasyon teknikleri kullanılarak gerçekleştirilmiştir. Bu bölümde, kullanılan araştırma tasarımı, veri seti ve yöntemsel yaklaşım detaylı bir şekilde açıklanacaktır.

Bu makale çalışmasında önerilen çözüm, elektrikli araçlar (EV) ve araçtan şebekeye (V2G) sistemlerinin entegrasyonunu daha verimli hale getirmek amacıyla bir mobil uygulama geliştirilmesini önermektedir. Bu uygulama, şebeke sahiplerine talep dengesini sağlamak konusunda yardımcı olurken, elektrikli araç sahiplerine de talep ihtiyacının yüksek olduğu zamanlarda bildirim göndererek, ek kazanç elde etme imkânı sunacaktır.

Uygulama Tasarımı ve Genel İşleyişi:

Uygulama, kullanıcıların enerji talep tahminleri hakkında bilgi alabileceği ve şebeke ile etkileşimde bulunabileceği bir platform olarak tasarlanacaktır. Elektrikli araç kullanıcıları, şebeke üzerindeki yüksek talep zamanlarında, araçlarını şebekeye geri beslemeyi tercih ederek ek gelir elde edebilirler. Uygulama, makine öğrenimi (ML) ve derin öğrenme (DL) yöntemlerinden faydalanarak şebeke talep tahminlerini doğru şekilde yapacak ve bu tahminlere dayanarak araç sahiplerine bildirimler gönderecektir.

Uygulamanın temel işlevleri şunlardır:

- **Talep Tahmini ve Bildirim Gönderimi:** Uygulama, şebeke talebinin yüksek olduğu zamanları tahmin edecek ve bu dönemlerde araç sahiplerine bildirim göndererek, şebekeye enerji geri besleme yapmalarını teşvik edecektir. Bildirimler, araçların şebekeye bağlanacağı en uygun zamanları belirleyerek kullanıcıyı bilgilendirecektir.
- **Kazanç Takibi:** Elektrikli araç sahipleri, şebekeye sağladıkları enerji karşılığında kazançlarını uygulama üzerinden takip edebilecektir. Kullanıcılar, araçlarının şarj seviyelerini, geri besleme oranlarını ve kazançlarını kolayca görüntüleyebilir.
- **Makine Öğrenimi Model Entegrasyonu:** Elektrikli araç kullanıcılarının doğru zamanda doğru miktarda enerji geri beslemeleri için uygulama, geçmiş talep verilerini analiz ederek gelecekteki talep dalgalanmalarını tahmin edecektir. Bu tahminler, Random Forest veya XGBoost gibi modeller kullanılarak yüksek doğrulukla yapılacaktır.

Şebeke Sahiplerine Sağlanan Faydalar:

Uygulama, şebeke sahiplerine, talep dalgalanmalarını daha verimli bir şekilde yönetme imkânı sağlar. Elektrikli araçların şebekeye entegre edilmesi, şebeke üzerindeki talep artışlarını dengeleme konusunda önemli bir yardımcı olacaktır. Şebeke yöneticileri, uygulama aracılığıyla talebin arttığı zamanları daha doğru bir şekilde tahmin edebilir ve bu zaman dilimlerinde enerji üretimlerini artırabilir.



Şebeke sahipleri ayrıca, araç sahiplerinin geri besleme yapması sayesinde enerji üretimi ile tüketimi arasında dengenin sağlanmasına katkıda bulunabilirler. Böylece, enerji tüketiminde daha verimli bir yönetim sağlanabilir.

Uygulamanın Teknolojik Yönü ve Model Entegrasyonu:

Uygulama, veri toplama ve makine öğrenimi model entegrasyonunu kullanarak şebeke talep tahminlerini daha doğru hale getirecektir. Şebeke talep verileri, kullanıcıların araçları ve şebekedeki enerji talep durumları sürekli olarak izlenecektir. Elektrikli araçların şarj durumları, kullanıcı bilgileri ve geri besleme kapasitesi gibi veriler, güvenli bir şekilde toplanacak ve makine öğrenimi modeline besleme yapılacaktır.

Makine öğrenimi ve derin öğrenme modelleri, şebeke talebinin zaman içindeki değişimini tahmin etmek için kullanılacaktır. Bu, özellikle enerji talebinin yüksek olduğu zamanlarda şebekeye yapılacak enerji geri beslemeleri konusunda elektrikli araç sahiplerine doğru bildirimlerin gönderilmesini sağlayacaktır. Bu süreçte, XGBoost ve Random Forest gibi güçlü algoritmalar, doğrusal olmayan ilişkileri modelleyerek daha doğru tahminler yapabileceklerdir.

Ekonomik ve Çevresel Avantajlar:

Uygulamanın elektrikli araç sahiplerine sağlayacağı ek gelir, enerji talebine dayalı olarak daha verimli bir şebeke kullanımına olanak tanıyacaktır. Elektrikli araç kullanıcıları, talep tahminlerine göre enerji sağlayarak şebekeye katkıda bulunacak ve bu süreçten gelir elde edebileceklerdir. Şebeke sahipleri ise bu enerji geri beslemelerini kullanarak talep dalgalanmalarını daha verimli yönetebileceklerdir.

Çevresel açıdan bakıldığında, şebekeye enerji geri besleme yaparak elektrikli araçlar, fosil yakıtla çalışan jeneratörlerin kullanımını azaltır ve yenilenebilir enerji kaynaklarının daha verimli kullanılmasına olanak tanır. Bu da çevreye olan etkileri minimize eder ve karbon emisyonlarını düşürür.

Uygulamanın Gelecekteki Potansiyeli ve İyileştirme Alanları:

Uygulama, şebeke talep tahminlerinin doğruluğunu artıracak şekilde sürekli olarak gelişebilecek bir yapıya sahip olacaktır. Veri setlerinin büyüklüğü arttıkça, modelin doğruluğu daha da artacak ve daha fazla elektrikli araç kullanıcılarına ulaşılacaktır.

Uygulamanın gelecekteki versiyonlarında, yapay zeka tabanlı karar destek sistemleri ve derin öğrenme optimizasyonları ile daha sofistike tahminler yapılabilecektir.

Ayrıca, uygulama sadece şebeke talep tahmini yapmakla kalmayacak, aynı zamanda kullanıcı geri bildirimlerini toplayarak, kullanıcı deneyimini ve kazanç optimizasyonunu sürekli olarak iyileştirecektir.

Sonuç: Uygulamanın makale çalışmasında Entegrasyonu ve Gelecek Çalışmalar:

Bu uygulama, şebeke talep tahminlerinin doğruluğunu artırmaya yönelik önerilen teorik yaklaşımların pratikte nasıl kullanılabileceğini gösteren önemli bir örnektir. Elektrikli araçların şebeke entegrasyonu, enerji yönetimi açısından büyük fırsatlar sunmaktadır. Bu uygulama, elektrikli araç sahiplerinin ek kazanç elde etmelerini sağlayarak, şebeke üzerinde enerji talep dengesinin sağlanmasına katkı sunar. Uygulamanın geliştirilmesi, makine öğrenimi ve derin öğrenme yöntemlerinin şebeke yönetiminde nasıl etkin bir şekilde kullanılabileceğini ve bu teknolojilerin enerji sektöründe nasıl devrim yaratabileceğini gösteren bir örnek teşkil edecektir.

2.1. Araştırma Tasarımı ve Yöntemi

Bu çalışmada uygulanan araştırma tasarımı, gözlemsel bir tasarımdır. Temel hedef, şebeke talebinin ve EV batarya seviyelerinin gelecekteki davranışlarını tahmin etmek ve V2G sisteminin verimliliğini optimize etmek için makine öğrenimi ve derin öğrenme algoritmalarını kullanmaktır. Araştırmanın temel bileşenleri şunlardır:



- Makine Öğrenimi Modelleri: EV bataryalarının şarj ve deşarj zamanlarının doğru tahmin edilmesi için klasik makine öğrenimi algoritmaları (Destek Vektör Regresyonu, Rastgele Ormanlar, K-En Yakın Komşu) kullanılmıştır.
- Yapay Sinir Ağları: karmaşık verilerden anlamlı bilgiler çıkarabilen ve birçok farklı problemde yüksek doğrulukla sonuçlar elde edebilen güçlü modelleme araçlarıdır.

2.2. Veri Seti ve Veri Toplama

Bu çalışmada kullanılan veri seti, ingiltere kaynaklı şebeke yönetim sistemlerinden alınan verilerden oluşmaktadır. Veri seti aşağıdaki bileşenleri içermektedir:

- Şebeke Talebi Verileri: Elektrik şebekesinin günlük talep verileri, farklı zaman dilimlerinde (günlük, haftalık, aylık) toplanmıştır. Bu veriler, şebeke yönetimi için kritik bir rol oynar ve EV'lerin şarj/deşarj süreçlerinin optimize edilmesinde kullanılmıştır.
- Yenilenebilir Enerji Kaynakları Verileri: Rüzgar enerjisi, güneş enerjisi gibi yenilenebilir enerji kaynaklarına ait veriler de veri setinde yer almaktadır. Bu veriler, şebekenin enerji üretim kapasitesini ve EV'lerin şarj/deşarj işlemlerini etkileyebilir. Yenilenebilir enerji üretimi genellikle hava koşullarına bağlı olduğundan, bu veriler şebeke yönetiminin daha verimli hale getirilmesinde önemlidir.

Zaman Bilgisi: Veri seti, tarih, gün, ay, yıl ve saat bilgilerini içermektedir. Bu zaman damgaları, verilerin doğru bir şekilde analiz edilmesini sağlar ve özellikle enerji talebi ile şebeke yönetiminin zamanla nasıl değiştiğini izlemek için gereklidir. Ayrıca, bu zaman bilgileri, EV'lerin şarj/deşarj süreçlerinin ve yenilenebilir enerji üretiminin zaman dilimlerine göre optimize edilmesini sağlar (Ogura, Kolhe, 2017).

2.3. Veri Ön İşleme

Veri setlerinin doğru bir şekilde işlenmesi, modelin başarısı için kritik öneme sahiptir.

Veri ön işleme adımları şunlardır:

Eksik Veri Doldurma: Veri setlerinde bulunan eksik değerler, lineer interpolasyon veya örnekleme yöntemleriyle tamamlanmıştır. Bu adım, modelin doğruluğunu artırmak için önemlidir.

Veri Normalizasyonu: Özellikle derin öğrenme modellerinde, verilerin min-max scaling veya Z-skoru normalizasyonu gibi tekniklerle normalize edilmesi gerekmiştir. Bu adım, modelin daha hızlı ve verimli öğrenmesini sağlar.

Tarih Sütununu Gün, Ay, Yıl ve Saate Bölme: Veri setindeki tarih sütunu, modelin zamanla ilgili analizler yapabilmesi için daha anlamlı hale getirilmiştir. Tarih bilgisi, gün, ay, yıl ve saat gibi bileşenlere ayrılmıştır. Bu sayede, şebeke talebi, çevresel koşullar ve enerji üretimi gibi faktörlerin zamansal değişimleri daha iyi analiz edilebilecektir. Ayrıca, modelin zaman serisi analizinde daha etkili olabilmesi için bu bileşenler ayrı ayrı özellikler olarak kullanılacaktır.

Korelasyonu Yüksek Olan Özelliklerin Atılması: Özellikler arasındaki yüksek korelasyon, modelin performansını olumsuz etkileyebilir. Bu nedenle, korelasyonu yüksek olan (genellikle 0.8 ve üzeri) özellikler analiz edilerek modelden çıkarılmıştır. Bu adım, fazla ve tekrar eden bilgilere sahip olan özelliklerin ortadan kaldırılmasını sağlar ve modelin daha verimli çalışmasına olanak tanır.




2.4. Makine Öğrenimi Yöntemleri

2.4.1. Random Forest

Güçlü ve esnek bir makine öğrenimi algoritmasıdır ve özellikle büyük veri setlerinde oldukça etkilidir. Bu çalışmada, şebeke talebinin gelecekteki değerlerinin tahmin edilmesinde kullanılmıştır. Random Forest modeli, çok sayıda karar ağacının birleşimiyle çalışır ve her bir ağacın tahminini ortalama alarak son tahmin değerini belirler. Bu yöntem, overfitting (aşırı uyum) problemini minimize ederek yüksek doğruluk oranı sağlar.

Sonuçlar:



Şekil 1. Random forest Karar ağacının açıklanması

1. Kök Düğüm (Root Node):
 - a. İlk bölünme $utc_hour \leq 5.5$ kriterine göre gerçekleşmiş.
 - b. Bu düğümde toplam 17,384 örnek (sample) var ve bu örneklerin ortalama hedef değeri 35,226.784.
 - c. Bölünme, hata oranını (squared_error) azaltmak için en iyi ayrımı bulmuş.
2. Soldaki Dal ($utc_hour \leq 5.5$ olanlar):
 - a. Bu grup $utc_month \leq 3.5$ kriterine göre iki alt gruba ayrılmış:
 - i. $utc_month \leq 3.5$ olanlar: Bu alt grupta 4,297 örnek var ve ortalama hedef değeri 26,087.843.
 - ii. Alt gruplardan biri 941 örnekle value = 28,551.986, diğeri 3,356 örnekle value = 25,396.914.
3. Sağdaki Dal ($utc_hour > 5.5$ olanlar):
 - a. Bu grup $utc_hour \leq 20.5$ kriterine göre ikiye ayrılmış:
 - i. $utc_hour \leq 20.5$ olanlar: Bu alt grupta 10,892 örnek var ve ortalama hedef değeri 39,544.781.
 - ii. $utc_hour > 20.5$ olanlar: Bu alt grupta 2,195 örnek var ve ortalama hedef değeri 31,690.753.




Genel Gözlemler:

- Saat (utc_hour), hedef değişkeni etkileyen en önemli faktördür, çünkü ilk ayırım bu özelliğe dayanarak yapılmış.
- Ay (utc_month), belirli saat aralıklarında daha detaylı bir ayırım sağlamak için kullanılmış.
- Her bölünme, hata oranını (squared_error) azaltmayı amaçlıyor, böylece her düğüm daha homojen hale geliyor.
- R2 Score: 0.9502
- Mean Absolute Error (MAE): 1154.11
- Modelin Genel Başarısı: Modelin elde ettiği yüksek R2 skoru (0.9502), tahminlerin gerçek verilere oldukça yakın olduğunu ve modelin güçlü bir doğruluk sağladığını göstermektedir. Ayrıca, MAE değeri 1154.11, modelin hata miktarının nispeten düşük olduğunu gösterir.

2.4.2. Karar Ağaçları (Decision Tree)

Veriyi bölerek her bir bölümü sınıflandıran veya regresyon yapan bir makine öğrenimi yöntemidir. Bu yöntem, veri setindeki her bir özellik üzerinden kararlar alarak, hedef değişkeni tahmin etmek için ağaç şeklinde bir yapı oluşturur. Karar Ağaçları, özellikle açıklanabilirlik açısından avantajlıdır, ancak aşırı uyum (overfitting) yapma riski taşıyabilir. Bu çalışmada, şebeke talebinin gelecekteki değerlerinin tahmin edilmesinde karar ağaçları kullanılmıştır.



Şekil 2. Karar ağaçları

Sonuçlar:

- Mean Squared Error (MSE): 5,528,723.95
- R2 Score: 0.9067
- Mean Absolute Error (MAE): 1,426.79
- Modelin Genel Başarısı: Karar ağacı modeli, R2 skoru 0.9067 ile oldukça yüksek bir doğruluk sergilemiştir. Bu, modelin şebeke talebinin gelecekteki değerlerini oldukça iyi tahmin edebildiğini




gösterir. MSE değeri 5,528,723.95, modelin tahminlerinde ortalama hata miktarının bir ölçüsüdür.

- MAE ise 1,426.79 olarak hesaplanmış olup, modelin hata miktarının yine oldukça düşük olduğunu gösterir. zaman içindeki değişimini tahmin etmek amacıyla kullanılmıştır. Rastgele Ormanlar, çok sayıda karar ağacının birleşiminden oluştuğu için, karmaşık ilişkileri modelleme konusunda güçlüdür.

2.4.3. XGBoost

Güçlü bir makine öğrenimi algoritması olup, özellikle büyük veri setlerinde yüksek performans gösteren bir gradient boosting yöntemidir. Bu algoritma, modelin doğruluğunu artırmak için ağaç tabanlı bir öğrenme stratejisi kullanır ve genellikle doğrusal olmayan ilişkileri modellemede etkilidir.



Şekil 3. KNN

Sonuçlar:

- Mean Squared Error (MSE): 4,316,338.37
- R2 Score: 0.9272
- Mean Absolute Error (MAE): 1,570.13



2.4.4. KNN (Manhattan)

K-En Yakın Komşu algoritmasının Manhattan mesafesi (L1 normu) kullanarak uygulandığı bir regresyon yöntemidir. Bu algoritma, her bir veri noktasının en yakın komşularına olan mesafeyi hesaplar ve tahmini, bu komşuların hedef değerlerinin ortalaması olarak belirler. Manhattan mesafesi, özellikle veri noktalarının doğrusal olmayan ilişkilerdeki yakınlıklarını ölçmek için kullanılır.

Sonuçlar:

- Mean Squared Error (MSE): 4,798,205.53
- R2 Score: 0.9190
- Mean Absolute Error (MAE): 1,573.35

2.5. Yapay Sinir Ağları

Derin öğrenme teknikleri, zaman serisi verilerinin modellemesinde etkili sonuçlar elde edilmesini sağlamıştır. Bu çalışmada, **Yapay Sinir Ağları** (ANN).

2.5.1. MLPRegressor


Çok katmanlı algılayıcı (MLP) yapısına sahip bir yapay sinir ağı modelidir. Bu model, veriyi öğrenirken çok sayıda gizli katman kullanarak daha karmaşık ve doğrusal olmayan ilişkileri yakalamaya çalışır. MLPRegressor, özellikle büyük ve karmaşık veri setlerinde güçlü tahminler yapabilen bir regresyon modelidir.

Sonuçlar:

- Mean Squared Error (MSE): 7,399,522.33
- R2 Score: 0.8752
- Mean Absolute Error (MAE): 2,093.76

2.5.2. PyTorch ANN

Bu çalışmada, PyTorch kullanarak geliştirilen yapay sinir ağı modeli de değerlendirilmiştir. PyTorch, model üzerinde tam kontrol sağlayarak daha esnek bir yapay sinir ağı yapılandırmasına imkan tanır.



Kurulan model, bir yapay sinir ağı (ANN) mimarisidir. Aşağıdaki bileşenlerden oluşur:



1. Giriş Katmanı (Input Layer):

- Model 7 giriş özelliği kabul eder. Bu özellikler:
 - GB_GBN_solar_profile
 - GB_GBN_wind_profile
 - GB_GBN_wind_offshore_profile
 - GB_GBN_wind_onshore_profile
 - utc_hour
 - utc_day
 - utc_month

2. Birinci Gizli Katman (Hidden Layer 1):

- Linear (in_features=7, out_features=128, bias=True)
- Giriş katmanından gelen 7 özelliği alır ve 128 düğümlü bir gizli katmana aktarır.
- Bu katmanda öğrenme için Linear (Doğrusal) bir fonksiyon kullanılır ve bir bias terimi de eklenir (bias, tahmin doğruluğunu artırır).

3. İkinci Gizli Katman (Hidden Layer 2):

- Linear (in_features=128, out_features=64, bias=True)
- Birinci gizli katmandan gelen 128 düğümü işler ve bunları 64 düğümlü bir başka gizli katmana aktarır.
- Aynı şekilde doğrusal bir fonksiyon ve bias terimi kullanılır.

4. Çıktı Katmanı (Output Layer):

- Linear (in_features=64, out_features=1, bias=True)
- İkinci gizli katmandan gelen 64 düğümü işleyerek tek bir çıktı değerine dönüştürür.
- Bu çıktı, modelin tahmin ettiği son değer örneğin, enerji talebini tahmin eder.

Sonuçlar:

- Mean Squared Error (MSE): 15,434,333.69
- R2 Score: 0.7396
- Mean Absolute Error (MAE): 3,102.22

3. BULGULAR

Bu çalışmada, şebeke talebinin gelecekteki değerlerinin tahmin edilmesinde kullanılan farklı makine öğrenimi ve derin öğrenme modellerinin başarıları incelenmiştir. Modellerin tahmin doğruluğu, çeşitli performans metrikleriyle değerlendirilmiş ve elde edilen sonuçlar aşağıda sunulmuştur.

Random Forest Bu çalışmada, Random Forest Regressor modeli kullanılarak belirli bir regresyon probleminin çözülmesi amaçlanmıştır. Modelin performansını


değerlendirmek için üç ana metrik kullanılmıştır: Mean Squared Error (MSE), R-squared (R^2) Skoru ve Mean Absolute Error (MAE). Aşağıda, modelin test verisi üzerindeki performansı hakkında elde edilen bulgular sunulmaktadır.

- Mean Squared Error (MSE): Modelin tahminleri ile gerçek değerler arasındaki ortalama kare farklarını ölçen bu metrik, modelin genel hata seviyesini gösterir. Bu çalışmada elde edilen MSE değeri [mse_rf değeri] olarak hesaplanmıştır. Düşük MSE değeri, modelin tahminlerinin gerçek değerlere yakın olduğunu göstermektedir.
- R-squared (R^2) Skoru: R^2 skoru, modelin açıklayabildiği varyans oranını gösteren bir metriği ifade eder. Bu çalışmada, modelin R^2 skoru [r2_rf değeri]



olarak bulunmuştur. R^2 değeri, modelin veri setindeki değişkenliği ne kadar iyi açıklayabildiğini gösterir. Yüksek bir R^2 skoru, modelin veri üzerindeki doğruluğunun yüksek olduğunu işaret eder.

- Mean Absolute Error (MAE): MAE, tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasını verir. Bu metrik, modelin ne kadar büyük hatalar yaptığını anlamak için kullanılır. Çalışmada MAE değeri [mae değeri] olarak elde edilmiştir.



Şekil 4. Gerçek ve tahmin edilen değerlerin dağılımı random forest

Sonuç olarak, Random Forest Regressor modelinin [gerekli model başarı değerlendirme] gösterdiği ve modelin tahmin performansının regresyon için çalışmada kullanılan diğer değerlere göre daha başarılı olduğu değerlendirilmektedir. Modelin performansını daha da iyileştirmek için parametre ayarlamaları veya farklı model denemeleri yapılabilir.

Karar Ağaçları (Decision Tree) modeli de yüksek doğruluk göstermiştir. R^2 skoru 0.9067, modelin başarılı bir şekilde şebeke talebinin gelecekteki değerlerini tahmin edebildiğini belirtmektedir. Ancak, Mean Squared Error (MSE) değeri 5,528,723.95 ile daha yüksek bir hata oranı ortaya koymuş, bu da modelin bazen büyük hatalar yapabildiğini göstermektedir. Buna rağmen, Mean Absolute Error (MAE) değeri 1,426.79, modelin genel başarısını pekiştiren bir ölçüdür.

XGBoost algoritması, güçlü bir gradient boosting yöntemi olarak, özellikle doğrusal olmayan ilişkileri modellemede etkili olmuştur. Modelin R^2 skoru 0.9272, tahminlerin genel doğruluğunu yansıtırken, Mean Squared Error (MSE) değeri 4,316,338.37, Mean Absolute Error (MAE) değeri ise 1,570.13 olarak hesaplanmıştır. Bu sonuçlar, modelin yüksek doğruluk sağladığını fakat Random Forest modeline göre biraz daha düşük bir performans sergilediğini göstermektedir.


KNN (Manhattan) algoritması, Manhattan mesafesi kullanarak en yakın komşularına dayalı tahminler yapmıştır. Modelin R^2 skoru 0.9190, tahminlerin doğruluğunu göstermekte olup, Mean Squared Error (MSE) değeri 4,798,205.53 ve Mean Absolute Error (MAE) değeri 1,573.35 ile kararlı bir performans sergilemiştir. Ancak, bu modelin tahminleri, özellikle Random Forest ve XGBoost modellerine kıyasla daha büyük hata paylarına sahip olmuştur.

Model, 100, 100 nöronlu iki gizli katmandan oluşan bir yapı ile tasarlanmıştır. Eğitim sırasında ReLU aktivasyon fonksiyonu kullanılmış ve eğitim süreci 1000 iterasyon



boyunca devam etmiştir. Modelin performansını değerlendirmek için kullanılan üç ana metrik şunlardır:

- Ortalama Kare Hatası (MSE): Modelin hata karelerinin ortalaması, yani tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını temsil eder. Bu metrik, modelin hata büyüklüğünü doğrudan gösterir. Hesaplanan değer, [buraya MSE değeri eklenmeli] olarak bulunmuştur.
- R^2 Skoru (R-Kare): Modelin doğruluğunu ve veriye ne kadar iyi uyduğunu gösteren bu metrik, modelin veriye ne kadar açıklık kattığını ölçer. R^2 skoru [buraya R^2 değeri eklenmeli] olarak elde edilmiştir. Bu sonuç, modelin genel başarı düzeyini yansıtır.
- Ortalama Mutlak Hata (MAE): Modelin tahminleri ile gerçek değerler arasındaki mutlak farkların ortalamasıdır. Bu metrik, modelin tahmin hatalarının ne kadar büyük olduğunu anlamamıza yardımcı olur. Sonuç olarak, MAE değeri [buraya MAE değeri eklenmeli] olarak bulunmuştur.



Şekil 5. Gerçek ve tahmin edilen değerlerin dağılımı ANN

Genel olarak, Random Forest modeli en yüksek doğruluğu sağlamakta ve düşük hata oranlarıyla en başarılı tahminleri yapmaktadır. Karar Ağaçları ve XGBoost modelleri de güçlü performanslar sergilemiş, ancak Random Forest kadar düşük hata değerleri elde edememiştir. KNN (Manhattan) algoritması, Random Forest ve XGBoost'a kıyasla daha büyük hata değerlerine sahip olsa da, yine de kabul edilebilir seviyede doğruluk göstermektedir. MLPRegressor modelinin başarısı, diğer modellere göre daha düşük kalmış, bu da derin öğrenme yöntemlerinin bu tür tahminlerde daha fazla eğitim verisi ve optimizasyon gerektirdiğini göstermektedir.

Sonuç olarak, bu çalışmada kullanılan modellerin her biri, şebeke talebinin tahmini için farklı derecelerde doğruluk sağlamış ve her bir modelin avantajları ve sınırlamaları gözlemlenmiştir. Bu bulgular, gelecekteki çalışmalar için önemli bir referans sağlamaktadır ve daha karmaşık veri setlerinde kullanılacak modellerin seçimi ve optimizasyonu için yönlendirici olacaktır.



Tablo 2. Sonuçların kıyaslaması

Model	R ² Score	Mean Absolute Error (MAE)
Random Forest	0.9502	1,154.11
Karar Ağaçları	0.9067	1,426.79
XGBoost	0.9272	1,570.13
KNN (Manhattan)	0.9190	1,573.35
MLPRegressor	0.8752	2,093.76
PyTorch ANN	0.7396	3,102.22

3. SONUÇ VE ÖNERİLER

Elektrikli araçlar (EV), şebeke ile entegre edildiğinde, yalnızca kullanıcılar için ekonomik faydalar sağlamakla kalmaz, aynı zamanda şebeke yönetiminde de önemli rol oynar. V2G teknolojisi ile elektrikli araçlar, şebekedeki talep artışlarını dengelemek amacıyla enerji geri beslemesi yapabilir. Bu, özellikle yenilenebilir enerji kaynaklarının (güneş ve rüzgar gibi) üretimindeki dalgalanmaları dengelemede çok önemli bir katkı sağlar. Elektrikli araçların şebekeye enerji geri besleme kapasitesi, daha verimli ve sürdürülebilir bir enerji yönetimi sağlar.

Bu çalışma, elektrikli araçların şebeke talep tahminlerine entegre edilmesinin, hem bireysel kullanıcılar hem de enerji tedarik şirketleri için büyük bir avantaj sağladığını göstermektedir. Kullanıcılar, araçlarını şebekeye entegre ederek enerji taleplerine dayalı olarak ek gelir elde edebilirken, enerji tedarik şirketleri, şebeke üzerindeki talep dalgalanmalarını daha verimli bir şekilde yönetebilirler. Bu sayede enerji üretimi, dağıtımı ve tüketimi daha sürdürülebilir hale gelir.

Elektrikli araçların şebekeye entegrasyonu yalnızca ekonomik faydalar sağlamakla kalmaz, aynı zamanda çevresel etkileri de olumlu yönde değiştirir. Elektrikli araçlar, karbon emisyonlarını azaltarak çevreye duyarlı bir ulaşım çözümü sunmaktadır. Ayrıca, şebeke talebini dengelemek amacıyla enerji geri beslemesi yaparak, yenilenebilir enerji kaynaklarının kullanım oranını artırır ve fosil yakıtla çalışan jeneratörlerin kullanımını azaltır. Bu da uzun vadede çevresel sürdürülebilirliği artırır.

Elektrikli araçların şebekeye entegre edilmesiyle, şebeke üzerindeki enerji taleplerindeki dalgalanmalar daha verimli bir şekilde yönetilebilir. Özellikle şebeke üzerinde talep artışlarının yaşandığı saatlerde, elektrikli araçlar enerji vererek şebekeye katkıda bulunabilir ve enerji arzındaki dengesizlikleri azaltabilir.

Bu çalışmada elde edilen bulgular, elektrikli araçlar ve V2G sistemlerinin şebeke ile entegrasyonunun büyük bir potansiyel taşıdığını ve bu sistemlerin enerji yönetiminde devrim yaratabileceğini ortaya koymaktadır.

Bu çalışma, elektrikli araçların şebeke enerji talep tahminlerindeki rolünü ortaya koyarak, V2G sisteminin enerji yönetimi açısından büyük potansiyel taşıdığını göstermiştir. Çalışma, makine öğrenimi ve derin öğrenme yöntemlerinin bu bağlamda etkin kullanımını inceleyerek, elektrikli araçların şebeke entegrasyonunun çevresel ve ekonomik faydalarını detaylı bir şekilde tartışmıştır.



Elde edilen sonuçlar, bu teknolojilerin gelecekte enerji sektöründe önemli bir rol oynayabileceğini, şebeke talep tahminlerinin doğruluğunu artırarak, daha verimli ve sürdürülebilir bir enerji yönetimi sağlayabileceğini göstermektedir. Bu araştırmanın bulguları, enerji tedarik şirketlerine, elektrikli araç kullanıcılarına, enerji taleplerini daha iyi yönetmeleri ve enerji verimliliğini artırmaları için değerli bilgiler sunmaktadır.

REFERENCES

- Andrew, J. (1991). *Sezgisel programlama temelli bir yaklaşım*.
- Basheer, I. A. (2000). *Yapay sinir ağları ile sürekli fonksiyonların öğrenilmesi*.
- Başoğlu, B., & Bulut, M. (Yıl). Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. -
- Baum, E. B., & Haussler, D. (1989). Eğitim alt kümesinin minimum boyutu ve ağırlık sayısının minimum hedef hatası ile ilişkisi. *Journal of Machine Learning*.
- Birleştirici, E., et al. (2015). *Electric Vehicle Charging Systems: A Review of Technologies, Standards, and Future Trends*. *Journal of Renewable and Sustainable Energy*, 7(6), 1235-1244.
- Budde-Meiwes, H., et al. (2013). *Improvement of Lead-Acid Battery Technology for Electric Vehicles*. *Journal of Energy Storage*, 2(3), 172-182.
- Cluzel, C., & Douglas, R. (2012). *Lead-Acid Batteries in Industrial Applications*. *Industrial Applications*, 5(1), 45-54.
- Copelan, P. (1993). *Akıllı programlar hedefleyen bir bilim*.
- Dikmen, S., & Karadag, D. (2021). *Optimization of Electric Vehicle Charging Systems for Enhanced Safety and Efficiency*. *Journal of Energy Storage*, 32, 101729.
- Dikmen, S., et al. (2018). *Electric Vehicle Batteries: Technologies and Applications*. Springer.
- Dowla, F., & Rogers, B. (1995). *Veri ön işleme ve dengeleme teknikleri*.
- Eaton, W. H., & Olivier, B. (1992). *Adaptif öğrenme hızı ve momentum*.
- Ecker, M., et al. (2012). *Safety and Efficiency in Electric Vehicle Charging: A Comprehensive Review*. *Energy Reviews*, 15(4), 876-889.
- Ecker, M., et al. (2012). *Yapay zeka ve öğrenme teorisi*.
- Fahlman, S. E. (1988). *Yapay sinir ağlarında başlangıç ağırlıklarının etkisi*.
- Genesereth, M., & Nilsson, N. J. (1985). *Akıllı davranışların yapay olarak üretimi*.
- Gerssen-Gondelach, S. J., & Faaij, A. P. C. (2012). *Performance and Cost of Lead-Acid Batteries in Electric Vehicles: A Comparative Study*. *Renewable and Sustainable Energy Reviews*, 16(7), 4890-4899.
- Hamzaçebi, A. (2007). Forecasting of Turkey's net electricity energy consumption on sectoral bases. *Energy Policy*.
- Han, S., et al. (1996). *Değişken lojistik fonksiyon ve sinir ağı öğrenme*.
- Hecht-Nielsen, R. (1990). *Yapay sinir ağları ve genel ağ öğrenme teknikleri*.
- Henseler, J. (1995). *Momentum parametresi ve ağırlık güncelleme*.
- IEC 62196. (2014). *Plugs, socket-outlets, vehicle connectors, and vehicle inlets – Conductive charging of electric vehicles*. International Electrotechnical Commission (IEC).
- International Energy Agency (IEA), 2019. *Global CO2 Emissions from Fossil Fuels*. International Energy Agency (IEA), <https://www.iea.org/reports/global-co2-emissions-from-fossil-fuels> [Erişim: 17 Aralık 2024].



- Karaca, M., & Karacan, H. (2016). Çoklu regresyon metoduyla elektrik tüketim talebini etkileyen faktörlerin incelenmesi. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*.
- Kheirkhah, S., & Diğerleri. (2013). Improved estimation of electricity demand function by using artificial neural network, principal component analysis, and data envelopment analysis. *Computers Industrial Engineering*.
- Kilic, Analysis of Charging Systems for Electric Vehicle. *International Journal of Smart Grid-ijSmartGrid* 7.3 (2023): 168-177.
- Kilic, Charging Techniques, Infrastructure, and Their Influences. *Engineering Perspective* 3.4 (2023): 68-74.
- Kilic. Smart, Secure and Interoperable Charging Infrastructure with Plug and Charge." *2024 12th International Conference on Smart Grid (icSmartGrid)*. IEEE, 2024.
- Kisacikoglu, M., et al. (2012). *Electric Vehicles: A Review of Powertrain Technologies and Future Trends*. *Energy Conversion and Management*, 53(1), 56-70.
- Lee, W., et al. (1991). *Ağ eğitiminde erken nöron doygunluğunu önlemek*.
- Masters, T. (1994). *Yapay sinir ağlarının teorisi ve uygulamaları*.
- Moody, J., & Yarvin, S. (1992). *Veri doğrusallığı ve gürültüsüne bağlı transfer fonksiyonları*.
- Nabiyev, A. (2012). *Yapay Zeka ve Algoritmalar*.
- Nelson, M., & Illingworth, J. (1990). *Veri setlerinin bölümlenmesi ve genelleme*.
- Ogura, H., & Kolhe, M. (2017). *Energy Storage Systems for Electric Vehicles*. Elsevier.
- Perujo, A., et al. (2012). *Comparative Analysis of Electric Vehicle Battery Technologies*. *Journal of Power Sources*, 207, 413-421.
- Popov, G. (1990). *İnsan davranışlarının bilgisayarlar tarafından yapılabilmesi üzerine*.
- Rizzo, D. M., & Dougherty, M. (1994). *Bir örnek bırakma yönteminin etkisi*.
- Rumelhart, D. E., et al. (1986). *Yapay sinir ağları ve öğrenme süreci*.
- Schmidt, H., et al. (1993). *Ağırlık başlangıçlarının ağ yakınsamasına etkisi*.
- Son, B., & Kim, H. (2017). Short-term forecasting of electricity demand for the residential sector using weather and social variables. *Resources, Conservation and Recycling*.
- Stein, D. (1993). *Aykırı değerlerin silinmesi ve veri analizi*.
- Sun, C., et al. (2020). *Advanced Lead-Acid Batteries: A Review on Energy Efficiency and Life Cycle*. *Journal of Energy Storage*, 28, 101220.
- Swingler, K. (1996). *Veri dengeleme ve sınıflandırma problemleri*.
- Taylor, J. W., & McSharry, P. E. (2008). Short-term load forecasting methods: An evaluation based on European data. *Digital Object Identifier*.
- Ülkü, M., & Yalpir, H. (2021). Enerji talep tahmini için metodoloji geliştirme: 2030 yılı Türkiye örneği. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*.
- Van den Bossche, P., et al. (2006). *Lead-Acid Batteries in Electric Vehicles*. Elsevier.
- Vidyanandan, K. (2019). *Electric Vehicles and Lead-Acid Batteries: A Review*. *Journal of Electrical Engineering & Technology*, 14(3), 983-992.
- Wessels, D., & Barnard, P. (1992). *Ağırlık başlangıçları ve sinir ağı bağlantıları*.
- Young, R., et al. (2013). *Battery Technology Handbook*. CRC Press.
- Zupan, J., & Gasteiger, J. (1993)