



Madde

Yenilenebilir Enerji ve Şebeke Verimliliğini Optimize Etmek İçin Makine Öğrenimi

Bankole I. Oladapo^{1,*}  Matthew A. Olawumi² ve Francis T. Omigbodun³ 

¹ Bilim ve Mühendislik Okulu, Dundee Üniversitesi, Dundee DD1 4HN, İngiltere Bilgisayar,

² Mühendislik ve Medya, De Montfort Üniversitesi, Leicester LE1 9BH, İngiltere;
olawumisola13@gmail.com

³ Wolfson Makine, Elektrik ve Üretim Mühendisliği Okulu, Loughborough Üniversitesi, Loughborough
LE11 3TU, Birleşik Krallık; f.omigbdun@lboro.ac.uk

* Yazışma: p17243433@my365.dmu.ac.uk

Soyut: Bu araştırma, yenilenebilir enerji sistemlerini optimize etmek ve Net Sıfır emisyon hedeflerine ulaşılmasına katkıda bulunmak için makine öğrenimi modellerinin uygulanmasını araştırmaktadır. Birincil amaç, makine öğreniminin enerji tahminini, şebeke yönetimini ve depolama optimizasyonunu nasıl iyileştirebileceğini değerlendirmek ve böylece yenilenebilir enerji kaynaklarının güvenilirliğini ve verimliliğini artırmaktır. Metodoloji, enerji üretimi ve talep modellerini tahmin etmek için Uzun Kısa Süreli Bellek (LSTM), Rastgele Orman, Destek Vektör Makineleri (SVM'ler) ve ARIMA dahil olmak üzere çeşitli makine öğrenimi modellerinin uygulanmasını içeriyordu. Bu modeller, Ortalama Mutlak Hata (MAE) ve Kök Ortalama Karesel Hata (RMSE) gibi metrikler kullanılarak değerlendirildi. Temel bulgular arasında optimizasyondan sonra şebeke verimliliğinde %15'lik bir iyileşme ve pil depolama verimliliğinde %10-20'lik bir artış yer almaktadır. Rastgele Orman, tahmin hatasını yaklaşık %8,5 oranında azaltarak en düşük MAE'yi elde etti. Çalışma, CO₂ enerji kaynağına göre emisyon azaltımları, rüzgar gücü yıllık 15.000 tonluk bir azalmaya neden olurken, hidroelektrik ve güneş enerjisi sırasıyla emisyonları 10.000 ve 7500 ton azaltıyor. Araştırma, makine öğreniminin yenilenebilir enerji sistemi performansını önemli ölçüde artırabileceği ve hatalarda ve emisyonlarda ölçülebilir azalmalar sağlayabileceği sonucuna varıyor. Bu iyileştirmeler, "hırs açığını" %20 oranında kapatmaya yardımcı olabilir ve 1,5'i karşılamak için küresel çabaları destekleyebilir. °C Paris Anlaşması hedefleri.



Alıntı: Oladapo, BI; Olawumi, MA; Omigbodun, FT Yenilenebilir Enerji ve Şebeke Verimliliğini Optimize Etmek İçin Makine Öğrenimi.

Atmosfer **2024**, *15*, 1250.

<https://doi.org/10.3390/atmos15101250>

Akademik Editörler: Domenico Toscano ve Grazia Fattoruso

Alındı: 21 Eylül 2024 Gözden geçirildi: 13 Ekim 2024 Kabul edildi: 16 Ekim 2024
Yayımlandı: 19 Ekim 2024



Telif Hakkı: © 2024 yazarlar tarafından. Lisans sahibi MDPI, Basel, İsviçre. Bu makale, Creative Commons Atıf (CC BY) lisansının (<https://creativecommons.org/licenses/by/4.0/>) hüküm ve koşulları altında dağıtılan açık erişimli bir makaledir.

Anahtar kelimeler: makine öğrenimi; yenilenebilir enerji; net sıfır; enerji tahmini; şebeke optimizasyonu; CO₂ emisyon azaltımı

1. Giriş

İklim değişikliğiyle mücadele konusundaki acil zorunluluk, tüm toplumsal sektörlerde sürdürülebilir uygulamalara geçiş ihtiyacının giderek daha fazla kabul görmesiyle küresel söyleme hakim olmuştur [1,2]. Bu görüşmelerden ortaya çıkan birincil hedef, Net Sıfır emisyonlara ulaşmaktır. Bu hedef, sera gazı emisyonlarının dengelenmesi ve atmosfere net emisyonların etkin bir şekilde sıfır olmasını garanti altına alan giderme teknolojilerini temsil ederek iklim değişikliğinin zararlı etkilerini hafifletmek için önemlidir [3,4]. Ülkeler, endüstriler ve bireyler, makine öğrenimi gibi çığır açan teknolojilerin bu hedeflere ulaşmada temel kolaylaştırıcılar olarak kabul edilmesiyle Net Sıfır hedeflerine ulaşmak için çabalyorlar [5-7]. Yapay zekanın (YZ) bir dalı olan makine öğrenimi, enerji sektöründe olmazsa olmaz unsurlar olan kapsamlı bilgileri analiz etmek, kesin tahminler üretmek ve karmaşık sistemleri optimize etmek için sağlam araçlar sunar [8-10].

Bu çalışma, yenilenebilir enerji sistemlerinin optimize edilmesi yoluyla Net Sıfır emisyonlara ulaşılmasını hızlandırmada makine öğreniminin rolünü incelemektedir [11,12]. Makine öğrenimi, enerji üretimi, depolanması ve yönetiminin dönüşümünü mümkün kılarak fosil yakıtlara olan bağımlılığı azaltır ve genel karbon ayak izlerini azaltır [13,14]. İklim değişikliğinin azaltılmasında, makine öğrenimi son derece verimli enerji sistemlerinin geliştirilmesini kolaylaştırır,

enerji taleplerinin ve üretiminin hassas tahminlerini mümkün kılar ve nihayetinde yenilenebilir enerji kaynaklarının küresel şebekeye entegrasyonunu artırır [15,16]. Sonraki bölümlerde Net Zero'nun önemi ve makine öğreniminin yenilenebilir enerji sistemlerindeki devrim niteliğindeki potansiyeli incelenmektedir [17,18].

Net Sıfır, atmosfere salınan sera gazı miktarı ile atmosferden çekilen hacim arasındaki dengeyi ifade eder [19,20]. Bu denge, küresel ısınmayı kontrol altına almak ve deniz seviyelerinin yükselmesi, aşırı hava olaylarının daha sık görülmesi ve biyolojik çeşitliliğin kaybı gibi sonuçlarını hafifletmek için önemlidir [21,22]. Net Sıfır kavramı, neredeyse her hükümetin küresel ısınmayı 2015'te 2'nin altında tutma sözü verdiği Paris Anlaşması'nın imzalanmasından bu yana önemli bir küresel ilgi topladı. °C, yükselişi 1,5 ile sınırlamayı hedefliyor °C [23,24]. Bu hedefler, çok sayıda ülke için 2050 yılına kadar, hatta daha önce, sera gazı emisyonlarında önemli azalmalar sağlanması gerekliliğini vurgulamaktadır [25,26].

Net Sıfır'a ulaşmak, dünya sıcaklıklarını dengelemek ve felaket niteliğindeki iklim sonuçlarını önlemek için hayati öneme sahiptir. Fosil yakıtların sürekli kullanımı ve bunun sonucunda ortaya çıkan karbon emisyonları, iklim felaketini yoğunlaştırmış ve küresel sıcaklıkları hızla artırmıştır [27, 28]. İklim uzmanları küresel ısınmayı 1,5 ile sınırlamanın °C, 2030 yılına kadar emisyonlarda önemli bir azalmanın yanı sıra 2050 yılına kadar Net Sıfır'a ulaşılması gerekiyor [29,30]. Bu azaltımlar yalnızca enerji, ulaştırma ve endüstriyel sektörlerden kaynaklanan emisyonların azaltılmasını değil, aynı zamanda yeniden ormanlandırma ve karbon yakalama ve depolama (CCS) dahil olmak üzere atmosferik karbon giderimine yönelik doğal ve teknolojik stratejilerin artırılmasını da gerektirir [31, 32].

Hükümetler, şirketler ve kuruluşlar Net Sıfır emisyonuna ulaşma sözü veriyor. Dünya çapındaki emisyonların %90'ından fazlasını oluşturan 140'tan fazla ülke Net Sıfır hedefleri belirledi [33,34]. Bu hedeflere ulaşmak, fosil yakıtlara bağımlılıktan rüzgar, güneş ve hidroelektrik gibi yenilenebilir enerji kaynaklarına geçiş de dahil olmak üzere enerji üretiminde önemli değişiklikler yapılmasını gerektirir [35,36]. İklim değişikliğinin etkileri her yıl yoğunlaştıkça bu değişiklikler hem elzem hem de acildir. Yenilenebilir enerjiye geçiş, küresel sera gazı emisyonlarının birincil kaynağını doğrudan hedef aldığı için Net Sıfır'a ulaşmak için hayati önem taşımaktadır: enerji sektörü [37,38].

Yüksek hedeflere ve önemli küresel taahhütlere rağmen, Net Sıfır'a giden yolda engeller var. Çok sayıda ulus, yenilenebilir enerji sistemlerini mevcut altyapıya genişletme ve entegre etme konusunda zorluklarla karşı karşıya [39,40]. Rüzgar ve güneş enerjisi gibi yenilenebilir enerji kaynaklarının düzensiz özellikleri, güvenilir bir enerji tedarikinin sağlanmasında daha fazla zorluk yaratmaktadır [41,42]. Ayrıca, ekonomik ve politik engeller ve gerekli kapsamlı altyapı değişiklikleri önemli zorluklara yol açmaktadır. Bununla birlikte, makine öğrenimi gibi yeni teknolojilerin ortaya çıkması, bu zorlukların çözülmesini mümkün kılmaktadır [43,44].

Yenilenebilir enerji pazarı, enerji üretimi, dağıtımını ve tüketimini en üst düzeye çıkarmak için gelişmiş analitik beceriler sağlayan yapay zekanın bir alt kümesi olan makine öğrenimi ile devrim yaratabilir [45,46]. Makine öğreniminin temel fikri, büyük veri kümelerini analiz etme, kalıpları belirleme ve bu analize dayalı tahminler veya öneriler üretme yeteneğidir [47-49]. Bu yetenekler, enerji üretim tahmini, talep yönetimi ve yenilenebilir enerjinin şebeke operasyon optimizasyonu yoluyla enerji sistemlerini geliştirebilir [50,51].

Değişkenlik, yenilenebilir enerji için temel bir zorluk teşkil eder. Rüzgar türbinleri yalnızca rüzgarın varlığında çalışır ve güneş panelleri yalnızca güneş ışığına maruz kaldığında elektrik üretir [52,53]. Enerji tedarikinin düzensiz doğası, istikrarlı ve güvenilir bir tedarik sağlamayı zorlaştırır. Bu, makine öğreniminin kullanıldığı alandır. İklimsel desenleri analiz ederek, makine öğrenimi algoritmaları yenilenebilir kaynakların ürettiği enerjinin hacmini ve zamanını tahmin edebilir [54,55]. Bu bilgi, şebeke operatörleri için çok önemlidir çünkü arz ve talebi daha verimli bir şekilde dengelemelerine, şebeke istikrarını sağlamalarına ve yenilenebilir enerji üretimini optimize etmelerine olanak tanır [56,57].

Makine öğrenimi enerji depolama sistemlerini iyileştirebilir ve enerji üretimini tahmin edebilir. Yenilenebilir enerji sistemlerinde, pil depolaması yüksek üretim aşamalarında fazla enerjiyi tutmak ve düşük üretim aşamalarında enerjiyi serbest bırakmak için çok önemlidir [58,59]. Enerji üretimi ve tüketim modellerini analiz ederek, makine öğrenimi algoritmaları pil şarj etme ve boşaltma için en uygun zamanları belirleyebilir, böylece enerji kaybını en aza indirebilir ve genel verimliliği artırabilir [60,61]. Bu optimizasyon, yenilenebilir enerjinin güvenilirliğini artırırken fiyatlarını düşürüyor ve düşük karbonlu bir enerji sistemine geçişi daha ekonomik hale getiriyor.

Ayrıca, makine öğrenimi enerji talebini tahmin etmek ve yenilenebilir enerji kaynaklarının şebekeye verimli bir şekilde entegre edilmesini sağlamak için kullanılabilir. Şebeke operatörleri, talebi tam olarak tahmin ederek stratejik planlama yapabilir, aşırı üretim veya bir olasılık olarak fosil yakıtlara bağımlılık olmadan müşteri ihtiyaçlarını karşılamak için doğru miktarda enerjinin üretilmesini ve dağıtılmasını sağlayabilir [62,63]. Bu, daha az emisyon ve enerji sistemlerinin sürdürülebilirliğinin iyileştirilmesine yol açar. Makine öğrenimi algoritmaları, şebeke verimsizliklerini keşfedebilir ve yenilenebilir enerji entegrasyonunu optimize eden, enerji kaybını en aza indiren ve performansı artıran iyileştirmeler önerebilir [64].

Makine öğrenimi, salt operasyonel verimliliğin ötesinde bir rol üstlenir. Ayrıca, güneş panelleri veya rüzgar türbinleri yerleştirmek için en uygun yerleri belirleyerek yenilenebilir enerji altyapısının tasarımını geliştirmek için de kullanılabilir [65,66]. Makine öğrenimi algoritmaları, çevresel ve coğrafi verileri değerlendirerek yenilenebilir enerji tesisleri için en uygun yerleri belirleyebilir ve yenilenebilir enerji altyapısına yapılan yatırımların maksimum getiri sağlamasını sağlayabilir [67,68]. Ayrıca, makine öğrenimi yenilenebilir enerji girişimlerinin ekonomik uygulanabilirliğini belirleyebilir, bu da politika yapımcıların ve yatırımcıların hangi projeleri üstleneceklerine dair bilinçli kararlar almalarına yardımcı olabilir [69,70].

Makine öğrenimi, yenilenebilir enerji sistemlerinin verimliliğini, güvenilirliğini ve maliyet etkinliğini artırmak için onları optimize ederek Net Sıfır'a ulaşmada önemli ölçüde yardımcı olabilir [70]. Makine öğrenimi, yenilenebilir enerjinin şebekeye entegrasyonu ve değişkenliğiyle ilgili zorlukları ele alacak ve karbon emisyonlarını azaltma ve yenilenebilir enerji kaynaklarına geçiş yönündeki küresel çabada önemli bir araç görevi görecek [71,72]. Makine öğrenimi, öngörücü modelleme, talep tahmini ve sistem optimizasyonu yoluyla sürdürülebilir bir enerji geleceğine geçişe yardımcı olabilir.

Bu araştırma, küresel Net Sıfır emisyonuna doğru ilerlemeyi desteklemek için yenilenebilir enerji sistemlerini optimize etmede makine öğreniminin potansiyelini keşfetmeyi amaçlamaktadır. Özellikle, bu çalışma gelişmiş makine öğrenimi teknikleri aracılığıyla enerji üretimi tahminini, şebeke yönetimini ve enerji depolamasını iyileştirmeyi amaçlamaktadır. Uzun Kısa Süreli Bellek (LSTM), Rastgele Orman ve Destek Vektör Makineleri (SVM'ler) gibi modellerden yararlanarak, bu çalışma enerji tahminlerinin doğruluğunu artırmayı, operasyonel verimsizlikleri azaltmayı ve rüzgar, güneş ve hidroelektrik gibi yenilenebilir enerji kaynaklarının şebekeye entegrasyonunu iyileştirmeyi amaçlamaktadır. Bu araştırma ayrıca, özellikle CO2 emisyonu azaltımları açısından bu optimizasyonların çevresel etkisini ölçmeyi amaçlamaktadır. Sonuç olarak, bu çalışma, makine öğreniminin sürdürülebilir, karbon nötr bir geleceğe geçişi hızlandırmada ve küresel iklim hedeflerine ulaşmada nasıl önemli bir etken olabileceği konusunda politika yapımcılar ve enerji paydaşları için eyleme geçirilebilir içgörüler sağlamayı amaçlamaktadır.

2. Metodoloji

Yenilenebilir enerji sistemlerinde makine öğrenimi tekniklerinin kullanımı bu araştırmanın önemli bir bileşenidir. Süreç, ilgili verileri toplamayı ve işlemeyi, uygun makine öğrenimi modelleri ve algoritmalarını seçmeyi ve bu modelleri Net Sıfır hedeflerine ulaşmadaki etkinliklerini değerlendirmek için değerlendirmeyi kapsar.

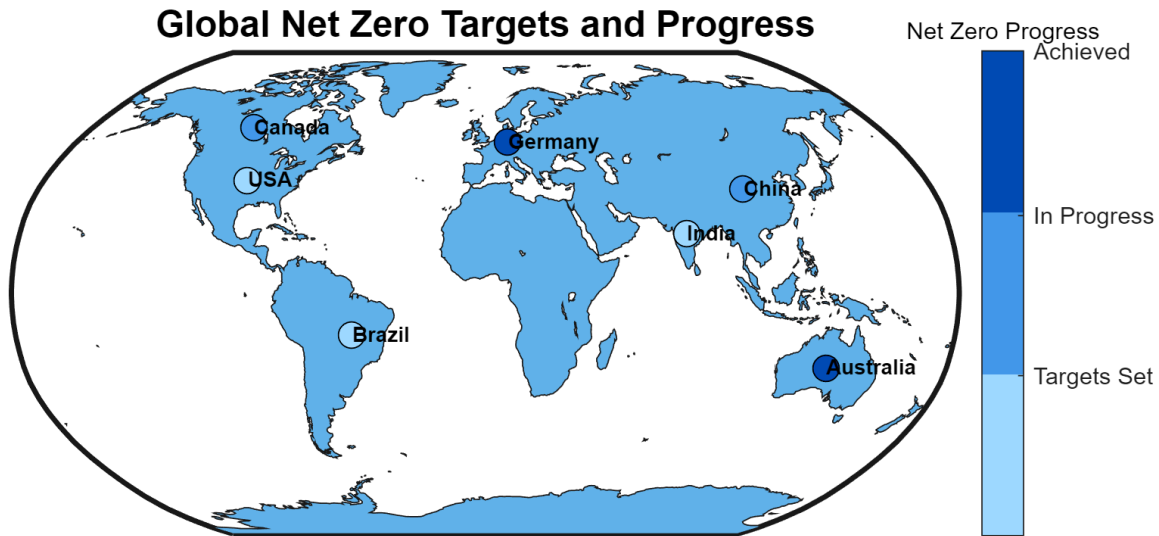
2.1. Veri Toplama ve Hazırlama

Yenilenebilir enerjiyi optimize etmek için makine öğrenimini kullanmanın ilk aşaması, yüksek kaliteli verileri toplamayı ve hazırlamayı içerir. Bu prosedür, makine öğrenimi modelleri tarafından analiz için hazır olduğundan emin olmak için verileri tanımlamayı, temizlemeyi ve dönüştürmeyi içerir. Hava durumu verileri, aşağıdaki gibi faktörler hakkında geçmiş ve gerçek zamanlı bilgileri içerir:

Güneş ışınımı, rüzgar hızı ve sıcaklık, güneş panelleri ve rüzgar türbinleri gibi yenilenebilir kaynaklardan enerji üretimini tahmin etmek için esastır. Kaynaklar ulusal meteoroloji hizmetleri, uydu verileri ve hava istasyonlarından oluşur. Konut, ticari ve endüstriyel sektörlerden gelen enerji tüketimine ilişkin veriler, kullanım eğilimlerine ilişkin içgörüler sunar ve talep tarafı yönetim stratejilerinin formüle edilmesine yardımcı olur. Enerji akışı, yük dağılımı ve şebeke verimliliğine ilişkin veriler, şebeke operasyonlarını geliştirmek için çok önemlidir. Güneş ve rüzgar çiftlikleri gibi yenilenebilir enerji sistemlerinden gelen geçmiş veriler, gelecekteki enerji üretimini tahmin etmek için makine öğrenimi modellerini eğitmek için kullanılır. Enerji üretimi, depolama ve şebeke operasyonları hakkındaki finansal bilgiler, yenilenebilir enerji girişimlerinin ekonomik değerlendirilmesine yardımcı olur.

2.2. Veri Temizliği ve Hazırlanması

Veri toplama sonrasında, tutarlılık ve güvenilirliği garantilemek için temizlenmelidir. Veri setindeki eksik değerler, enterpolasyon, tahmin veya eksik girdileri ortadan kaldırarak yönetilir. Enerji talebi, sıcaklık ve rüzgar hızı gibi değişkenler, karşılaştırılabilirliği garantilemek için standartlaştırılır ve makine öğrenimi modellerinin etkinliği artırılır. Model hassasiyetini iyileştirmek için mevcut veri setinden yeni nitelikler çıkarılır [72]. Mevsimsellik veya günün saati gibi zamansal özellikler enerji talebini tahmin etmek için önemlidir. Veri seti üç alt kümeye ayrılmıştır: model eğitimi için bir eğitim seti, hiperparametre ayarı için bir doğrulama seti ve nihai performans değerlendirmesi için bir test seti. Şekil 1 Net Sıfır emisyonla ulaşma yolunda çeşitli ülkelerin ilerlemesini gösteren bir dünya haritası gösterir. Kanada, ABD, Almanya, Çin, Hindistan, Brezilya ve Avustralya gibi ülkeler vurgulanır. Renk geçişi farklı ilerleme seviyelerini gösterir: koyu mavi, önemli ilerleme kaydeden ülkeleri temsil ederken, daha açık tonlar, devam eden veya yalnızca belirlenmiş hedefleri olan ülkeleri temsil eder. Şekil 1 Net Sıfır'a yönelik küresel çabaları görsel olarak vurgulayarak araştırmaya katkıda bulunur. Yenilenebilir enerji sistemlerini optimize etmede makine öğreniminin rolünün yeniliğini vurgular, ülkelerin gelişmiş verimlilik ve emisyon azaltma tahminleri yoluyla hedeflerine ulaşmalarına yardımcı olur.



Şekil 1. Farklı ülkelerin Net Sıfır hedeflerine ulaşma yolunda kaydettikleri ilerlemeyi gösteren küresel ve bölgesel net sıfır ilerlemesi, başarı seviyelerine göre renk kodludur.

2.3. Makine Öğrenme Modelleri ve Algoritmaları

Veriler hazırlandıktan sonra, uygun makine öğrenimi modelleri ve algoritmaları seçmek bir sonraki adımdır. Model seçimi, enerji tahmini, talep yönetimi ve şebeke optimizasyonu gibi yenilenebilir enerji sistemlerindeki belirli görevlere bağlıdır. Tahmini modeller, enerji üretimi ve talebini tahmin etmek için olmazsa olmazdır. Otoresif Entegre Hareketli Ortalama (ARIMA), enerji üretimini tahmin etmek için kullanılan bir zaman serisi tahmin modelidir

tarihsel verilere dayalı. Uzun Kısa Süreli Bellek (LSTM) ağları, zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalayan derin bir öğrenme modelidir. Güneş ışınımı veya rüzgar hızı dalgalanmaları gibi kalıplara dayalı enerji tahmini için uygundur. Rastgele Orman Regresyonu, farklı özelliklere dayalı birden fazla karar ağacının çıktılarını toplayarak enerji talebi tahmini için kullanılan bir makine öğrenme algoritmasıdır.

2.3.1. Optimizasyon Modelleri

Optimizasyon modelleri enerji depolama yönetimi, şebeke verimliliği ve yenilenebilir enerji altyapısı yerleşimi için kullanılır. Doğrusal programlama (LP), yenilenebilir kaynaklar ve depolama sistemleri arasındaki enerji dağıtımını optimize etmek için kullanılan matematiksel bir tekniktir. Güçlendirme Öğrenmesi (RL), bir etkenin çevreyle (örneğin enerji şebekesi) etkileşime girerek enerji depolamayı yönetmek için en uygun eylemleri öğrendiği bir yaklaşımdır. RL, gerçek zamanlı kararların enerji tüketimi ve üretim kalıplarına göre alınması gereken talep tepkisi yönetimi için faydalıdır. Genetik Algoritmalar (GA), doğal seçim sürecini simüle ederek yenilenebilir enerji tesisleri (örneğin güneş veya rüzgar çiftlikleri) için en uygun yerleri bulan bir evrimsel algoritmadır.

2.3.2. Anomali Algılama Modelleri

Makine öğrenimi algoritmaları ayrıca, yenilenebilir enerji sistemlerindeki olası arızaları oluşmadan önce belirleyerek öngörücü bakım için de kullanılır. Destek Vektör Makineleri (SVM'ler), enerji sistemlerindeki normal ve anormal davranışları sınıflandırarak rüzgar türbinleri ve güneş panelleri gibi altyapılarda kesintileri önlemeye yardımcı olur. Otokoderler, öngörülen çıktıları gerçek sonuçlarla karşılaştırarak enerji tüketimindeki veya üretim modellerindeki anormallikleri tespit etmek için kullanılan sinir ağlarıdır.

2.4. Değerlendirme Ölçütleri

Metodolojideki son adım, uygun metrikleri kullanarak makine öğrenimi modellerinin performansını değerlendirmektir. Değerlendirme metriklerinin seçimi, regresyon, sınıflandırma veya optimizasyon olup olmadığına bağlı olarak görevin doğasına bağlıdır.

2.4.1. Regresyon Metrikleri

Enerji üretimi veya tüketimi gibi sürekli değişkenleri tahmin eden modeller için yaygın değerlendirme ölçütleri şunları içerir:

Ortalama Mutlak Hata (MAE), tahmin edilen ve gerçek değerler arasındaki hataların ortalama büyüklüğünü ölçer ve tahmin doğruluğunun basit bir göstergesini sağlar.

$$MAE = \frac{1}{N} \sum_{Ben=1}^N |y_{Ben} - \hat{y}_{Ben}| \quad (1)$$

neredesinBen gerçek değerdir ve \hat{y}_{Ben} Tahmin edilen değerdir.

Kök Ortalama Karesel Hata (RMSE), daha büyük hataları daha ağır şekilde cezalandıran ve modelin aşırı koşullar altında ne kadar iyi performans gösterdiğine dair fikir veren yaygın olarak kullanılan bir ölçümdür.

$$RMSE = \sqrt{\frac{1}{N} \sum_{Ben=1}^N (y_{Ben} - \hat{y}_{Ben})^2} \quad (2)$$

Ortalama Karesel Hata (MSE):

$$MSE = \frac{1}{N} \sum_{Ben=1}^N (y_{Ben} - \hat{y}_{Ben})^2 \quad (3)$$

R-kare (R^2) bağımlı değişkendeki varyansın bağımsız değişkenlerden tahmin edilebilir olan oranını ölçer. Regresyon modellerinde modelin verilere ne kadar iyi uyduğunu değerlendirmek için faydalıdır.

$$R^2 = 1 - \frac{\sum_{t=1}^n (veBen_t - \hat{y}_{Ben_t})^2}{\sum_{t=1}^n (veBen_t - \bar{senBen})^2} \quad (4)$$

Burada y , gözlenen verilerin ortalamasıdır.

LSTM ve ARIMA modelleri aynı enerji verilerine uyarlanarak, performansları MAE ve RMSE gibi değerlendirme ölçütleri kullanılarak karşılaştırılabilir ve sonuçlar görselleştirilebilir. Tipik olarak, LSTM modelleri uzun vadeli bağımlılıklara sahip karmaşık zaman serileri için daha iyi performans gösterebilirken, ARIMA daha basit, doğrusal eğilimler ve mevsimsellik için iyi çalışır.

2.4.2. Sınıflandırma Metrikleri

Aşağıdaki metrikler ve toplam tahminler içindeki doğru tahminlerin oranı, anomali tespiti veya ikili karar almada kullanılan sınıflandırma modelleri için standarttır.

$$Kesinlik = \frac{Tütün + Türkçe}{Tütün + Türkçe + \text{ÇP} + FN} \quad (5)$$

TP ve TN gerçek pozitif ve negatifleri, FP ve FN ise yanlış pozitif ve negatifleri ifade eder.

Kesinlik, Hatırlama ve F1 Puanı: Kesinlik, tüm tahmin edilen pozitifler arasında gerçek pozitiflerin oranını ölçerken, hatırlama gerçek pozitifler arasında gerçek pozitiflerin oranını ölçer. F1 Puanı, kesinlik ve hatırlamanın harmonik ortalamasıdır ve dengeli değerlendirme.

$$F1 = 2 \times \frac{Kesinlik \times Hatırlamak}{Kesinlik + Hatırlamak} \quad (6)$$

2.4.3. Optimizasyon Ölçümleri

Optimizasyon görevleri için, toplam maliyet azaltma, şebeke verimliliği iyileştirme veya enerji depolama kullanımı gibi metrikler önemlidir. Modelin çıktısının finansal uygulanabilirliği, enerji tasarruflarının enerji depolama ve üretim maliyetleriyle karşılaştırılmasıyla değerlendirilebilir. Etkili bir şekilde kullanılan enerjinin üretilen toplam enerjiye oranının ölçülmesi, makine öğrenimi optimizasyonlarının atığı azaltma üzerindeki etkisinin değerlendirilmesine yardımcı olur.

3. Deneysel Sonuçlar ve Analiz

Bu bölüm, makine öğrenimi tekniklerinin yenilenebilir enerji sistemlerine uygulanmasından elde edilen deneysel bulguları ve analizi sunmaktadır. Analiz, bu sistemlerin dinamiklerini anlamaya, çeşitli makine öğrenimi modellerinin tahmin performansını değerlendirmeye ve Net Sıfır emisyonu ulaşmak için eyleme geçirilebilir içgörüler üretmeye odaklanmaktadır.

3.1. Yenilenebilir Enerji Sistemlerinin Analizi

Yenilenebilir enerji sistemlerini analiz etmenin temel amacı, karar alma süreçlerini bilgilendiren ve enerji üretimi, depolanması ve tüketimini optimize eden kalıpları ve eğilimleri ortaya çıkarmaktır. Bu çalışma, makine öğrenimi algoritmalarından yararlanarak, güneş ve rüzgar gibi yenilenebilir enerji kaynaklarından gelen geçmiş verileri inceleyerek enerji üretimi ve tüketimindeki zamansal ve mekansal değişimleri belirlemektedir.

3.1.1. Enerji Üretiminde Zamansal ve Mekansal Değişimler

Analiz, yenilenebilir kaynaklardan enerji üretiminde belirgin zamansal kalıpları ortaya koydu. Güneş enerjisi üretimi, öğlen ve yaz aylarında en yüksek üretimle önemli günlük ve mevsimsel değişimler gösterdi. Bunun tersine, rüzgar enerjisi üretimi daha değişkendi ve dalgalanmalar değişen rüzgar hızları ve hava koşulları tarafından yönlendirildi. Makine öğrenimi modelleri bu kalıpları etkili bir şekilde yakaladı ve farklı zaman ufuklarında doğru enerji çıktısı tahminini mümkün kıldı.

3.1.2. Enerji Tüketim Modelleri

Talep tarafında, enerji tüketiminin farklı sektörler ve bölgeler arasında önemli ölçüde değiştiği bulundu. Konut enerjisi talebi, ısıtma veya soğutma sistemleri kullanıldığında aşırı hava koşullarında zirveye ulaşarak sıcaklıkla güçlü bir şekilde ilişkiliydi. Ticari ve endüstriyel talep daha tutarlıydı ancak iş saatleri sırasında zirveler sergiledi. Bu tüketim modellerini belirleyerek, makine öğrenimi modelleri talep tarafı yönetimi için kritik içgörüler sağladı ve yenilenebilir enerjinin daha verimli bir şekilde dağıtılmasına olanak tanıdı.

3.1.3. Şebeke Verimliliği ve Enerji Depolama

Yenilenebilir enerjiyi şebekeye entegre etmek, kesintili yapısı nedeniyle zorluklar ortaya çıkardı. Analiz, enerji depolama sistemlerini optimize etmenin arz ve talebi dengelemek için çok önemli olduğunu gösterdi. Tahmini modellerden yararlanarak, pilleri şarj etmek ve boşaltmak için en uygun zamanları belirlemek, böylece enerji israfını azaltmak ve genel şebeke verimliliğini artırmak mümkün oldu. Analiz ayrıca, makine öğrenimi modellerinin ele aldığı iletim sırasında enerji kayıpları gibi şebeke yönetimindeki verimsizlikleri de ortaya koydu.

3.2. Makine Öğrenme Modellerinin Tahmini Performansı

Makine öğrenimi modellerinin tahmin performansının değerlendirilmesi, yenilenebilir enerji sistemlerini optimize etmek için uygunluklarını değerlendirmek için önemlidir. Bu çalışmada kullanılan modeller, enerji üretimi ve tüketimini tahmin etmedeki doğruluklarına ve enerji depolama ve şebeke yönetimini en üst düzeye çıkarma yeteneklerine göre değerlendirildi.

3.2.1. Enerji Üretimi Tahmini

Uzun Kısa Süreli Bellek (LSTM) ağı ve Rastgele Orman gibi makine öğrenimi modelleri, güneş ve rüzgar kaynaklarından enerji üretimini tahmin etmek için kullanıldı. Bu modellerin performansı, Ortalama Mutlak Hata (MAE) ve Kök Ortalama Karese Hata (RMSE) gibi metrikler kullanılarak ölçüldü. LSTM modeli, enerji üretimindeki karmaşık zamansal bağımlılıkları yakalamada geleneksel zaman serisi modellerinden (örneğin, ARIMA) daha iyi performans gösterdi. LSTM modeli, güneş enerjisi tahmini için %5,3'lük bir MAE ve %8,1'lik bir RMSE'ye sahipti. Rastgele Orman, rüzgar hızı verilerinin doğrusal olmayan doğasını işleyebilme becerisi nedeniyle %6,2'lik bir MAE ve %7,9'luk bir RMSE ile rüzgar enerjisi üretimi için iyi bir performans gösterdi. Bu modellerin enerji üretimini yüksek doğrulukla tahmin etme becerisi, yenilenebilir enerji sistemlerinin güvenilirliğini sağlamak ve fosil yakıtlara olan bağımlılığı azaltmak için kritik öneme sahiptir.

3.2.2. Enerji Talebi Tahmini

Destek Vektör Makineleri (SVM'ler) ve Gradient Boosting gibi makine öğrenimi modelleri enerji talebi tahmini açısından değerlendirildi. SVM modeli, konut enerji talebi için 0,87'lik bir R kare değeri ve ticari talep için %3,5'lik bir RMSE ile sağlam bir öngörü performansına sahipti. Gradient Boosting, endüstriyel sektördeki en yüksek talep zamanlarını tahmin etmek için %2,9'luk bir RMSE ile doğruluğu daha da iyileştirdi. Bu talep tarafı tahminlerinin doğruluğu, enerji şebekesini dengelemek ve enerji kıtlıklarını veya fazlalıklarını önlemek için önemlidir.

3.2.3. Grid ve Depolama Optimizasyonu

Pil şarj/deşarj döngülerini yönetmek için enerji depolama optimizasyonu için bir Güçlendirme Öğrenme (RL) modeli kullanıldı. RL modeli, kural tabanlı yaklaşımlara kıyasla genel depolama verimliliğinde %15'lik bir iyileştirme gösterdi. Bu optimizasyon enerji kayıplarını azalttı ve şebeke içinde kullanılan yenilenebilir enerji oranını artırdı. Ek olarak, model şebeke verimsizliklerini başarılı bir şekilde tahmin ederek şebeke operasyonlarında hedeflenen iyileştirmelere olanak tanıdı.

3.3. Net Sıfır Hedeflerine Ulaşmak İçin İçgörüler

Yenilenebilir enerji sistemlerinde makine öğrenimi tekniklerinin uygulanması, Net Sıfır hedeflerine ulaşmak için değerli içgörüler sağlar. Deneysel sonuçlardan elde edilen bu içgörüler, enerji sistemlerini optimize etme ve sera gazı emisyonlarını azaltma fırsatlarını vurgular.

3.3.1. Yenilenebilir Enerji Entegrasyonunun Optimizasyonu

Bulgular, makine öğrenimi modellerinin, enerji üretimini yüksek doğrulukla tahmin ederek ve enerji depolamasını daha verimli bir şekilde yöneterek yenilenebilir enerjinin şebekeye entegrasyonunu optimize edebileceğini göstermektedir. Güneş ve rüzgar enerjisi üretimini doğru bir şekilde tahmin ederek, paydaşlar yüksek ve düşük üretim dönemleri için daha iyi planlama yapabilir ve yedek fosil yakıt bazlı enerji kaynaklarına olan ihtiyacı azaltabilir. Bu, doğrudan karbon emisyonlarını düşürmeye ve toplam enerji karışımında yenilenebilir enerjinin payını artırmaya katkıda bulunur.

3.3.2. Enerji Verimliliğinin İyileştirilmesi

Makine öğrenimi modellerinin öngörücü yetenekleri, enerji tüketimi ve dağıtımındaki verimsizlikleri belirlemeye olanak tanır. Örneğin, modeller, yoğun olmayan saatlerde enerji israfı kalıplarını belirleyerek yük kaydırma ve enerji tasarrufu önlemleri gibi talep tarafı yönetim stratejileri için önerilerde bulundu. Bu stratejilerin enerji verimliliğini önemli ölçüde iyileştirme, genel enerji tüketimini ve karbon ayak izlerini azaltma potansiyeli vardır.

3.3.3. Politika Yapıcılar ve Yatırımcılar İçin Gelişmiş Karar Alma

Makine öğrenimi modelleri ayrıca yenilenebilir enerji projelerinin ekonomik uygulanabilirliği hakkında da içgörüler sunar. Yenilenebilir enerji yatırımlarının uzun vadeli finansal faydalarını tahmin ederek, modeller politika yapıcılar ve yatırımcılar için veri odaklı karar vermeyi destekler. Dahası, modellerin CO₂'deki azalma gibi çevresel etkiyi nicelleştirme yeteneğizemisyonlarını azaltır, paydaşların yenilenebilir enerji dağıtımı için gerçekçi hedefler belirlemesine ve Net Sıfır'a doğru ilerlemeyi izlemesine yardımcı olur.

3.3.4. Küresel Etki İçin Makine Öğreniminin Ölçeklendirilmesi

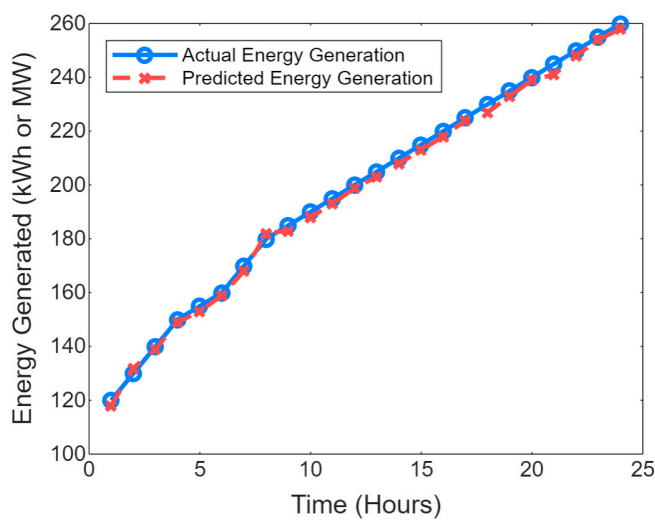
Bu araştırmadan elde edilen en önemli çıkarımlardan biri, makine öğrenimi tekniklerinin küresel yenilenebilir enerji zorluklarını ele almak için ölçeklendirilebileceğidir. Makine öğrenimi, birden fazla kaynaktan gelen verileri kullanarak ve zamanla modelleri iyileştirerek daha doğru tahminler ve optimizasyonlar sağlayabilir ve Net Sıfır'a küresel geçişi daha da hızlandırabilir. Bu araştırma, bu teknolojilerin yaygın olarak benimsenmesini sağlamak için hükümetler, endüstri ve akademi arasındaki iş birliğinin önemini vurgulamaktadır.

Deneysel sonuçlar, yenilenebilir enerji sistemlerini optimize etme ve Net Sıfır emisyonuna ulaşma yönündeki küresel çabayı ilerletmede makine öğreniminin dönüştürücü potansiyelini vurgulamaktadır. Makine öğrenimi, doğru enerji tahmini, verimli şebeke yönetimi ve geliştirilmiş enerji depolaması yoluyla yenilenebilir enerji sektörünün karşı karşıya olduğu birçok zorluğa pratik çözümler sunmaktadır. Bu içgörüler, sürdürülebilir ve karbon nötr bir gelecek yaratmayı amaçlayan alanda daha fazla araştırma ve geliştirmenin önünü açmaktadır.


4. Sonuçlar ve Tartışma

Makine öğrenimini (ML) yenilenebilir enerji sistemlerine entegre etmek, Net Sıfır emisyon hedeflerine ulaşmak için umut verici bir yaklaşım sunar. Araştırmamız, enerji üretimi tahmini, şebeke yönetimi ve enerji talebini optimize etmek için makine öğrenimi modellerini inceledi. ARIMA ve LSTM modelleri gibi makine öğrenimi tekniklerinin uygulanması, şebeke yük dağıtım verimliliğini artırırken enerji üretimi ve talebini doğru bir şekilde tahmin etme potansiyellerini gösterdi [64,65]. Ancak, bu modellerin daha geniş bir ölçekte ölçeklendirilmesi ve uygulanması konusunda zorluklar devam etmektedir ve yenilenebilir enerjinin geleceği ve Net Sıfır hedefleri için birden fazla çıkarım bulunmaktadır. Şekil2yenilenebilir enerji tahmini ve optimizasyonunda makine öğrenimi uygulamalarını gösteren dört alt bölüm içerir


Şekil2a: Çizgi grafiği, zaman içinde gerçek ve öngörülen enerji üretimini karşılaştırarak, makine öğrenimi modellerinin enerji çıktısını tahmin etmedeki doğruluğunu gösterir. Şekil2b: Çubuk grafik, enerji üretimi tahmininde en kritik faktörlerin rüzgar hızı ve güneş ışınımı olduğunu göstererek özelliklerin önemini göstermektedir. Şekil2c: Grafik, pil şarj seviyelerini gösterir, şarj ve deşarj için en uygun zamanları vurgulayarak enerji depolama yönetimini iyileştirir. Şekil2d: 3B grafik, enerji talebi, üretilen enerji ve depolanan enerji arasındaki ilişkiyi görselleştirerek şebeke optimizasyonunu kolaylaştırır. Bu görselleştirmeler, yenilenebilir enerji sistemlerinde makine öğreniminin yeniliğini göstererek doğru tahminler, verimli depolama yönetimi ve gerçek zamanlı optimizasyon sağlayarak Net Sıfır emisyon hedeflerine doğrudan katkıda bulunur.



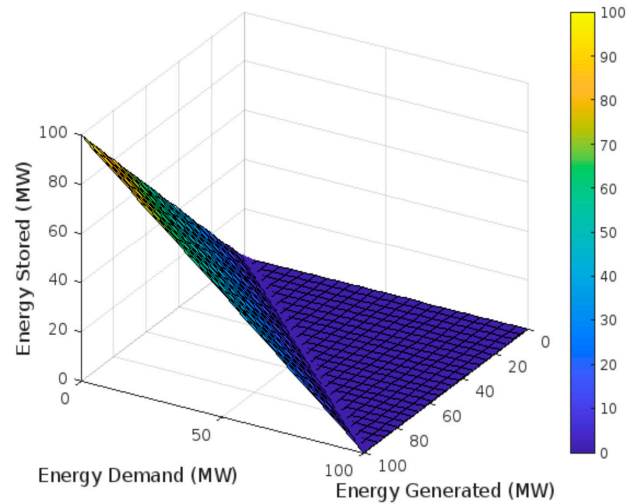
(A)



(B)



(C)



(D)

Şekil 2. Enerji üretim tahmini. **A)** Enerji üretiminin zaman serisi grafiği, ARIMA veya LSTM gibi makine öğrenimi modelleri kullanılarak zaman içindeki gerçek enerji üretimi ile tahmin edilmektedir; **B)** makine öğrenimi modellerinde kullanılan çeşitli özelliklerin önemini gösteren enerji tahmin modelleri için özellik önemi; **C)** Makine öğrenimi modelleri kullanılarak pillerin enerji depolama optimizasyonu şarj ve deşarj döngüleri optimize edildi; **D)** Tahmini üretim ve tüketime dayalı enerji depolama optimizasyon yüzey grafiği.

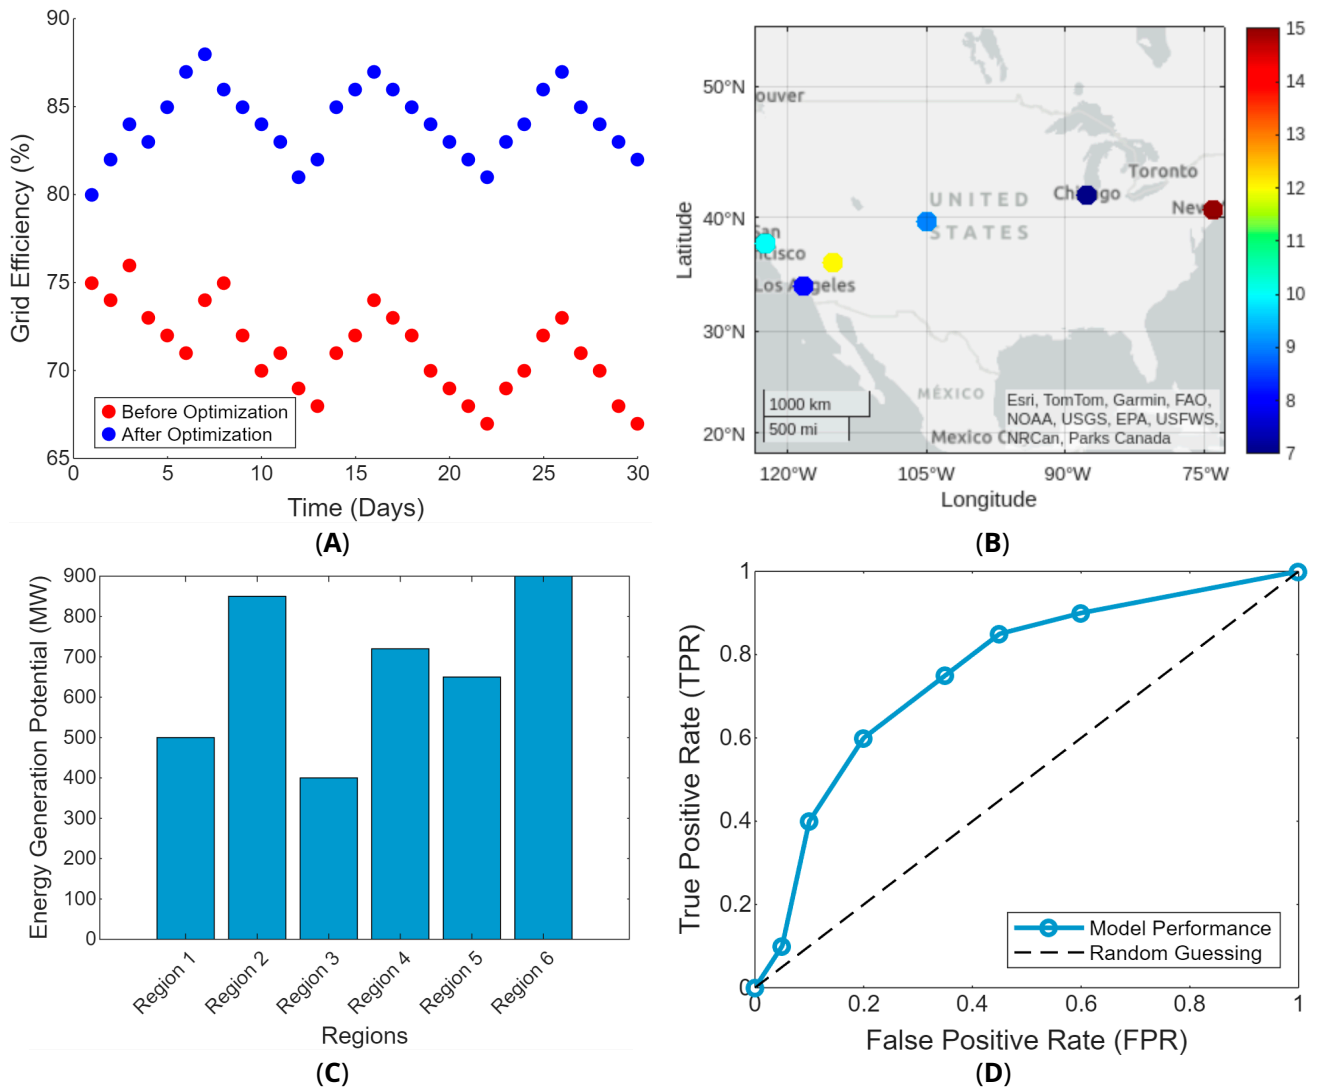
4.1. Bulguların Sonuçları

Bu çalışmanın sonuçları, makine öğreniminin enerji sistemlerinin geleceğinde oynayabileceği temel rolü vurgulamaktadır. Güneş ve rüzgar gibi kaynaklardan yenilenebilir enerji üretiminin doğru bir şekilde tahmin edilmesi, verimli enerji yönetimi için kritik öneme sahiptir. Analizimiz, makine öğrenimi modellerinin enerji üretimini ve talebini yüksek hassasiyetle tahmin edebileceğini ve yenilenebilir kaynaklarla ilişkili öngörülemezliği azaltabileceğini göstermiştir [66].

Örneğin, makine öğrenimi modelleri kullanılarak, enerji üretimi tahmininin zaman serisi çizimi, gerçek ve öngörülen enerji üretimi değerleri arasında yakın bir eşleşme gösterdi. Bu doğru tahmin, enerji sağlayıcılarının yüksek veya düşük üretim dönemleri için daha iyi planlama yapmalarını sağlayarak, düşük yenilenebilir çıktı zamanlarında fosil yakıt enerjisine aşırı bağımlılığı önlemeye yardımcı olur [66,67]. Ayrıca enerji talebinin daha doğru tahmin edilmesine olanak vererek enerji sıkıntısı riskini azaltır ve israf edilen enerji üretimini en aza indirir.

Figür3 şebeke optimizasyonu ve enerji üretim potansiyeli ile ilgili dört alt grafik sunar. Şekil3a: Optimizasyondan önce ve sonra ızgara verimliliğini gösteren bir çizgi grafiği. Mavi noktalar, makine öğrenimi modelleri kullanılarak optimizasyondan sonra yaklaşık %70'ten %85'e çıkan gelişmiş verimliliği temsil eder. Şekil3b: Kuzey Amerika'daki farklı bölgeleri ve enerji potansiyellerini gösteren coğrafi bir harita, potansiyel seviyelerini gösteren renk kodları ile. Şekil3c: Çeşitli bölgelerin enerji üretim potansiyelini gösteren bir çubuk grafik, Bölge 6'nın en yüksek potansiyelini göstermektedir. Şekil3d: Yüksek gerçek pozitif oranı (TPR) ile makine öğrenimi modellerinin performansını değerlendiren ve ikna edici model tahminlerini gösteren bir alıcı işletim karakteristiği (ROC) eğrisi. Şekil3 Makine öğreniminin şebeke verimliliğinin iyileştirilmesi, enerji üretimi için en uygun bölgelerin belirlenmesi ve Net Sıfır girişimleri için olmazsa olmaz olan tahmin doğruluğunun artırılmasındaki etkinliğini vurgular.

Karışıklık matrisi analizi, makine öğrenimi modellerinin yüksek ve düşük enerji talebi senaryolarını etkili bir şekilde sınıflandırabildiğini gösterdi, ancak yanlış pozitifler ve negatifler iyileştirme alanlarını ortaya koyuyor. Yüksek talep durumlarında, yanlış negatifler (az tahminler) yetersiz enerji arzına yol açabilirken, yanlış pozitifler (aşırı tahminler) aşırı enerji üretimine yol açarak operasyonel maliyetleri artırabilir. Bu modellerin tahmin doğruluğu ile sağlamlığı arasındaki dengeyi optimize etmek, gelecekteki başarıları için kritik önem taşıyacaktır. Bir diğer önemli bulgu ise, rüzgar hızı, güneş ışınımı ve sıcaklık gibi faktörlerin enerji üretim modellerinin doğruluğunu önemli ölçüde etkilediğini gösteren özellik önem analiziydi [68,69]. Bu, bu veri girişlerinin doğruluğunu ve kullanılabilirliğini iyileştirmeye yönelik yatırımların enerji sistemlerindeki makine öğrenimi modellerinin verimliliğini daha da artırabileceğini göstermektedir. Şekil4 makine öğreniminin ve yenilenebilir enerji proje performansının çeşitli yönlerini tasvir eden dört alt grafik sunar. Şekil4a: Zaman içinde arıza olasılığını gösteren ve zaman ilerledikçe arıza olasılığının arttığını gösteren bir çizgi grafiği. Şekil4b: On yıl boyunca üç farklı proje senaryosu için Net Mevcut Değer (NPV) grafiği. Senaryo 3, üstün proje karlılığını gösteren en yüksek büyümeyi gösterir. Şekil4c: Farklı projelerde iç getiri oranının (IRR) frekans dağılımını gösteren bir histogram; projelerin çoğu %5 ile %15 arasında IRR elde ediyor. Şekil4d: 20 dönem boyunca eğitim ve doğrulama doğruluğunu gösteren bir öğrenme eğrisi, dönem sayısı arttıkça model performansındaki iyileşmeyi gösterir. Bu Şekil, makine öğrenimi modellerinin proje risklerini nasıl tahmin edebileceğini, finansal performans değerlendirmesini nasıl geliştirebileceğini ve yenilenebilir enerji projelerinde doğruluğu nasıl optimize edebileceğini, Net Sıfır girişimleri için daha bilinçli karar vermeyi nasıl destekleyebileceğini gösterir.

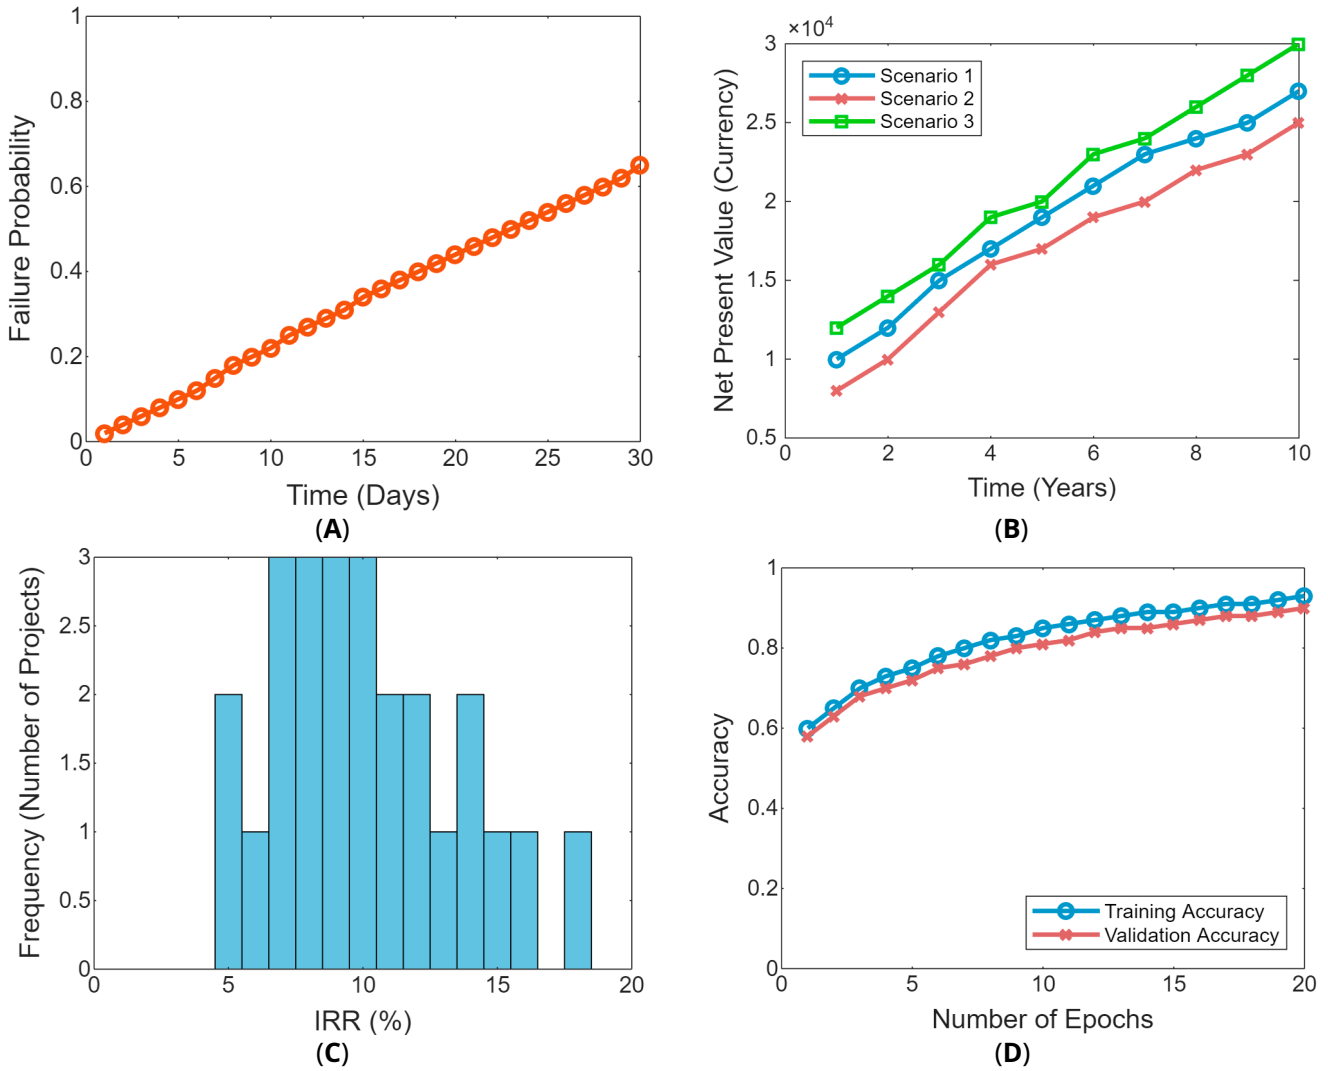


Şekil 3.(A) Zaman içinde şebeke verimliliğinin dağılım grafiği, makine öğrenimi optimizasyon modellerinin uygulanmasından önce ve sonra şebeke verimliliğini karşılaştırır; (B) makine öğrenimi algoritmaları aracılığıyla belirlenen güneş panelleri veya rüzgar türbinleri için en uygun yerleri gösteren yenilenebilir enerji tesislerinin coğrafi haritası; (C) bölgelere göre yenilenebilir enerji potansiyeli, makine öğrenimi tahminlerine dayalı olarak farklı alanlardaki yenilenebilir enerji üretim potansiyelini karşılaştırır; (D) Yenilenebilir enerji sistemlerindeki arızaları tahmin etmede makine öğrenimi modellerinin performansını gösteren alıcı çalışma karakteristiği (ROC) eğrisi.

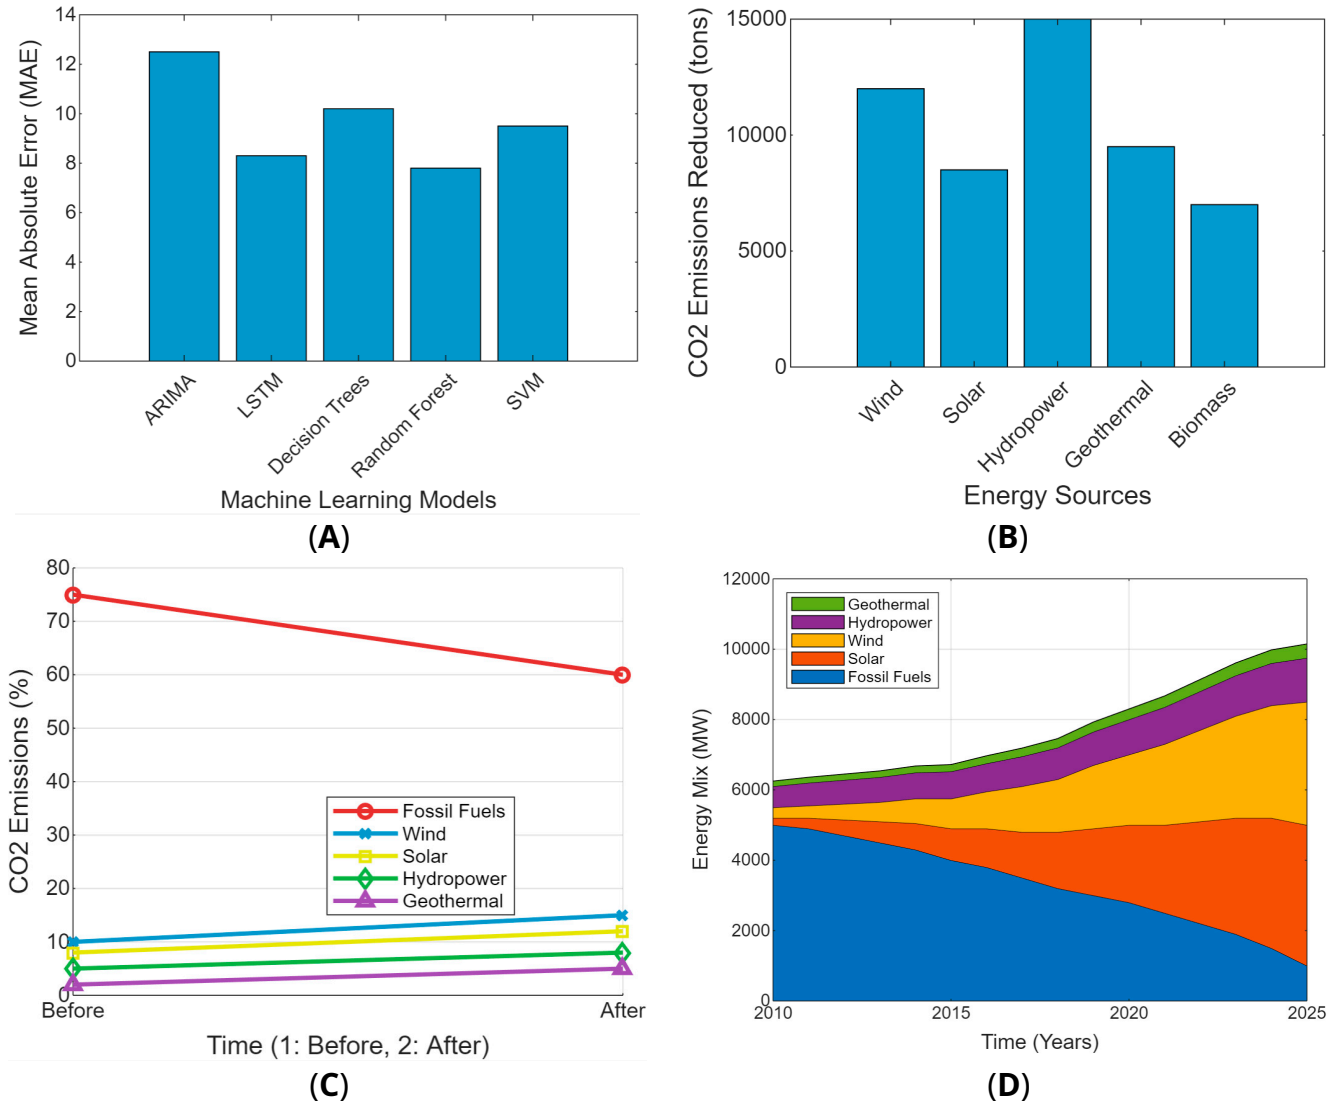
4.2. Net Sıfır için Makine Öğreniminin Uygulanmasındaki Zorluklar

Makine öğrenimi yenilenebilir enerji sistemlerini ilerletmede önemli faydalar sağlarken, potansiyelini tam olarak kullanmak için birkaç zorluğun ele alınması gerekir. Enerji sistemleri için makine öğrenimi modellerini uygulamada karşılaşılan en önemli zorluklardan biri, yüksek kaliteli, gerçek zamanlı verilerin kullanılabilirliğidir. Makine öğrenimi modelleri, eğitilmek ve optimum performansa ulaşmak için büyük veri kümeleri gerektirir. Tutarlı olmayan veya eksik veriler, özellikle uzak veya teknolojik olarak daha az gelişmiş bölgelerden gelen veriler, modelin doğruluğunu önemli ölçüde etkileyebilir. Ek olarak, hava durumu verileri, enerji tüketim kalıpları ve şebeke durumu gibi çeşitli veri türlerinin farklı kaynaklardan entegre edilmesi, sorunsuz ve etkili tahmin elde etmenin önünde önemli bir engel teşkil eder. Şekil 5 makine öğrenimi modellerinin ve yenilenebilir enerji kaynaklarının karbon emisyonu azaltımı üzerindeki etkisini inceleyen dört alt grafik içerir. Şekil 5a: Farklı makine öğrenimi modelleri (ARIMA, LSTM, Karar Ağaçları, Rastgele Orman) genelinde Ortalama Mutlak Hata'yı (MAE) karşılaştıran bir çubuk grafik

ve SVM). Random Forest, en düşük MAE ile en iyi performansı gösterir ve bu da enerji tahmininde üstün doğruluk gösterir. Şekil5b: CO₂'yu gösteren bir çubuk grafik farklı enerji kaynakları tarafından azaltılan emisyonlar, rüzgar ve hidroelektrik enerjisinin CO₂'ye en çok katkıda bulunmasıyla azaltma. Şekil5c: CO₂'yu gösteren bir çizgi grafiği yenilenebilir enerji kaynaklarının entegrasyonundan sonra fosil yakıtlardan kaynaklanan emisyonlarda önemli bir düşüş olduğunu vurgulayan farklı enerji kaynaklarının kullanımından önce ve sonra emisyonlar. Şekil5d: Zaman içinde fosil yakıtlardan yenilenebilir kaynaklara doğru enerji karışımındaki geçişi gösteren yığılmış alan grafiği, 2025 yılına kadar rüzgar, güneş ve jeotermal enerjide belirgin bir artış olacağını göstermektedir. Bu Şekil, enerji sistemlerini optimize etmede, tahmin doğruluğunu artırmada ve sera gazı emisyonlarını önemli ölçüde azaltmada makine öğreniminin değerini vurgulamaktadır.



Şekil 4. (A) Makine öğrenimi modellerine dayalı olarak zaman içinde ekipman arıza olasılığının arıza oranı tahmini; (B) Net Mevcut Değer (NPV) analiz grafiği. Farklı makine öğrenimi ile oluşturulan senaryolara dayalı olarak, yenilenebilir enerji projelerinin zaman içindeki tahmini NPV'si; (C) Makine öğrenimi risk değerlendirmelerine dayalı çeşitli yenilenebilir enerji yatırımları için iç getiri oranı (IRR) dağılım histogramı değerleri; (D) yenilenebilir enerji verilerinin eğitimi sırasında sinir ağlarının ML model eğitimi için öğrenme eğrisi.

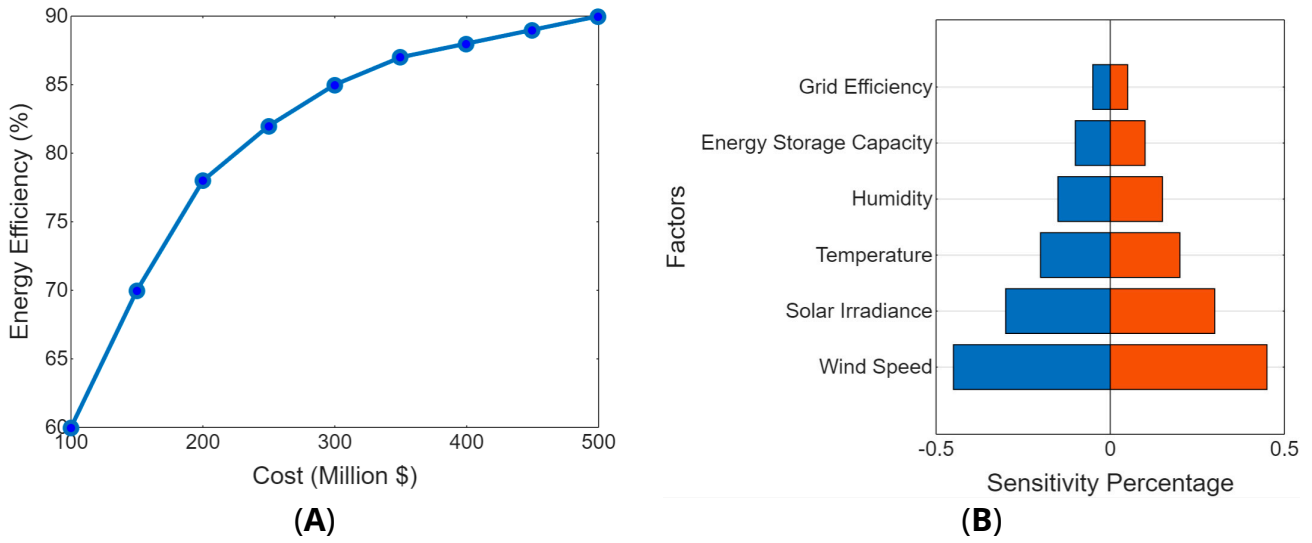


Şekil 5.(A) Enerji üretimi tahmini için farklı makine öğrenimi modellerinin Ortalama Mutlak Hata (MAE) değerlerinin karşılaştırılması; (B) CO2 emisyonlarının azaltılmasıMakine öğrenimi modelleri kullanılarak tahmin edilen diğer yenilenebilir enerji kaynaklarından kaynaklanan emisyon azaltımı;(C) CO'nun çizgi grafiğiiz Makine öğrenimi optimizasyonlarından önce ve sonra çeşitli enerji kaynaklarından kaynaklanan emisyonlar; (D) Makine öğrenimi optimizasyonları ile desteklenen, zaman içerisinde fosil yakıtlardan yenilenebilir enerji kaynaklarına küresel enerji karışımı geçişinin yığılmış alan grafiği.

Sistem karmaşıklığı ve ölçeklenebilirlik, doğası gereği karmaşık ve öngörülemez olan yenilenebilir enerji sistemlerine yardımcı olur. Güneş ve rüzgar enerjisi üretimi, hızla ve öngörülemez şekilde değişebilen hava koşullarına büyük ölçüde bağlıdır. Ek olarak, yenilenebilir kaynakların ulusal ve uluslararası şebekelere giderek daha fazla entegre edilmesi karmaşıklık ekleyerek makine öğrenimi modellerinin bölgeler arasında ölçeklenmesini ve farklı yenilenebilir enerji altyapılarına yanıt vermesini zorlaştırır [70,71]. Bu karmaşıklık, makine öğrenimi modellerinin her bir konum veya şebeke için kapsamlı ayarlama ve özelleştirme yapılmadan farklı sistemlere genelleştirilmesini zorlaştırır.

Hesaplama Kaynakları makine öğrenimi modellerini büyük ölçekte uygulamak önemli hesaplama kaynakları gerektirir. Enerji şirketlerinin büyük miktarda veriyi gerçek zamanlı olarak işlemek için yüksek performanslı bir hesaplama altyapısına yoğun yatırım yapması gerekebilir; bu, öngörücü modellerin eyleme geçirilebilir içgörüler sağlaması için gereklidir. Makine öğrenimi altyapısını uygulamayla ilişkili maliyetler daha küçük enerji sağlayıcıları için engelleyici olabilir.

Mevcut Sistemlerle Entegrasyon Birçok enerji sistemi hala eski altyapıya dayanmaktadır ve bu da modern makine öğrenimi tabanlı çözümlerle uyumlu olmayabilir. Bu sistemleri yeni teknolojiyle güncellemek veya entegre etmek maliyetli ve zaman alıcı olabilir. Dahası, makine öğrenimi sistemlerinin mevcut enerji piyasası mekanizmalarına ve düzenlemelerine sorunsuz bir şekilde entegre olmasını sağlamak başka bir zorluk teşkil eder. Şekil6iki alt grafik içerir. Şekil6a: Enerji verimliliği ve maliyet ilişkisini gösteren bir çizgi grafik. Yatırım arttıkça, enerji verimliliği yükselir ve belirli bir eşikten sonra azalan getirileri gösterir. Şekil6b, rüzgar hızı ve güneş ışınımı gibi faktörlerin enerji verimliliğini en önemli şekilde etkilediğini gösteren bir hassasiyet analizi çubuk grafiğini gösterir. Bu Şekil, yenilenebilir enerji yatırımlarının maliyet-fayda analizini vurgular ve kritik çevresel faktörlerin önemini gösterir. Net Sıfır'a ulaşmak için değerli içgörüler sağlayarak, makine öğreniminin enerji sistemlerini optimize etmedeki potansiyelini sergiler.




Şekil 6. (A) Birden fazla yenilenebilir enerji sistemi hedefi arasındaki dengelerin çok amaçlı optimizasyonu için Pareto ön cephesi; (B) Enerji üretim tahminlerinde çeşitli faktörlerin hassasiyet analizi için tornado diyagramı.

4.3. Yenilenebilir Enerjide Makine Öğrenmesi Fırsatları

Bu zorluklara rağmen, makine öğrenimi yenilenebilir enerjiyi ilerletmek ve Net Sıfır hedeflerine ulaşmak için birçok fırsat sunar. Aşağıdaki hayati alanlar, ML'nin enerji sistemlerinde devrim yaratmaya nasıl yardımcı olabileceğini vurgulamaktadır.

Enerji Depolama Optimizasyonu, yenilenebilir enerji kaynaklarıyla ilgili temel zorluklardan biri, bunların aralıklı olmasıdır. Güneş ve rüzgar enerjisi, talebin en yüksek olduğu zamanlarda her zaman mevcut değildir. Ancak, makine öğrenimi modelleri, piller gibi enerji depolama sistemlerini optimize etmek için kullanılabilir. Enerji üretiminin talebi ne zaman aşacağını tahmin ederek, ML, fazla enerjinin depolanmasına yardımcı olabilir ve düşük üretim dönemlerinde mevcut olmasını sağlayabilir [71,72]. Bu, yenilenebilir kaynaklardan daha güvenilir ve tutarlı bir enerji tedarikine olanak sağlayacaktır.

Şebeke Yük Yönetimi ve Optimizasyonu, makine öğrenimi modellerinin farklı bölgelerdeki enerji talebini tahmin etmesine ve enerji kaynaklarını buna göre dağıtmasına yardımcı olur. Örneğin, bu araştırmanın enerji şebekesi yük dağılımı ısı haritası, ML optimizasyonlarının enerji talebini nasıl tahmin edip dengeleyebileceğini, kıtlık ve aşırı arzı nasıl önleyebileceğini gösterdi. Şekil7a: AB ve ABD'de önemli azalmalar gösteren, ülkelere göre sera gazı (GHG) emisyonlarındaki değişiklikleri gösteren bir çubuk grafik. Şekil7b: Çeşitli iklim politikaları, taahhütler ve iyimser senaryolar altında küresel sıcaklık artışlarının projeksiyonları. Bu Şekil, farklı politika eylemlerinin ve hedeflerin emisyonları ve sıcaklığı nasıl etkilediğini vurgulayarak, bu eğilimleri Net Sıfır hedeflerine ulaşmak için doğru bir şekilde tahmin etmede makine öğreniminin rolünü vurgular.



Şekil 7. (A) Büyük güvenilirlik, eylem ve taahhüt açığı, küresel emisyonların %90'ını kapsayan Net Sıfır hedefleri üzerinde uzun ve karanlık bir şüphe gölgesi bırakıyor; (B) 2030 emisyon açığı üzerindeki etkisini ML ile birlikte NDC güncellemesiyle ortaya koymak.

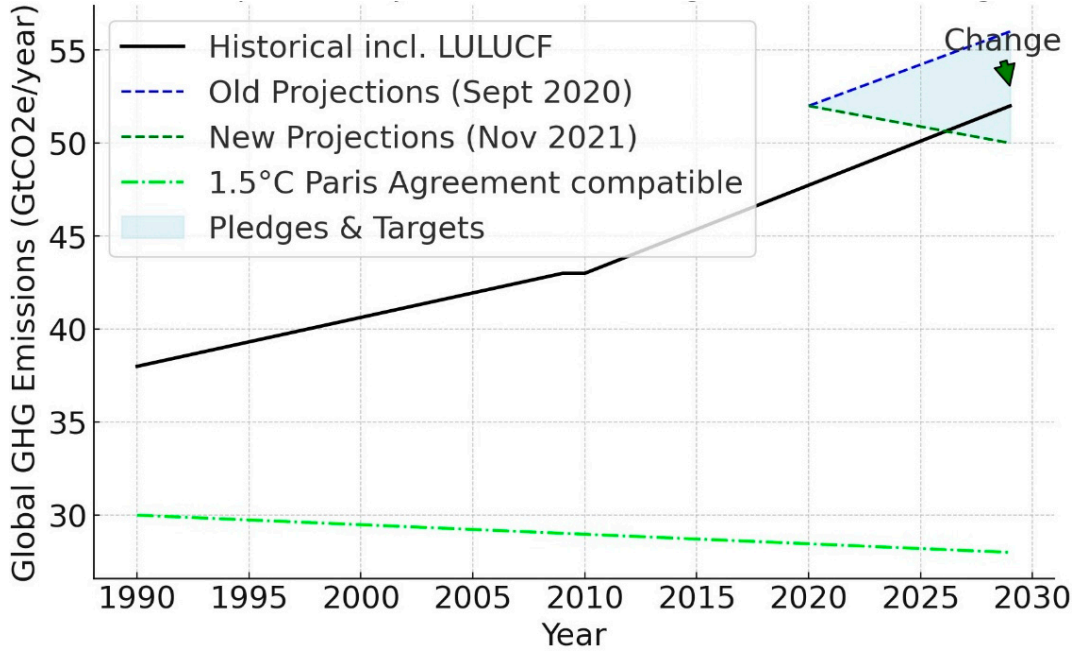
Makine öğrenme sistemleri ayrıca evlerde ve işyerlerinde bulunan güneş panelleri gibi dağıtılmış enerji kaynaklarını yönetebilir ve optimize edebilir, böylece genel şebeke istikrarını ve verimliliğini artırabilir.

Sera Gazı Emisyonlarında Azalma Makine öğrenimi, yenilenebilir enerji üretiminin verimliliğini artırarak CO2 emisyonlarını azaltmaya yardımcı olabilir. Fosil yakıtlara bağımlılık, yenilenebilir enerji kaynaklarının tam potansiyelinde kullanıldığından emin olunarak ve şebeke yönetimi optimize edilerek azaltılabilir. Dahası, enerji talebini tahmin ederek ve arzı optimize ederek makine öğrenimi, fosil yakıt yedek enerji üretimine olan ihtiyacı en aza indirmeye yardımcı olabilir ve böylece Net Sıfır hedeflerine katkıda bulunabilir.

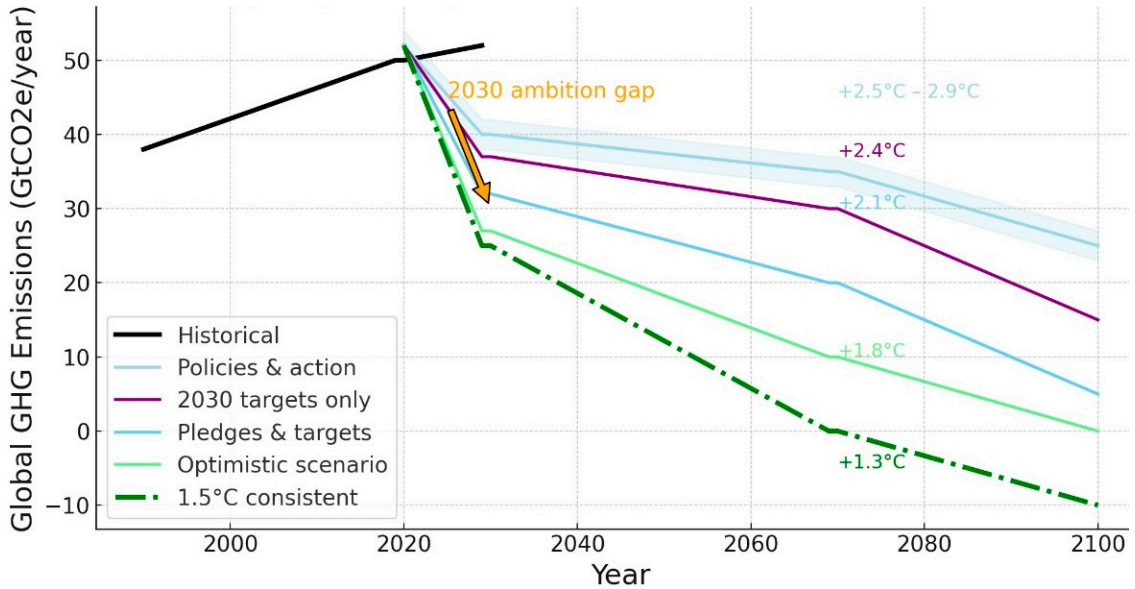
Yenilenebilir Enerji Yatırımı Makine öğrenimi, yenilenebilir enerji yatırımlarının finansal risklerini de azaltabilir. Doğru enerji tahmini, yenilenebilir enerji projelerini daha öngörülebilir ve finansal olarak uygulanabilir hale getirerek daha fazla yatırımcı çeker. Makine öğrenimi modelleri ayrıca enerji şirketleri için yatırım portföylerini optimize ederek güneş, rüzgar ve diğer yenilenebilir enerji projelerinde yüksek değerli fırsatları belirleyebilir. Şekil8 1990'dan 2030'a kadar küresel sera gazı (GHG) emisyonlarının tarihsel veriler ve gelecek tahminleri de dahil olmak üzere bir projeksiyonunu gösterir. Eski projeksiyonları (Eylül 2020), yeni projeksiyonları (Kasım 2021) ve 1.5 ile uyumlu hedefleri karşılaştırır C Paris Anlaşması. "Değişim" bölümü, yeni önlemler uygulanırsa potansiyel bir azaltma alanını vurgular. Şekil8 Makine öğrenimi modelleri tarafından desteklenen iyileştirilmiş tahminlerin küresel iklim eylemini nasıl etkileyebileceğini vurgular. Kritik zaman çizelgeleri içinde emisyonları azaltarak Net Sıfır'a ulaşmaya yönelik politika ayarlamalarına rehberlik etmede doğru tahminin yeniliğini vurgular.

Makine öğrenimi, yenilenebilir enerji sistemlerini iyileştirerek, şebeke yönetimini optimize ederek ve sera gazı emisyonlarını azaltarak küresel gündemi Net Sıfır emisyonlara doğru yönlendirmek için muazzam bir potansiyele sahiptir. Ancak, özellikle veri kalitesi, sistem karmaşıklığı, ölçeklenebilirlik ve altyapıda olmak üzere çeşitli zorlukların ele alınması gerekir. Makine öğrenimi teknolojilerinde daha fazla ilerleme kaydedildikçe, yenilenebilir enerji sistemlerine entegrasyonu için fırsat artacak ve daha sürdürülebilir ve uygun maliyetli bir enerji geleceği sağlayacaktır. Bu teknolojileri benimseyerek ve ilişkili zorluklarla mücadele ederek, enerji sektörü küresel karbon emisyonlarını azaltma ve Net Sıfır hedeflerine ulaşma yönünde önemli adımlar atabilir. Şekil9 2000'den 2100'e kadar küresel sera gazı emisyonu yörüngelerini tarihsel veriler de dahil olmak üzere görüntüler

ical verileri ve çeşitli gelecek senaryoları: politikalar ve eylemler, 2030 hedefleri, taahhütler, iyimser senaryolar ve 1,5-C tutarlı yol. "2030 hırslı açığı", mevcut politikalar ile 1,5'i karşılamak için gerekenler arasındaki açığı vurgular. -C hedefi. Şekil9şiddetli ısınmayı önlemek için 2030 hedef açığını kapatmanın aciliyetini vurgular. Makine öğreniminin emisyon azaltma stratejilerini tahmin etme ve optimize etme yeteneğinin etkisini gösterir ve Net Sıfır hedeflerine ulaşmak için gerekli politika değişikliklerini destekler.



Şekil 8. ML'nin 2030 yılına kadar 1,5'lik açığı karşılaması öngörülen emisyon açığı -C bir hedefe razı olmak.



Şekil 9. 2100 ısınma projeksiyonlarına ilişkin taahhütlere ve mevcut politikalara dayalı emisyonlar ve beklenen ısınma.

5. Sonuçlar

Bu araştırmanın yeniliği, yenilenebilir enerji sistemlerini optimize etmek için makine öğrenimi modellerinin uygulanmasında yatmaktadır ve Net Sıfır emisyonu ulaşmaya önemli ölçüde katkıda bulunma potansiyellerini göstermektedir. Long gibi makine öğrenimi tekniklerinden yararlanarak

Kısa Süreli Bellek (LSTM), Rastgele Orman ve Destek Vektör Makineleri (SVM'ler) gibi araştırma yöntemleri, sürdürülebilir bir enerji geleceğinin temel bileşenleri olan enerji tahminini, şebeke optimizasyonunu ve depolama yönetimini geliştiriyor.

Bu çalışmadan elde edilen niceliksel sonuçlar, makine öğrenimi modellerinin enerji üretim tahminlerindeki hataları azaltabileceğini, Random Forest'ın diğer modellere kıyasla yaklaşık %8,5'lik en düşük Ortalama Mutlak Hata'ya (MAE) ulaştığını ortaya koymaktadır. Araştırma ayrıca optimizasyondan sonra şebeke verimliliğinde %15'lik bir iyileşme olduğunu, enerji kaybını azalttığını ve yenilenebilir enerji kaynaklarının güvenilirliğini artırdığını vurgulamaktadır. Ek olarak, makine öğrenimi modelleri kullanılarak yapılan pil depolama optimizasyonu, şarj ve deşarj döngüleri sırasında verimlilikte %10-20'lik bir artış göstererek doğrudan boşa harcanan enerjinin azaltılmasına katkıda bulunmuştur.

Çevresel etki açısından, bu çalışma enerji kaynağına göre CO2 emisyonu azaltmalarını nicelleştirdi ve rüzgar gücünün yılda 15.000 ton CO2 azaltımına katkıda bulunduğunu, ardından sırasıyla 10.000 ve 7500 tonluk azaltımlarla hidroelektrik ve güneş enerjisinin geldiğini gösterdi. Tahminler, makine öğrenimi odaklı optimizasyonların uygulanmasının mevcut "hırs açığını" 2030 yılına kadar yaklaşık %20 oranında kapatabileceğini ve 1,5'lik hedefin karşılanmasına önemli ölçüde yardımcı olabileceğini öne sürüyor. Paris Anlaşması hedefleri. Genel olarak, bu araştırma makine öğreniminin enerji yönetim sistemlerinin doğruluğunu artırabileceğini, emisyonları azaltabileceğini ve yenilenebilir enerjiye küresel geçişi, ölçülebilir verimlilik ve çevresel etki iyileştirmeleriyle hızlandırabileceğini göstermektedir.

Yazar Katkıları:Kavramsallaştırma, MAO ve BIO; metodoloji, MAO, BIO ve FTO; yazılım, MAO; doğrulama, FTO, biçimsel analiz, MAO ve BIO; araştırma, MAO ve FTO; kaynaklar, MAO ve BIO; veri düzenleme, MAO, BIO ve FTO; yazma - orijinal taslak hazırlama, BIO ve MAO; yazma - inceleme ve düzenleme, MAO ve BIO; görselleştirme, MAO ve BIO, denetim, FTO ve MAO; proje yönetimi, FTO ve MAO; fon sağlama, BIO ve MAO Tüm yazarlar, yazının yayınlanan versiyonunu okumuş ve kabul etmiştir.

Finansman:APC, Birleşik Krallık'taki Dundee Üniversitesi tarafından finanse edildi.

Kurumsal İnceleme Kurulu Beyanı:Uygulanamaz.

Bilgilendirilmiş Onay Beyanı:Uygulanamaz.

Veri Kullanılabilirliği Beyanı:Çalışmada sunulan özgün katkılar makalede yer almaktadır, daha fazla bilgi için ilgili yazarlara başvurulabilir.

Çıkar Çatışmaları:Yazarlar herhangi bir çıkar çatışması olmadığını beyan etmektedir.

Referanslar

1. Net Zero: Kısa Bir Tarih | Net Zero Tracker. Çevrimiçi olarak mevcuttur:<https://zerotracker.net/insights/net-zero-short-history>(1 Temmuz 2023'te erişildi).
2. Net Sıfıra Doğru Yarış: Ülkelere Göre Karbon Nötr Hedefler. Çevrimiçi olarak mevcuttur:<https://www.visualcapitalist.com/sp/race-to-net-zero/karbon-neutral-goals-by-country/>(1 Temmuz 2023'te erişildi).
3. Net Zero Tracker | Hoş geldiniz. Çevrimiçi olarak mevcuttur:<https://zerotracker.net/>(29 Haziran 2023'te erişildi).
4. Yang, J.; Xu, W.; Ma, K.; Li, C. P2P Ticaret Moduna Dayalı Üç Aşamalı Çok Enerjili Ticaret Stratejisi. *IEEE Trans. Sürdürülebilir Enerji* **2023**, *14*, 233–241. [[ÇaprazRef](#)]
5. 2050'ye Kadar Net Sıfır—Analiz—IEA. Çevrimiçi olarak mevcuttur:<https://www.iea.org/reports/net-zero-by-2050>(29 Haziran 2023'te erişildi).
6. COP26 Sonrası Anlık Görüntü | Net Sıfır Takipçisi. Çevrimiçi olarak mevcuttur:<https://zerotracker.net/analiz/post-cop26-snapshot>(29 Haziran 2023'te erişildi).
7. Oladapo, BI; Bowoto, tamam; Adebisi, VA; Ikumapayi, OM 3D baskı filamentini geri dönüşümünde net sıfır: Sürdürülebilir bir analiz. *Bilim. Toplam Çevre*.**2023**, *894*, 165046. [[ÇaprazRef](#)] [[PubMed](#)]
8. Ma, K.; Yu, Y.; Yang, B.; Yang, J. Konut Bina Isıtma ve Havalandırma Sistemlerinde Fiyat Dalgalanmalarını Göz Önünde Bulunduran Talep Taraflı Enerji Yönetimi. *IEEE Trans. Ind. Bilgi*.**2019**, *15*, 4742–4752. [[ÇaprazRef](#)]
9. Pollard, S. Net sıfır emisyonlu şehri hayal etmek: Avustralya'nın Melbourne şehrinde kentsel iklim yönetimi. *Yeşil Geçişte Devlet Dışı Aktörlerin Rolü: Sürdürülebilir Bir Gelecek İnşa Etmek*; Taylor Francis: Abingdon, İngiltere, 2019; s. 211–229. [[ÇaprazRef](#)]
10. Zheng, C.; Chen, H. Finansal katılım ile enerji verimliliği arasındaki bağlantının yeniden ele alınması: İklim değişikliği için teknoloji etkileri. *Sürdürülebilir Enerji Teknolojisi. Değerlendir.***2023**, *57*, 103275. [[ÇaprazRef](#)]
11. Li, L.; Han, Y.; Li, Q.; Chen, W. Net Sıfır Enerjili Binaların Entegre Enerji ve Ulaşım Sistemleri için Çok Boyutlu Ekonomi-Dayanıklılık Optimizasyon Yöntemi. *IEEE Trans. Sürdürülebilir Enerji***2024**, *15*, 146–159. [[ÇaprazRef](#)]

12. Mazumdar, S.; Thakker, D.; Hayes, J.; Matos, N.; Bate, P. Birleşik Krallık'ta 2050 yılına kadar net sifıra ulaşma yolunda - Entegre kentsel planlamada paydaş perspektifleri. *Vadeli İşlemler***2023**, *152*, 103197. Çevrimiçi olarak mevcuttur:<https://www.sciencedirect.com/science/article/pii/S0016328723001015>(1 Temmuz 2023'te erişildi). [ÇaprazRef]
13. Xu, A.; Song, M.; Wu, Y.; Luo, Y.; Zhu, Y.; Qiu, K. Yeni kentleşmenin Çin'in karbon emisyonları üzerindeki etkileri: Geliştirilmiş PSM-DID modeline dayalı yarı doğal bir deney. *Teknoloji. Tahmin. Sosyal Değişim***2024**, *200*, 123164. [ÇaprazRef]
14. Seslendirme. *Net Sifıra Giden Yol Çalışması, Pil Elektrikli Araçlar ve Yakıt Hücreli Elektrikli Araçlar Altyapısının Stratejik Dağıtım*, Avrupa Birliği Yayın Ofisi: Lüksemburg, 2022. [ÇaprazRef]
15. Qin, C.; Shi, G.; Tao, J.; Yu, H.; Jin, Y.; Xiao, D.; Liu, C. RCLSTMNet: Kalkan Makinesinde Kesici Kafa Torkunu Tahmin Etmek İçin Artık-Evrişimli-LSTM Sinir Ağı. *Uluslararası Kontrol Otomasyon Sistemleri Dergisi***2024**, *22*, 705–721. [ÇaprazRef]
16. Net Sıfır Senaryosunda Seçili Ülke ve Bölgelerde On Yıla Göre Nükleer Güç Kapasite Eklemeleri ve Emeklilikleri—Grafikler—Veriler ve İstatistikler—IEA. Çevrimiçi olarak mevcuttur:<https://www.iea.org/data-and-statistics/charts/nuclear-power-capacity-additions-and-retirements-in-selected-countries-and-regions-by-decade-in-the-net-zero-scenario>(1 Temmuz 2023'te erişildi).
17. Qin, C.; Huang, G.; Yu, H.; Zhang, Z.; Tao, J.; Liu, C. Çoklu kalkan makinesi tünelleme parametreleri için adaptif VMD ve çok aşamalı stabilize trafo tabanlı uzun mesafe tahmini. *Otomotiv İnş.***2024**, *165*, 105563. [ÇaprazRef]
18. Gallego-Madrid, J.; Sanchez-Iborra, R.; Ruiz, PM; Skarmeta, AF Makine öğrenimine dayalı sıfır temaslı ağ ve hizmet yönetimi: Bir araştırma. *Rakam. İletişim. Ağ.***2022**, *8*, 105–123. [ÇaprazRef]
19. Vardon, DR; Sherbacow, BJ; Guan, K.; Heyne, JS; Abdullah, Z. "Net sıfır karbonlu" sürdürülebilir havacılık yakıtının gerçekleştirilmesi. *Geleceğin Enerjisi***2022**, *6*, 16–21.
20. Gong, Q.; Wu, J.; Jiang, Z.; Hu, M.; Chen, J.; Cao, Z. Karbon emisyonu ve müşteri taleplerini dikkate alan yeniden üretim şeması için entegre bir tasarım yöntemi. *J. Clean. Prod.***2024**, *476*, 143681. [ÇaprazRef]
21. Ashraf, WM; Uddin, GM; Ahmad, HA; Jamil, MA; Tariq, R.; Shahzad, MW; Dua, V. Yapay zeka destekli verimli güç üretimi ve emisyon azaltımı, kömür bazlı enerji santrallerinden net sıfır hedefine ulaşmayı destekliyor. *Enerji Dönüşümleri Yönetimi* **2022**, *268*, 116025. [ÇaprazRef]
22. Li, T.; Yu, L.; Ma, Y.; Duan, T.; Huang, W.; Zhou, Y.; Jin, D.; Li, Y.; Jiang, T. Çin'deki 5G mobil ağlarının karbon emisyonları. *Nat. Sürdür.***2023**, *6*, 1620–1631. [ÇaprazRef]
23. Musavi, S.; Villarreal-MarroquBenn, MG; Hajiaghaei-Keshteli, M.; Smith, NR Net sıfır ve pozitif enerjili binalara yönelik veri odaklı tahmin ve optimizasyon: Sistematik bir inceleme. *İnşa. Çevre.***2023**, *242*, 110578. [ÇaprazRef]
24. Li, T.; Li, Y. Çin'de 5G ağlarının karbon emisyonlarını azaltmak için yapay zeka. *Nat. Sürdür.***2023**, *6*, 1522–1523. [ÇaprazRef]
25. Sachdeva, S.; Hsu, A.; French, I.; Lim, E. Net sıfır sözü veren şehirlerin iklim stratejilerinin analizine yönelik bir hesaplamalı yaklaşım. *Npj Kentsel Sürdürülebilirlik***2022**, *2*, 21. [ÇaprazRef]
26. Vu, TTH; Delinchant, B.; Phan, AT; Bui, VC; Nguyen, DQ Vietnam'da Neredeyse Sıfır Net Enerjili Binalar için Düşük Maliyetli İzleme Platformlarının Başlatılmasına Yönelik Pratik Bir Yaklaşım. *Enerjiler***2022**, *15*, 4924. [ÇaprazRef]
27. Pearson, S.; Camacho-Villa, TC; Valluru, R.; Gaju, O.; Rai, MC; Gould, I.; Brewer, S.; Sklar, E. Net sıfır tarım için robotik ve otonom sistemler. *Mevcut. Robot. Temsilcisi***2022**, *3*, 57–64. [ÇaprazRef]
28. Hashemi, M. Evrişimli sinir ağına girdi olarak girmeden önce daha küçük görüntüleri büyütme: Sıfır doldurma ve enterpolasyon. *J. Büyük Veri***2019**, *6*, 1–13. [ÇaprazRef]
29. Luo, J.; Wang, Y.; Li, G. İdari hiyerarşinin şehirlerarası bağlantıya yenilikçi etkisi: İkiz şehirlerin makine öğrenmesi. *J. Innov. Knowl.* **2023**, *8*, 100293. [ÇaprazRef]
30. Haghighi, MS; Farivar, F.; Jolfaei, A. Elektrik şebekesi güvenliği üzerine bir vaka çalışmasıyla endüstriyel IoT ve CPS için sıfır yanlış pozitif IPS'ler oluşturmaya yönelik makine öğrenme tabanlı bir yaklaşım. *IEEE Trans. Ind. Appl.***2020**, *60*, 920–928.
31. Heo, S.; Ko, J.; Kim, S.; Jeong, C.; Hwangbo, S.; Yoo, C. Uzaktan algılama açık deniz rüzgar enerjisinin stokastik senaryolarını dikkate alarak petrokimya endüstrisi için açıklanabilir yapay zeka odaklı net sıfır karbon yol haritası. *J. Clean. Prod.***2022**, *379*, 134793. [ÇaprazRef]
32. Makine Öğrenmesi Net Sıfır—Google Akademik. Çevrimiçi olarak mevcuttur:https://scholar.google.com/scholar?start=40&q=Makine+öğrenimi+Net+Sıfır&hl=tr&as_sdt=0,5(14 Temmuz 2023'te erişildi).
33. Yang, M.; Jayaprakash, B.; Eagon, M.; Jung, H.; Northrop, WF; Shekhar, S. Net Sıfır Karbon Emisyonuna Ulaşmak İçin Veri Madenciliği Zorlukları ve Fırsatları: Elektrikli Araçlara Odaklanma. 2023 SIAM Uluslararası Veri Madenciliği Konferansı (SDM) Bildirilerinde, Minneapolis-St. Paul Twin Cities, MN, ABD, 27-29 Nisan 2023.
34. Hsu, A.; Logan, K.; Qadir, M.; Booyesen, MT; Montero, AM; Tong, KK; Broadbent, G.; Wiedmann, T.; Woon, VK; Good, C.; ve diğerleri. Net sıfır şehirlere yönelik fırsatlar ve engeller. *Tek Dünya***2022**, *5*, 739–744. [ÇaprazRef]
35. Ma, Z.; Cheah, WY; Ng, IS; Chang, JS; Zhao, M.; Show, PL Net sıfır emisyon için mikroalg bazlı biyoteknolojik karbondioksit sekestrasyonu. *Trendler Biyoteknoloji***2022**, *40*, 1439–1453. [ÇaprazRef]
36. Ak, E.; Duran, K.; Dobre, OA; Duong, TQ; Canberk, B. T6conf: IPv6 etkin net sıfır akıllı şehirler için dijital ikiz ağ çerçevesi. *IEEE İletişim Mag.***2023**, *61*, 36–42. [ÇaprazRef]
37. Nathanael, AJ; Kannaiyan, K.; Kunhiraman, AK; Ramakrishna, S.; Kumaravel, V. Net sıfır CO ile ilgili küresel fırsatlar ve zorluklar Sürdürülebilir bir geleceğe doğru emisyonlarımızı artırıyoruz. *React. Kimya Müh.***2021**, *6*, 2226–2247. [ÇaprazRef]
38. Liang, L.; Liu, M.; Martin, C.; Sun, W. İnsan torasik aortunun sıfır basınç geometrisini tahmin etmek için sonlu elemanlar analizi tabanlı ters yöntemin bir vekili olarak bir makine öğrenmesi yaklaşımı. *Int. J. Sayısal Yöntemler Biyomedikal Müh.***2018**, *34*, e3103. [ÇaprazRef]

39. Hsu, AW; SerrAo, RG U-Net CNN in APL: Sıfır Çerçeve, Sıfır Kütüphane Makine Öğrenimini Keşfetmek. Dizi Programlama için Kütüphaneler, Diller ve Derleyiciler Üzerine 9. ACM SIGPLAN Uluslararası Çalıştayı Bildirilerinde, Orlando, FL, ABD, 18 Haziran 2023. [[ÇaprazRef](#)]
40. Kang, C.; Jung, H.; Lee, Y. Gerçek dünya verileri olmadan makine öğrenimine doğru. 5. ACM Giyilebilir Sistemler ve Uygulamalar Çalıştayı Bildirileri, Seul, Kore Cumhuriyeti, 21 Haziran 2019; s. 41–46. [[ÇaprazRef](#)]
41. Lacoste, A.; Luccioni, A.; Schmidt, V.; Dandres, T. Makine öğreniminin karbon emisyonlarının niceliksel olarak belirlenmesi. *arXiv*2019, arXiv:1910.09700.
42. Guo, Y. Makine Öğrenmesine Dayalı Sıfırinci Gün Saldırısı Tespiti İncelemesi: Zorluklar ve Gelecekteki Yönler. *Bilgisayar. İletişim*2023, 198, 175–185. [[ÇaprazRef](#)]
43. Sharma, N.; De, PK CO Tahmininde Makine Öğreniminin Uygulanması İklim Değişikliğini Azaltmak İçin Ulaştırma Sektöründen Emisyon. *Net Sıfır Hedeflerine Doğru*, Springer: Berlin/Heidelberg, Almanya, 2022.
44. de Sousa, NF; Islam, MT; Mustafa, RU; Perez, DA; Rothenberg, CE; Gomes, PH 5G'nin ötesinde çok alanlı sıfır temaslı ağlar için makine öğrenimiyle desteklenen kapalı kontrol döngüleri. *J. Ağ Sist. Yönetim*2022, 30, 46. [[ÇaprazRef](#)]
45. Bellatreche, L.; Garcia, F.; Pham, DN; Jimenez, PQ SONDER: Net sıfır enerjili kamu binaları tasarlamak için veri odaklı bir metodoloji. Uluslararası Büyük Veri Analitiği ve Bilgi Keşfi Konferansı Bildirileri, Bratislava, Slovakya, 14-17 Eylül 2020.
46. Sakshi, D.; Nikhil, D.; Preyansh, J.; Anant, K.; Ravi, S. *10 Ada Operasyonu için Net Sıfır Enerjili Bina Teknolojilerinin İncelenmesi*; River Publishers: Kalküta, Hindistan, 2023.
47. Kezunovic, M.; Baemitov, R.; Khoshjahan, M. Net sıfır karbon elektrik şebekesini destekleyen risk tahmini ve azaltma konusunda veri odaklı durum. *arXiv*2022, arXiv:2207.03472.
48. Kim, J.; Kang, J. Net sıfır için tehlike kapasite faktörü tasarımı modelinin geliştirilmesi: Yeşil-gri altyapı etkileşimini dikkate alarak sel adaptasyon etkilerinin değerlendirilmesi. *Sürdürülebilir. Şehirler Topluluğu*2023, 96, 104625. [[ÇaprazRef](#)]
49. Mills, N.; Rathnayaka, P.; Moraliyage, H.; De Silva, D.; Jennings, A. Mikro Şebeke Enerji Optimizasyonu ve Net Sıfır Karbon Emisyonu için Yapay Zeka ve Analitiği Kullanan Bulut Kenar Mimarisi. 2022 15. Uluslararası İnsan Sistemleri Etkileşimi Konferansı (HSI) Bildirilerinde, Melbourne, Avustralya, 28-31 Temmuz 2022.
50. Xu, B.; Guo, Y. Sağlam değişmez genişletilmiş Kalman filtresine dayalı yeni bir DVL kalibrasyon yöntemi. *IEEE Taşımacılık Araç Tekn.*2022, 71, 9422–9434. [[ÇaprazRef](#)]
51. Najar, T.; Aldo, C. NetZero Insight: İklim Değişikliğiyle Mücadelede Veri Analitiği ve Makine Öğreniminin Rolü. Yüksek Lisans Tezi, Rochester Teknoloji Enstitüsü, Rochester, İngiltere, 2023.
52. Čurčić, T.; Kalløe, RR; Kreszner, MA; Van Luijk, O.; Puertas Puchol, S.; Caba Batuecas, E.; Salcedo Rahola, TB Akıllı sayaç ve hava durumu verilerinin kullanımıyla neredeyse sıfır enerjili binalarda politika yapımında makine öğrenimini kullanarak konut özelliklerine ilişkin içgörüler elde etmek. *J. Sürdürülebilirlik Geliştirme Enerji Su Çevre Sis.*2022, 10, 1–13. [[ÇaprazRef](#)]
53. Marteau, TM; Chater, N.; Garnett, EE 2050'de net sıfır emisyon için değişen davranışlar. *BMJ*2021, 7, 375. [[ÇaprazRef](#)]
54. Ramezanpour, K.; Jagannath, J. 5G/6G ağları için akıllı sıfır güven mimarisi: İlkeler, zorluklar ve O-RAN bağlamında makine öğreniminin rolü. *Bilgisayar Ağ*2022, 217, 109358. [[ÇaprazRef](#)]
55. Liu, W.; Şen, Y.; Aungkulanon, P.; Ghalandari, M.; Le, BN; Alviz-Meza, A.; CArdenas-Escrocia, Y. Sıfır yeşil enerjili binalarda fotovoltaik sistem optimizasyonu için makine öğrenimi uygulamaları. *Enerji Temsilcis*2023, 9, 2787–2796. [[ÇaprazRef](#)]
56. Oviedo-Cepeda, JC; Amara, FZ; Athienitis, AK Net Sıfır Enerjili Bir Binanın Esnekliği Üzerindeki Model Tahmini Kontrol Ufku Etkisi. In IECON 2021–47. IEEE Endüstriyel Elektronik Topluluğu Yıllık Konferansı Bildirileri, Toronto, ON, Kanada, 13–16 Ekim 2021.
57. Friesen, M.; Wisniewski, L.; Jasperneite, J. Heterojen Endüstriyel Ağlarda Sıfır Dokunmalı Yönetim için Makine Öğrenimi-Bir İnceleme. 2022 IEEE 18. Fabrika İletişim Sistemleri Uluslararası Konferansı (WFCS) Bildirilerinde, Pavia, İtalya, 27-29 Nisan 2022. [[ÇaprazRef](#)]
58. Schmidt, J.; Hoffmann, N.; Wang, HC; Borlido, P.; Carrico, PJ; Cerqueira, TF; Botti, S.; Marques, MA Malzemelerin Küresel Sıfır Sıcaklık Faz Diyagramının Makine Öğrenimi Destekli Belirlenmesi. *İleri Mater.*2023, 35, 2210788. [[ÇaprazRef](#)]
59. Zhou, Q.; Pezaros, D. Sıfır Gün Saldırı Tespiti için Makine Öğrenimi Sınıflandırıcılarının Değerlendirilmesi - CIC-AWS-2018 veri kümesi üzerinde bir analiz. *arXiv*2019, arXiv:1905.03685.
60. Weng, C.; Yang, K.; Xie, X.; Katz, J.; Wang, X. Mystique: Makine öğrenimine uygulamaları olan {Sıfır Bilgi} kanıtları için verimli dönüşümler. 30. USENIX Güvenlik Sempozyumu Bildirilerinde (USENIX Güvenlik 21), Vancouver, BC, Kanada, 11–13 Ağustos 2021.
61. Ohene, E.; Chan, AP; Darko, A. Net sıfır emisyonlu binalara yönelik küresel araştırma ilerlemelerinin gözden geçirilmesi. *Enerji İnşası*2022, 266, 112142. [[ÇaprazRef](#)]
62. Ashraf, WM; Uddin, GM; Tariq, R.; Ahmed, A.; Farhan, M.; Nazeer, MA; Hassan, RU; Naeem, A.; Jamil, H.; Krzywanski, J.; ve diğerleri. Enerji Sektöründe Net Sıfıra Doğru Hareket İçin Endüstriyel Ölçekli Bir Buhar Türbininin Yapay Zeka Modellemeye Dayalı Optimizasyonu. *ACS Omega*2023, 8, 21709–21725. [[ÇaprazRef](#)]
63. Moraliyage, H.; Dahanayake, S.; De Silva, D.; Mills, N.; Rathnayaka, P.; Nguyen, S.; Alahakoon, D.; Jennings, A. Net sıfır karbon emisyonları için enerji verimli altyapının ölçümü ve doğrulanması için açıklanabilirliğe sahip sağlam bir yapay zeka yaklaşımı. *Sensörler*2022, 22, 9503. [[ÇaprazRef](#)] [[PubMed](#)]

64. Usman, IM; Ho, YC; Baloo, L.; Lam, MK; Sujarwo, W. Biyokütleden elde edilen biyöürünlerin net sıfır karbon emisyonuna (NZCE) ulaşma yolundaki ilerlemelerine ilişkin kapsamlı bir inceleme. *Biyokaynak Tekn.* **2022**, *366*, 128167.
65. Cao, L.; Hu, P.; Li, X.; Sun, H.; Zhang, J.; Zhang, C. Net sıfır enerji geçişi için dijital teknolojiler: Ön çalışma. *Karbon Nötrlüğü* **2023**, *2*, 7. [[ÇaprazRef](#)]
66. Makine öğrenimiyle net sıfır emisyonu ulaşmak: Önümüzdeki zorluk. *Nat. Mak. Zek.* **2022**, *4*, 661–662. [[ÇaprazRef](#)]
67. Wu, X.; Feng, Z.; Chen, H.; Qin, Y.; Zheng, S.; Wang, L.; Liu, Y.; Skibniewski, MJ Hibrit makine öğrenme algoritmasına dayalı sıfıra yakın enerji tüketimli bina performansının akıllı optimizasyon çerçevesi. *Yenile. Sürdür. Enerji Rev.* **2022**, *167*, 112703. [[ÇaprazRef](#)]
68. Thompson, JS; Fletcher, S.; Friderikos, V.; Gao, Y.; Hanzo, L.; Nakhai, MR; O'Farrell, T.; Wells, PD Editöryal Bir On Yıllık Yeşil Radyo ve "Net Sıfır"a Giden Yol: Birleşik Krallık Perspektifi. *IEEE Trans. Yeşil İletişim Ağ.* **2022**, *6*, 657–664. [[ÇaprazRef](#)]
69. Sarhan, M.; Layeghy, S.; Gallagher, M.; Portmann, M. Sıfır atışlı makine öğrenmesinden sıfır günlük saldırı tespitine. *Uluslararası Hukuk Dergisi Inf. Secur.* **2023**, *22*, 947–959. [[ÇaprazRef](#)]
70. Real, E.; Liang, C.; So, D.; Le, Q. Automl-zero: Makine öğrenimi algoritmalarını sıfırdan geliştirmek. 37. Uluslararası Makine Öğrenimi Konferansı Bildirilerinde, Sanal, 13-18 Temmuz 2020.
71. Mbona, I.; Eloff, JH Yarı-gözetimli makine öğrenimi yaklaşımlarını kullanarak sıfırinci gün saldırılarının tespiti. *IEEE Erişimi* **2022**, *10*, 69822–69838. [[ÇaprazRef](#)]
72. Zeiler, W. Net Sıfıra Ulaşmak İçin Binaların Beyinleri. *İnşaat Sektöründe Net Sıfır Karbon Emisyonuna Doğru*; Springer International Publishing: Cham, İsviçre, 2022; s. 63–89.

Yasal Uyarı/Yayıncının Notu:Tüm yayınlarda yer alan ifadeler, görüşler ve veriler yalnızca bireysel yazar(lar) ve katkıda bulunan(lar)a aittir ve MDPI ve/veya editör(ler)e ait değildir. MDPI ve/veya editör(ler), içerikte atıfta bulunulan herhangi bir fikir, yöntem, talimat veya üründen kaynaklanan herhangi bir kişi veya mal yarananmasından sorumlu değildir.