

Araştırma Makalesi - Research Article

Türkiye Kısa Dönem Elektrik Yük Talep Tahmininde Makine Öğrenmesi Yöntemlerinin Karşılaştırılması

Comparison of Machine Learning Methods in Turkey's Short- Term Electricity Load Demand Estimation

Kübra Kaysal^{1*}, Emre Akarşlan², Fatih Onur Hocaoğlu³

Geliş / Received: 05/10/2021

Revize / Revised: 24/07/2022

Kabul / Accepted: 25/07/2022

ÖZ

Enerji sektöründe arz-talep yönetimi, gelişmekte olan ve büyüyen ülke ekonomileri için öncelikli öneme sahiptir. Artan nüfusa, yükselen ekonomiye ve sanayideki gelişmelere bağlı olarak ülkelerin enerji ihtiyaçları da büyük ölçüde artmaktadır. Bu nedenle, gelecekteki elektrik arz-talep eğilimlerinin doğru ve güvenilir bir şekilde tahmin edilmesi için modeller kullanılması, tüketiciler ve bu alandaki yatırımcılar için dikkat çeken bir konu olmuştur. Bu çalışmada, Türkiye kısa dönem elektrik yük talep tahminini gerçekleştirebilmek için başarıları literatürde kanıtlanmış makine öğrenmesi yöntemlerinden, Yapay Sinir Ağları, Ridge Regresyon, Lasso Regresyon ve Destek Vektör Regresyonu kullanılmıştır. Tahmin modellerinde kullanılan veriler Türkiye Elektrik İletim Anonim Şirketi'nden temin edilmiştir. Geçmişe dönük saatlik frekansta ölçülmüş bir yıllık veri seti ile bir saatlik ileriye yönelik tahminler gerçekleştirilmiştir. Yöntemlerden elde edilen sonuçların karşılaştırılabilmesi için literatürde sık kullanılan performans ölçüt kriterlerinden RMSE, MAE ve R^2 değerleri hesaplanmıştır. Yapay Sinir Ağları, geliştirilen makine öğrenmesi modelleri arasında RMSE=0,86, MAE=0,62 ve $R^2=0,97$ sonuçları ile daha başarılı bulunmuştur.

Anahtar Kelimeler- Makine Öğrenmesi, Yapay Sinir Ağları, Destek Vektör Regresyonu, Lasso Regresyon, Ridge Regresyon

ABSTRACT

Supply-demand management of the energy sector is of prime importance for rapidly growing economies and developing countries. Depending on the increasing population, the rising economy, and the developments in the industry, the countries' energy needs are increasing to a great extent. Therefore, using models to accurately and reliably predict future electricity supply-demand trends has attracted the attention of consumers and investors in this field. In this study, Artificial Neural Networks, Ridge Regression, Lasso Regression and Support Vector Regression, proven successes in the literature, are used to realize Turkey's short-term electric load demand estimation. Data used in the forecasting models were obtained from the Turkish Electricity Transmission Corporation. A one-hour future estimation is accomplished using a past year-long dataset of electrical energy. To compare the results obtained from the methods, RMSE, MAE and R^2 values, frequently used in the literature, were

^{1*}Sorumlu yazar iletişim: kkaysal@aku.edu.tr (<https://orcid.org/0000-0003-3983-2608>)

Elektrik Bölümü, Afyon Kocatepe Üniversitesi, Afyon Meslek Yüksek Okulu, Afyonkarahisar, Türkiye

²İletişim: akarşlan@aku.edu.tr (<https://orcid.org/0000-0002-5918-7266>)

Elektrik Mühendisliği, Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Afyonkarahisar, Türkiye

³İletişim: fohocaoglu@gmail.com (<https://orcid.org/0000-0002-3640-7676>)

Elektrik Mühendisliği, Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Afyonkarahisar, Türkiye

calculated. The comparison results show that the Artificial Neural Networks were more successful with RMSE=0.86, MAE=0.62 and $R^2=0.97$ results among the developed machine learning models.

Keywords- *Machine Learning, Artificial Neural Network, Support Vector Regression, Lasso Regression, Ridge Regression*

I. GİRİŞ

Günümüzde dünya üzerinde talebi hızla artan enerji türlerinden biri elektrik enerjisidir. Artan nüfus, gelişen teknoloji ve sanayi gibi etkenler elektrik ihtiyacını her gün biraz daha artırmaktadır. Bu ihtiyacın karşılanmaması arz-talep dengesini bozacağı ve dünya üzerinde enerji krizlerine yol açabileceği için ileriye dönük elektrik üretim, iletim ve dağıtım planlarının yapılması zorunluluk haline gelmiştir. Elektrik enerjisinin doğru bir şekilde kullanılması için ihtiyaç olan miktarda üretilmesi gerekmektedir. Bu yüzden enerji sektöründe planlama önemli bir yere sahip olmakta ve bunun temelini ise yük talep tahmini oluşturmaktadır. Enerji talebinin doğru bir şekilde tahmin edilememesi arz ve buna bağlı olarak talep arasında oluşacak farklar ülke ekonomisi üstünde olumsuz etkiler oluşturabilmektedir. Nitekim üretilen enerjinin talepten fazla olması elektrik sistemlerinde kararsızlığa, az olması ise enerji açıklarının oluşmasına, kesintilere, sistem sorunlarına vb. problemlere yol açabilmektedir. Bu sebeplerden dolayı dünyada enerji talebi üzerine yapılan çalışmalar oldukça önem kazanmış ve bu konu üzerine çalışmalar hız kesmeden devam etmiştir [1].

Haliloğlu ve Tutu, literatüre katkı sağladıkları bir çalışmalarında, Türkiye için kısa dönem elektrik enerjisi talep tahmini yapmışlardır. Çalışmada günlük toplam tüketim verileri kullanılarak bir gün sonrası En Küçük Kareler yöntemi ile tahmin edilmiştir [1]. Diğer bir çalışmada, Kell ve arkadaşları İngiltere için kısa dönem talep tahmininde 16 farklı makine öğrenmesi yöntemi kullanmışlardır. Yöntemlerden elde edilen hataları kıyaslayıp en uygun tahminin Online algoritmalarında olduğu gözlenmiştir [2]. Naik ve arkadaşları, rüzgâr hızı ve gücünün kısa dönem tahmini için hibrit bir tahmin modeli geliştirmiştir. Modelde Multi Kernel Ridge regresyon yöntemi kullanılmış ve modelin performansını geliştirmek için çeşitli parametreleri Mutasyona Uğramış Ateş Böceği algoritması ile optimize edilmiştir. Sonuç olarak optimize edilen modelin performansı daha başarılı bulunmuştur [3]. Lv ve arkadaşları, kısa dönem rüzgâr gücü tahmini için makine öğrenimi yöntemlerini kullanmışlardır. Sonuçlar olasılıksal tahmin yöntemlerinin daha başarılı olduğu göstermiştir [4]. Alleee ve arkadaşları, makine öğrenmesi yöntemlerini kullanarak Tanzanya için yük tahmini yapmışlardır. Tahmin modelleri için 1378 Tanzanya mini şebeke müşterisinden alınan anket ve akıllı sayaç verileri kullanılmıştır. En iyi performans Lasso Regresyon modelinden elde edilmiştir [5]. Yıldız ve arkadaşları, ticari bir binanın elektrik yükü tahmini için regresyon ve makine öğrenmesi yöntemlerini kullanmışlardır. Sonuç olarak Bayes Regülasyonlu Geri Yayılımlı Yapay Sinir ağlarının en iyi performansı gösterdiği tespit edilmiştir [6]. Bitirgen ve Filik literatüre katkıda buldukları çalışmalarında, elektrik fiyat tahmini için XGBoost ve ARIMA algoritmalarını kullanmışlardır. XGBoost modelinin MAE (Mean Absolute Error) sonucu 101,3 olarak bulunmuş ve performansı ARIMA modeline göre daha başarılı kabul edilmiştir [7]. Alsafadi ve Filik'in bir diğer çalışmasında ise, saatlik küresel güneş radyasyonu tahmini için makine öğrenmesi yöntemini kullanılmıştır [8]. Yürek ve arkadaşları, makine öğrenimi algoritmalarını kullanarak rüzgâr enerjisi ile elektrik üretimini tahmin etmişlerdir. Yöntemler arasından hatası en düşük çıkan Rasgele Karar Ormanı algoritması olmuştur [9]. Ali ve arkadaşları, ARIMA ve Random Forest tahmin yöntemleri ile kısa dönem elektrik yük tahmini yapmışlardır [10]. Shi ve arkadaşları kısa dönem yük tahmini için Random Forest ve Destek Vektör Makine öğrenmesi yöntemlerinin performanslarını kıyaslamışlardır. Çalışmada Random Forest modeli daha başarılı sonuçlar vermiştir [11]. Wang ve arkadaşları, kısa dönem güneş yoğunluğu tahminini Lasso Regresyon algoritmasını kullanarak gerçekleştirmişlerdir [12]. Küçük, çalışmasında parametre tahmini yapabilmek için Lasso, Ridge ve Liu yöntemlerini kullanmış ve bu yöntemlerin performansını karşılaştırmıştır. Sonuç olarak En Küçük Kareler yöntemine alternatif olarak bu üç yöntemde kullanılabileceğini gözlemlemiştir [13]. Shirzadi ve arkadaşları makine öğrenmesi ve derin öğrenme yöntemleri ile orta dönem elektrik yük tahmini yapmışlardır. Buna göre Derin Öğrenme yöntemlerinde tahmin hatalarının daha az olduğu görülmüştür [14].

Kaur ve arkadaşları, makine öğrenmesi yöntemleri ile kısa dönem elektrik talep tahmini yapmışlardır. Çeşitli makine öğrenmesi yöntemlerinden elde edilen sonuçlar kıyaslanmış ve bu çalışma için en uygun performansı, Destek Vektör Regresyonu ve Lasso Regresyon algoritmaları vermiştir [15]. Waciko ve Ismail Endonezya ve Hindistan'ın GSYİH tahmini için Makine öğrenmesi yöntemlerinden Lasso, Ridge ve Elastik Net Regresyon yöntemlerinin performanslarını karşılaştırmışlardır. MSE (Mean Square Error) kriterine göre Elastik Net Regresyon modeli, diğer modellerden daha başarılı sonuç vermiştir [16]. Portabales ve arkadaşları Yapay Sinir Ağları (YSA) tabanlı makine öğrenimi yöntemleri ile elektrik talep tahmini yapmıştır [17]. Khan ve arkadaşları

yenilenebilir ve yenilenemez güç kaynaklarının enerji tüketimini, makine öğrenimi yöntemleri ile tahmin etmişlerdir. Çok Katmanlı Yapay Sinir Ağı, Destek Vektör Regresyonu ve CatBoost yöntemleri birleştirilerek hibrit bir makine öğrenimi yöntemi oluşturulmuştur [18].

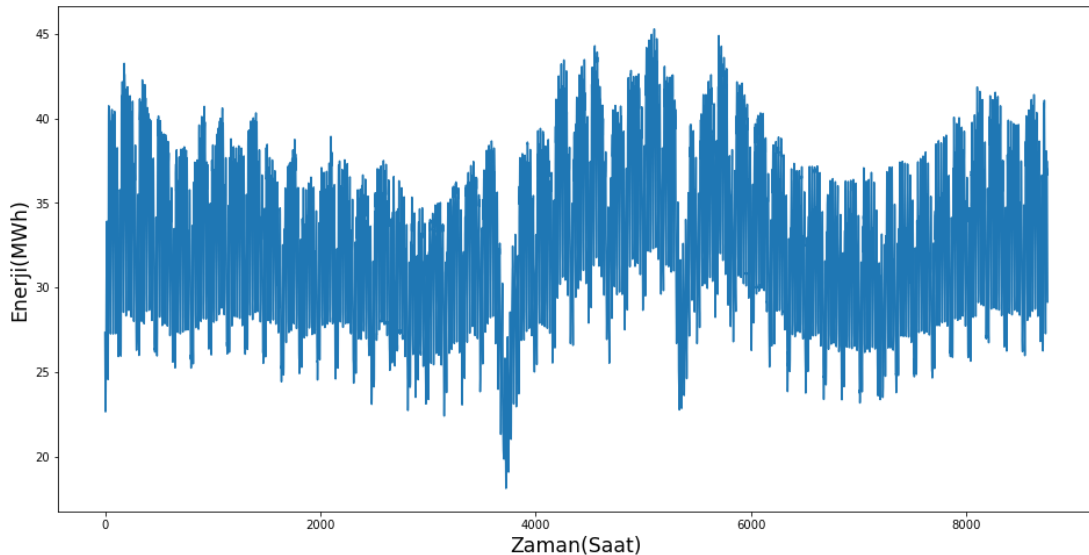
Mitchell ve arkadaşları, Yapay Sinir Ağı (YSA) ve Destek Vektör Regresyonunu kullanarak kısa dönem yük tahmini yapmışlardır. Çalışmada, YSA'nın tahmin hatası daha düşük tespit edilmiştir [19]. Mohammad ve arkadaşları derin sinir ağı metodu ile kısa dönem yük tahmini yapmışlardır. Sinir ağını sigmoid, hiperbolik tanjant gibi aktivasyon fonksiyonları ile test edip sonuçları değerlendirmişlerdir. Sonuç olarak hiperbolik tanjant aktivasyon fonksiyonunun daha iyi sonuçlar verdiğini gözlemlemişlerdir [20]. Küçük ve Gezer, enerji alanındaki tahmin problemlerinde, Makine Öğrenmesi ve Derin Öğrenme tekniklerini kullanmışlardır. Çalışmaların sonucunda Makine Öğrenmesi tekniklerinin yanında Derin Öğrenme tekniklerinin de başarılı sonuçlar verdiği tespit edilmiştir [21]. Işıl ve Bulut, Ridge Regresyon tahmin edicisinde farklı yanlılık parametrelerinin performanslarını simülasyon çalışması ve gerçek veri örneği üzerinde incelemiştir [22]. Yıldırım ve Kandemir, geçmiş yağış verilerini kullanarak yağış tahmini yapmışlardır. Tahminde, YSA ve Doğrusal Regresyon yöntemleri kullanılmış ve performansları kıyaslanmıştır. YSA modeli daha başarılı sonuçlar vermiştir [23].

Yapılan bu çalışmanın amacı, arz-talep dengesini sağlayabilmek adına, Türkiye kısa dönem elektrik yük talep tahmini için en doğru ve güvenilir sonuçlar veren, Makine Öğrenimi yöntemlerini belirlemektir. Bu kapsamda, literatürde farklı alanlarda tahminleme çalışmalarında kullanılan ve iyi performans gösterdiği belirlenen YSA, Ridge Regresyon, Lasso Regresyon ve Destek Vektör Regresyonu yöntemleri, sunulan çalışmada kullanılmak üzere seçilmiştir. Bu yöntemlerin, Türkiye kısa dönem elektrik yük talebi tahminindeki performansı incelenmiş ve değerlendirilmiştir. Çalışmada mevcut güncel veriler ve güncel yöntemler kullanıldığı için arz-talep tahmininin de enerji sektörüne ışık tutacağı düşünülmektedir.

II. MATERYAL VE METOT

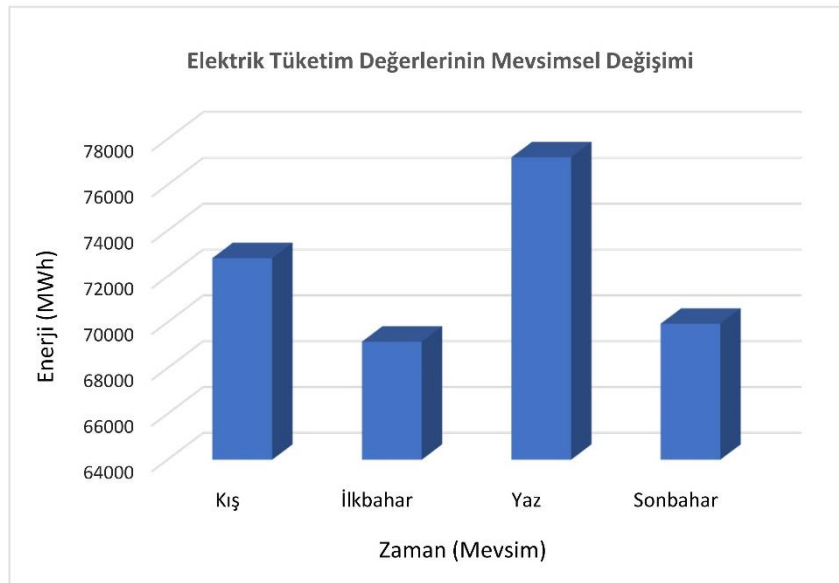
A. Veri Tanımı

Bu çalışmada, Türkiye Elektrik İletim Anonim şirketinden alınan 1 Ocak 2019 ile 31 Aralık 2019 dönemine ait elektrik yük talebi verileri kullanılmıştır. Saatlik frekansta toplam 8760 adet veri Makine Öğrenmesi algoritmaları kullanılarak eğitilmiştir [24]. Çalışmada kullanılan bir yıllık elektrik üretim verileri Şekil 1'de görülmektedir.



Şekil 1. 1 Ocak 2019-31 Ocak 2019 tarihlerinde üretilen saatlik elektrik tüketim verileri

Veriler incelendiğinde elektrik tüketiminin mevsimsel bir trend sergilediği görülmektedir. Tüketim verilerinin mevsimsel değişimini daha detaylı görebilmek için saatlik verilerin mevsimsel olarak ortalamaları alınmış ve Şekil 2'deki gibi oluşturulmuştur.




Şekil 2. Tüketim verilerinin mevsimsel değişimi

Doğrusal bir trende sahip olmayan bu verilerin modellenmesi oldukça karmaşık ve zor olduğu için klasik tahmin yöntemleri yerine Makine Öğrenmesi yöntemlerine ihtiyaç duyulmuştur. [25,26].

B. Yapay Sinir Ağları

Yapay sinir ağları; tıpkı insan beyni gibi katmanlı yapısı ile makineye sayısal olarak tüm işlevleri yaptırabilen bir modeldir. Ağın yapısı biyolojik sinir ağı yapısına benzemektedir. YSA'nın en önemli özelliği modele sunulan veri setini öğrenerek istenilen sonuca uygun tahmin ya da sınıflandırma yapabilmesidir. Veri seti üzerinde çalışarak ağın ağırlıkları belirlenir. Her bir ağırlık(w) her bir girdi değerleri(x) ile çarpılıp toplandıktan sonra bir aktivasyon fonksiyonunda işlenir ve çıktı katmanına gönderilir. YSA'nın kaç gizli katmanı ve kaç nöronu olacağı çalışmanın durumuna ve istenen sonuca göre değişiklik gösterir. Bir YSA modeli Şekil 3'te verilmiştir.



Şekil 3.Yapay sinir ağı modeli

En genel haliyle bir YSA'nın matematiksel ifadesi Denklem 1'de verilmiştir.

$$y = \sum_{i=1}^n x_i w_i \quad (1)$$

Burada x_i ağın girdi değerleri, w_i sistemin ağırlıkları ve y ise çıktı değerleridir.

C. Regresyon Yöntemi

Regresyon yöntemi, bilinen bir değerden bilinmeyen bir durumu belirlemek olarak adlandırılabilir. Bu yöntem içerisinde bağımlı ve bağımsız değişkenler mevcuttur. Model oluşturulurken istenen duruma göre bağımsız değişken bir veya daha fazla olabilir. Regresyon yöntemi değişkenler arasındaki ilişkiyi açıklayabildiği gibi bilinen durumlardan bilinmeyen durumları da tahmin edebilmektedir.

Tek bağımsız değişkeni olan regresyona basit regresyon, birden fazla değişkeni olan regresyona ise çok değişkenli regresyon denilmektedir. Çok değişkenli bir regresyon modelinin matematiksel ifadesi Denklem 2'de verilmiştir [27].

$$\beta = \beta^{arg\ min}\{\sum_{i=1}^n (y_i - x_i'\beta)^2\} \quad (2)$$

Denklem 2'de β katsayısı bağımsız değişkenlerin etkisini kontrol eder. Hata terimleri ε ile gösterilmektedir ve rassal bir dağılım söz konusudur. Burada $\beta^{arg\ min}$ doğrunun y eksenini kestiği yer ve regresyon sabitidir. β ise doğrunun eğimidir.

1) Ridge Regresyon: Doğrusal regresyonda hesaplanan varyansların büyük olması tahmini gerçek değerlerinden uzaklaştırmaktadır. Ridge Regresyon, çoklu doğrusal bağlantıda çoklu regresyon verilerini analiz etmek için kullanılan sapmalı bir tahmin yöntemidir. Doğrusal regresyonun bir dalı olan Ridge Regresyonda hatalar minimize edilerek hata fonksiyonu değiştirilmektedir. Bu değişikliği modelin β katsayılarının karesini bir ceza parametresi (λ) ile çarparak yapmaktadır. Bu sayede Doğrusal Regresyonda oluşan hatalar Ridge Regresyonda minimize edilmiş olacaktır [27]. Ridge Regresyon modelinin matematiksel ifadesi Denklem 3'teki gibi verilmiştir.

$$\beta^{rdg} = \beta^{arg\ min}\{\sum_{i=1}^n (y_i - x_i'\beta)^2 + \lambda \sum_{j=1}^p \beta_j^2\} \quad (3)$$

2) Lasso Regresyon: Lasso Regresyon doğrusal regresyon modelini iyileştirmek için geliştirilen yöntemlerden bir diğeridir. Çoklu doğrusal regresyonda değişken sayısı arttıkça kurulan modelde bir süre sonra aşırı öğrenmeye gidilmektedir. Bu durum tahmin sonuçlarını gerçek sonuçlardan uzaklaştırmaktadır. Diğer bir problem ise sıfırdan farklı katsayı arttıkça modeli açıklamak zorlaşabilmektedir. Lasso Regresyon'un amacı doğrusal regresyondaki sorunları azaltıp tahminin doğruluğunu artırmaktır. Bunun için modele bir ceza terimi olan λ katsayısı uygulanmaktadır. λ modeldeki hata kareler toplamını minimize eden terimdir. Modele uygulanan λ parametresinin seçimi modelin daha doğru çalışabilmesi için oldukça önemlidir. Eğer λ aşırı yüksek seçilirse katsayılar sıfır olabilir ve model kavramını ortadan kaldırabilir. λ sıfır olursa klasik regresyon analizi yapılmış olur. Bu sebeplerden dolayı λ 'nın optimal değeri yaygın olarak çapraz doğrulama metodu ile belirlenir. Lasso Regresyon'un matematiksel ifadesi Denklem 4'te verilmiştir [12, 13, 27].

$$\beta^{lasso} = \beta^{arg\ min}\{\sum_{i=1}^n (y_i - x_i'\beta)^2 + \lambda \sum_{j=1}^p |\beta_j|\} \quad (4)$$

3) Destek Vektör Regresyonu: Destek vektör regresyonu, denetimli makine öğrenmesi yöntemlerinden biridir. Bu regresyon modelinin temelini doğrusal olmayan bir fonksiyonun girdi verilerinin eşleştiği yüksek boyutlu bir girdi uzayında doğrusal regresyonun hesaplanması oluşturmaktadır. Böylece düşük boyutlu doğrusal olmayan bir regresyon probleminin çözümü yüksek boyutlu bir uzayda gerçekleştirilmektedir [27]. Destek vektör regresyonunun optimizasyonu için kernel parametresi (γ), ceza faktörü (C), epsilon değeri (ε) gibi hiper parametrelere ait değerlerdeki değişiklikler incelenebilmektedir [28]. Destek vektör regresyon modelinin matematiksel ifadesi Denklem 5'te verilmiştir.

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) < x_i, x > + b \quad (5)$$

Makine öğrenmesi yöntemlerinde performans değerlendirmek için çeşitli ölçütler kullanılmaktadır. Seçilen performans değerlendirme ölçütleri modele ve veri setine göre farklılık göstermektedir. Bu performans değerlendirme ölçütleri arasında en sık kullanılanlar, Açıklayıcılık Katsayısı (R^2), Ortalama Hata Kare Kökü (Root Mean SquareError-RMSE), Ortalama Mutlak Hata (Mean Absolute Error-MAE)'dir. RMSE ve MAE birer hata ölçüsü olduklarından performans değerlendirme de bu ölçütlerin ne kadar küçük olduğuna bakılmaktadır. RMSE sıfıra yakın veya sıfır gibi bir değer ise yapılan tahminin oldukça başarılı olduğu yorumu yapılabilmektedir [28]. R^2 performans ölçütü ise modelin doğruluğunu açıklamaktadır. R^2 ne kadar 1'e yakınsa modelin doğruluğu ve açıklanabilirliği o kadar yüksektir.

Enerji arz-talep dengesini sağlamak adına yük talep tahmini oldukça önemli bir yere sahiptir. Bunun için seçilen yöntemin hem veri setine uygun olması hem de performansının yüksek olmasına dikkat etmek gerekir [29]. Bu çalışmada, daha yüksek bir model performansını sağlamak için yük talep tahmininde makine öğrenmesi yöntemlerinden Ridge Regresyon, Lasso Regresyon, Destek Vektör Regresyonu ve Yapay Sinir Ağları yöntemleri ile yük tahmini yapılmış ve performans değerlendirmek için literatürde sıklıkla kullanılan RMSE, MAE ve R^2 kriterleri kullanılmış ve sonuçlar birbiriyle kıyaslanmıştır.

III. BULGULAR VE TARTIŞMA

Çalışmanın bu bölümünde farklı makine öğrenmesi yöntemleri, 2019 yılına ait Türkiye'nin toplam elektrik tüketim verileri kullanılarak Matlab R2020b yazılımı ile test edilmiştir. Öncelikle veriler hazırlanmış, değerlendirme kriterleri hesaplanmış ve sonuçlar hem sayısal hem de grafiksel olarak verilmiştir.

A. Veri Düzenleme ve Değerlendirme Ölçütleri

Bu çalışmada, çeşitli makine öğrenmesi algoritmalarının uygulanabilirliği ve performansı test edilmeye çalışılmıştır. Öncelikle; 1 Ocak 2019 ile 31 Aralık 2019 tarihleri arasında gerçek zamanlı saatlik frekansta ölçülen 8760 adet veri seti eğitimin daha verimli hale getirilebilmesi için normalleştirilmiştir. Veri normalleştirme tekniklerinden biri olan ve literatürde sık karşılaşılan Min-Max yöntemi ile veriler 0-1 aralığında olacak şekilde tekrar düzenlenmiştir [30]. Denklem 6'da Min-Max yöntemine ait formül verilmiştir.

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (6)$$

Burada x' normalleştirilmiş veriyi, x_i girdi verisini, x_{min} girdi veri seti içerisindeki en küçük değeri, x_{max} ise girdi veri seti içerisindeki en büyük değeri ifade etmektedir [30]. Sonrasında tahmin değişkenleri dört, üç, iki, bir saat önceki veriler olarak belirlenmiş ve bir saat sonrası tahmin edilmeye çalışılmıştır. Verinin %80'i eğitim, %20'si de test verisi olarak ayrılmıştır. Bu doğrultuda, 1 Ocak 2019-19 Ekim 2019 tarihleri arasında ölçülen 7008 adet veri modele eğitim, 20 Ekim 2019- 31 Aralık 2019 tarihleri arasında ölçülen 1752 adet veri ise modele test verisi olarak sunulmuştur.

Önerilen modellerin tahmin performansını değerlendirmek için literatürde sık kullanılan istatistiki değerlendirme ölçütlerinden Ortalama Hata Kare Kökü (RMSE), Ortalama Mutlak Hata (MAE) ve doğruluk kriterinden olan Belirleme Katsayısı R^2 kullanılmıştır [31-35]. RMSE, modeldeki tahmin hatalarının standart sapmasını hesaplamaktadır. Denklem 7 ile ifade edilmiştir.

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (y_n - \hat{y}_n)^2}{N}} \quad (7)$$

MAE, tahmin edilen değerler ile gerçek değerler arasındaki farkın ortalama mutlak sapmasıdır. Denklem 8 ile ifade edilmiştir [35].

$$MAE = \frac{\sum_{i=1}^n |y_n - \hat{y}_n|}{N} \quad (8)$$

R^2 , modellerden tahmin edilen değerler ile gerçek değerler arasındaki ilişkiyi hesaplamaktadır. Denklem 9'da verilmiştir [35].

$$R^2 = 1 - \frac{\sum_{n=1}^N (y_n - \hat{y}_n)^2}{\sum_{n=1}^N (y_n - \bar{y}_n)^2} \quad (9)$$

Değerlendirme ölçütleri olarak kullanılan Denklem (7)-(9)'daki y_n n. zamanda gözlenen veri değeri, \hat{y}_n tahmin edilen değeri, \bar{y}_n verilerin ortalamasını, N ise gözlem sayısını ifade etmektedir [15,35].

B. Modellerden Elde Edilen Sonuçlar

Makine öğrenmesi metodlarında model başarısını etkileyen çeşitli hiper parametreler bulunmaktadır. Uygun parametre değerleri, tahminde hatayı azaltmakta başarı oranını artırmaktadır [15,35]. Ridge ve Lasso Regresyon modellerinde hatayı minimize etmek amacıyla ceza katsayısı olan λ 'ya 0 ile 1 arası değişen çeşitli değerler verilerek hata ölçütlerinden RMSE ve MAE sonuçları hesaplanmıştır. Her iki model için en düşük hatayı veren λ değeri Ridge Regresyon için 0,012, Lasso Regresyon için 0,899 olarak bulunmuştur.

Destek Vektör Regresyonunda model hassasiyetini belirleyen hiper parametrelerden biri epsilon (ϵ) değeridir. ϵ değerinin çok yüksek seçilmesi veri üzerinde fazla basınç oluşturacağından, destek vektörlerinin sayısını azaltıp tahmin doğruluğunu düşürecektir. Modele 0 ile 1 arasında değişen farklı ϵ değerleri uygulandığında hata değerini en düşük hesaplayan ϵ değeri 0,54 olarak tespit edilmiştir.

YSA'da model üç adet gizli katman ve bir adet çıkış katmanından oluşmuştur. Sistemin üreteceği çıktıyı belirlemek için hiperbolik tanjant aktivasyon fonksiyonu kullanılmıştır.


Parametre ayarları tamamlandıktan sonra modeller ayrı ayrı eğitilmiştir. Her modelin RMSE, MAE ve R^2 değerleri hesaplanmış ve Tablo 1'de verilmiştir.

Tablo 1. Modellerden elde edilen performans sonuçları

Modellerden Elde Edilen RMSE, MAE ve R^2 Değerleri			
	RMSE (MWh)	MAE (MWh)	R^2
Ridge Regresyon	1,45	1,30	0,961
Lasso Regresyon	2,00	1,49	0,831
Destek Vektör Regresyonu	0,94	0,67	0,961
Yapay Sinir Ağları	0,86	0,62	0,97

Tahminlerde RMSE ve MAE gibi hata ölçüt kriterlerinin küçük olması gerçeğe yakın tahminler yapıldığını ve R^2 değerinin yüksek olması ise tahmin doğruluğunun yüksek olduğunu göstermektedir. Makine öğrenmesi yöntemleri ile tahminde başarılı sonuçlar alınıyor olması araştırmacıların ilgi odağı olmaya başlamıştır [1,7,8,15].

Modellerin sonuçlarından elde edilen, gerçek ve tahmini değerleri gösteren grafikler Şekil 4’de verilmiştir.



Şekil 4. Modellerden elde edilen tahmin grafiği

Türkiye elektrik talebinin saatlik tahmini için belirlenen modellerin güvenilirliğine yönelik yapılan analizler sonucunda dört farklı yöntem ile tahmin yapılmış ve modellerin performansı gerekli hiper parametre ayarları yapıldıktan sonra RMSE, MAE ve R^2 ölçütlerine göre değerlendirilmiştir. Tahmin modellerinden beklenen başarı hatası az, doğruluğu yüksek sonuçlar üretmektir. Bu amaç doğrultusunda modellerden elde edilen sonuçlar kıyaslanmış ve YSA’nın diğer modellere göre hata değerleri oldukça düşük, doğruluk kriteri ise 0,97 ile oldukça başarılı çıkmıştır. Çalışmada başarılı olan modelin performans sonuçları literatürde kullanılan ve güncel çalışmalardan oluşan tahmin modelleri ile kıyaslaması Tablo 2’de verilmiştir.

Tablo 2. Çeşitli makine öğrenmesi yöntemlerinin performanslarının yapılan çalışma ile kıyaslanması

Yazarlar	Yayın Tarihi	Tahmin Yöntemi	Değerlendirme Ölçütleri	Veri Seti
Haliloğlu vd. [1]	2018	EKK	$R^2 = 0,928$	1945 adet gerçek zamanlı veri seti
Allee vd. [5]	2021	Lasso Regresyon	RMSE=13,5 MAE=3,5 MAPE=%37	1378 adet gerçek zamanlı veri seti
Bitirgen ve Filik [7]	2020	XGBoost	MAE= 101,3 MAPE=306,9 RMSE=99,4	8760 adet gerçek zamanlı veri seti
Alsafadi vd. [8]	2020	Destek Vektör Regresyonu	RMSE=63,86 $R^2 = 0,97$	8760 adet gerçek zamanlı veri seti
Mitchell vd. [19]	2017	Yapay Sinir Ağları	MAPE = 1,04	15960 adet gerçek zamanlı veri seti
Mohammad vd. [20]	2018	Derin Öğrenme	MAPE = 0,58	62104 adet gerçek zamanlı veri seti
Yıldırım vd. [23]	2018	Yapay Sinir Ağları	$R^2 = 0,92$	4018 adet gerçek zamanlı veri seti
Bekçioğulları vd. [32]	2021	Destek Vektör Makinesi	RMSE=0,04 MAE=0,037 $R^2 = 0,97$	8760 adet gerçek zamanlı veri seti
Kuşkapan vd. [33]	2022	Yapay Sinir Ağları	$R^2 = 0,97$	1977-2019 yıllık veri seti
Yapılan Çalışma	2022	Yapay Sinir Ağları	RMSE=0,85 MAE=0,62 $R^2 = 0,97$	8760 adet gerçek zamanlı veri seti

Tablo 2 incelendiğinde tahmin için yeterli veri seti olduğu görülmektedir. Güncel literatür çalışmalarının tahmin sonuçları incelendiğinde bazılarında sadece hata değerlendirme ölçütleri kullanılıyorken bazılarında ise sadece doğruluk ölçütlerine göre değerlendirme yapılmıştır. Bu çalışmada hem hata hem de doğruluk ölçütlerine göre modellerin performansı değerlendirilmiş ve hata değerleri oldukça düşük, R^2 değeri oldukça yüksek çıktığı görülmüştür. Elde edilen sonuçlar diğer çalışmalarla kıyaslandığında bu çalışmada YSA'da oluşturulan modelin başarısı oldukça yüksek gözlenmiştir.

Çalışma sonuçlarının makine öğrenmesi yöntemleri kullanılarak yük talep tahmininin modellendiği araştırmalar için en uygun yöntemin belirlenmesi konusunda literatüre katkı sağladığı ve elde edilen başarılı tahmin sonuçlarına göre enerji piyasası yatırımcılarına doğru bir kaynak olacağı düşünülmektedir.

IV. SONUÇ

Yapılan çalışmada çeşitli makine öğrenmesi yöntemleri kullanılarak, Türkiye Elektrik İletim Anonim Şirketinden saatlik periyotlarda elde edilen tüketim verileri ile en doğru tahmini yapan yöntem belirlenmeye çalışılmıştır. Çalışmada, literatürde sık kullanılan makine öğrenimi modellerinden Ridge Regresyon, Lasso Regresyon, Destek Vektör Regresyonu ve YSA kullanılarak performansları incelenmiştir.

Oluşturulan modellerdeki hiper parametre değerleri hataları minimize edecek şekilde ayarlanmış ve başarı performansları kıyaslanmıştır. Çalışmada seçilen yöntemlerde düzenleyici hiper parametreler; Lasso ve Ridge Regresyon için λ , Destek vektör regresyonu için ϵ ve YSA için ise w tahmin doğruluğunu etkileyen faktörlerdir.

Yük talep tahmininde amaç hatayı en aza indirip doğruluğu ve güvenilirliği artırmaktır. Bu çalışmada performans değerlendirme ölçütlerinden hata ölçütü olan RMSE ve MAE, doğruluk ölçütü olan R^2 değeri kullanılmıştır. Deney sonuçları incelendiğinde çalışmada kullanılan makine öğrenmesi algoritmalarından YSA modeli hem hata hem de doğruluk testlerinde daha başarılı sonuçlar vermiştir. Ayrıca çalışmamız literatürdeki benzer çalışmalarla kıyaslandığında doğruluk ölçüt değeri olan R^2 yüksek sonuç vermiştir. İleriki çalışmalarda Makine Öğrenmesi yöntemleri ve Derin Öğrenme yöntemleri kullanılarak performans sonuçlarının incelenmesi planlanmaktadır.

KAYNAKLAR

- [1] Haliloğlu, Y.E., & Tutu, E. B. (2018). Türkiye İçin Kısa Vadeli Elektrik Enerjisi Talep Tahmini. *Journal of Yasar University*, 13-51, 243-255.
- [2] Kell, A.J.M, McGough, A.S., & Forshaw, M., (2021). The impact of online machine-learning methods on long-term investment decisions and generator utilization in electricity markets. *Sustainable Computing: Informatics and Systems*, 30.

- [3] Naik, J., Bisoi, R., & Dash, P.K., (2018). Prediction interval forecasting of wind speed and wind power using modes decomposition based low rank multi-kernel ridge regression. *Renewable Energy*, 129, 357-383.
- [4] Lv, J., Zheng, X., Pawlak, M., Mo, W., & Miskowicz, M. (2021). Very short-term probabilistic wind power prediction using sparse machine learning and nonparametric density estimation algorithms. *Renewable Energy*, 177, 181-192.
- [5] Allee, A., Williams, N.J., Davis, A., & Jaramillo P. (2021). Predicting initial electricity demand in off-grid Tanzanian communities using customer survey data and machine learning models. *Energy for Sustainable Development*, 62, 56-66.
- [6] Yildiz, B., Bilbao, J.I., & Sproul, A.B. (2017). A review and analysis of regression and machine learning models on commercial building electricity load forecasting. *Renewable and Sustainable Energy Reviews*, 73, 1104-1122.
- [7] Bitirgen, K., & Filik, Ü.B. (2020). Electricity Price Forecasting based on XGBooST and ARIMA Algorithms. *BSEU Journal of Engineering Research and Technology*, 1, 1.
- [8] Alsafadi, M., & Filik, Ü.B. (2020). Hourly Global Solar Radiation Estimation Based On Machine Learning Methods in Eskişehir. *Eskişehir Technical University Journal of Science and Technology*, 21(2), 294- 313.
- [9] Yürek, E.Ö., Birant, D., & Yürek, İ. (2021). Wind Power Generation Prediction Using Machine Learning Algorithms. *Dokuz Eylül University Faculty of Engineering Journal of Science and Engineering*, 67, 107-119.
- [10] Ali, S., Mansoor, H., Khan, I., Arshad, N., Khan, M.A., & Faizullah, S. (2020). Short-Term Load Forecasting Using AMI Data. *Electrical Engineering and Systems Science*, Signal Processing August 13, 2020, Cornell University.
- [11] Huo, J., Shi, T., & Chang, J. (2016). Comparison of Random Forest and SVM for Electrical Short-term Load Forecast with Different Data Sources. 7th IEEE International Conference on Software Engineering and Service Science (ICSESS), 26-28 Aug. 2016, Beijing, China.
- [12] Wang, Y., Shen, Y., Mao, S., Chen, X., & Zou, H. (2019). LASSO and LSTM Integrated Temporal Model for Short-Term Solar Intensity Forecasting. *IEEE Internet of Things Journal*, 6, 2.
- [13] Küçük, A. (2019). *Doğrusal Regresyonda Ridge, Liu ve Lasso Tahmin Edicileri Üzerine Bir Çalışma*. Yüksek Lisans Tezi, Hacettepe Üniversitesi, İstatistik Anabilim Dalı, Ankara.
- [14] Shirzadi, N., Nizami, A., Khazen, M., & Bakht, N.M. (2021). Medium-Term Regional Electricity Load Forecasting through Machine Learning and Deep Learning. *Designs*, 5(2), 27.
- [15] Kaur, M., Panwar, S., Joshi, A., & Gupta, K. (2021). *Residential Electricity Demand Prediction using Machine Learning*. International Semantic Intelligence Conference, February 25-27, New Delhi, India.
- [16] Waciko, K.J., & Ismail, B. (2020). Performance of Shrinkage Methods for Forecasting GDP. *International Journal of Advanced Science and Technology*, 29 (5), 7792-7799.
- [17] Portabales, A.R., Nores, M.L., & Arias, J.J.P. (2021). Systematic review of electricity demand forecast using ANN-based Machine Learning algorithms. Preprints (www.preprints.org), Not Peer-Reviewed, Posted: 21 May.
- [18] Khan, P.W., Byun, Y.C., Lee, A.J., Kang, D.H., Kang, J.Y., & Park, H.S. (2020). Machine Learning-Based Approach to Predict Energy Consumption of Renewable and Nonrenewable Power Sources. *Energies*, 13, 2681.
- [19] Mitchell, G., Bahadoorsingh, S., Ramsamooj, N., & Sarmaca., (2017). A Comparison of Artificial Neural Networks and Support Vector Machines for Short-term Load Forecasting using Various Load Types. 2017 *IEEE Manchester PowerTech*, 117044934.
- [20] Mohammad, F., Lee, K.B., & Kim, Y.C., (2018). *Short Term Load Forecasting Using Deep Neural Networks*. International Symposium on Information Technology Convergence, 2018, South Korea.
- [21] Küçük, D., & Gezer, D. (2020). *Enerji Alanındaki Tahmin Problemleri İçin Makine Öğrenmesi ve Derin Öğrenme Yöntemlerinin Kullanılması*. Elektrik İletim ve Üretiminde Enerji Verimliliği Sempozyumu, 2020, Ankara.
- [22] Işıl, M., & Bulut, Y.M. (2021). Farklı Yanlılık Parametreleri İçin Ridge GM Tahmin Edicilerinin Performanslarının Karşılaştırılması. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 8(1), 203-216.
- [23] Yıldırım, A., & Kandemir, S.Y. (2018). Yağış Miktarının Yapay Sinir Ağları ile Tahmini. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 5(2), 97-104.
- [24] TEİAŞ. (2021). Yıllık Rapor. <https://www.teias.gov.tr/tr-TR/turkiye-elektrik-uretim-iletim-istatistikleri>, (Erişim tarihi: 20.05.2021).
- [25] Aydın, D., Kavak A. F., & Toros H. (2015). *Isınma ve Soğuma Derece Günlerin Elektrik Tüketimi Üzerindeki Etkisi*. 7th Atmospheric Sciences Symposium, 2015, İstanbul.

- [26] Nebati, E.E., Taş, M., & Ertaş, G. (2021). Türkiye’de Elektrik Tüketiminde Talep Tahmini: Zaman Serisi ve Regresyon Analizi ile Karşılaştırma. *European Journal of Science and Technology*, 31, 348-357.
- [27] Demirezen, S., & Çetin, M. (2021). Rassel Orman Regresyonu ve Destek Vektör Regresyonu ile Piyasa Takas Fiyatının Tahmini. *Journal of Quantitative Sciences*, 3(1), 1-15.
- [28] Çınaroğlu, S. (2017). Sağlık Harcamasının Tahmininde Makine Öğrenmesi Regresyon Yöntemlerinin Karşılaştırılması. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 22(2), 179-200.
- [29] Demir, Y. (2021). Çoklu Doğrusal Regresyon ve Bazı Cezalı Tahmin Yöntemlerinin İncelenmesi. Gece Kitaplığı, Sosyal ve Beşerî Bilimlerde Teori ve Araştırmalar II, pp.261-276, Chapter 44.
- [30] Yavuz, S., & Deveci, M. (2013). Statiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187.
- [31] Hahn, H., Meyer-Nieberg, S., & Pickl, S. (2009). Electric load forecasting methods: Tools for decision making. *European Journal of Operational Research*, 199(3), 902-907.
- [32] Bekçioğulları, M. F., Dikici, B., Açıkgöz, H., & Keçecioglu, Ö.F. (2021). Güneş Enerjisinin Kısa-Dönem Tahmininde Farklı Makine Öğrenme Yöntemlerinin Karşılaştırılması. *EMO Bilimsel Dergi*, 11, 22.
- [33] Kuşkapan, E., Çodur, M. K., & Çodur, M.Y. (2022). Türkiye’deki Demiryolu Enerji Tüketiminin Yapay Sinir Ağları ile Tahmin Edilmesi. *Konya Journal of Engineering Sciences*, 10(1), 72-84.
- [34] Özkan, E., Güler, E., & Aladağ, Z. (2020). Elektrik Enerjisi Tüketim Verileri İçin Uygun Tahmin Yöntemi Seçimi. *Journal of Industrial Engineering*, 31(2), 198-214.
- [35] Kara, A. (2019). Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini. *Gazi Üniversitesi Fen Bilimleri Dergisi, Part C*, 7(4), 882-892.