



KAMU BİNALARINDA ENERJİ YÖNETİMİ İÇİN MAKİNE ÖĞRENMESİ YAKLAŞIMLARI

Vildan ARSLANTÜRK¹, Betül TURANOĞLU ŞİRİN^{1*}

¹Atatürk University, Faculty of Engineering, Department of Industrial Engineering, 25240, Erzurum, Türkiye

Özet: Modern yaşamın getirdiği yüksek refah standartları, elektrik enerjisini günlük yaşamın vazgeçilmez bir unsuru haline getirmiştir. Enerji politikalarının başarıya ulaşması, enerji talebinin doğru bir şekilde planlanması ve yönetilmesini zorunlu kılmaktadır. Elektrik arz güvenliğinin sağlanması, enerji verimliliğinin artırılması ve buna bağlı olarak enerji maliyetlerinin ekonomik etkisinin azaltılması, doğru enerji talep tahminleri ve etkin karar alma süreçleriyle mümkün olmaktadır. Bu durum, enerji tüketim tahminlerinin stratejik önemini bir kez daha ortaya koymaktadır. Bu çalışmada, Erzurum ilindeki üç farklı kaymakamlık binasının yıllık elektrik tüketimi; uzun dönemli tahmin modelleri (LSTM), k-en yakın komşu (KNN), gradyan destekli karar ağaçları (GBDT), rastgele orman (RF) ve aşırı gradyan artırma (XGBoost) gibi çeşitli makine öğrenmesi teknikleri kullanılarak modellenmiştir. Her bir bina için hesaplanan kök ortalama kare hata (Root Mean Square Error-RMSE), ortalama mutlak hata (Mean Absolute Error- MAE) ve ortalama mutlak yüzde hata (Mean Absolute Percentage Error- MAPE) performans metrikleri, yöntemlerin doğruluğu ve etkinliği açısından karşılaştırmalı bir analiz sunmaktadır. Elde edilen sonuçlar, bazı yöntemlerin yüksek tahmin performansı sergilediğini ve kamu binalarındaki enerji yönetimi süreçlerine önemli katkılar sağlayabileceğini göstermektedir. Bu çalışma, yalnızca kaymakamlık binaları için değil, aynı zamanda diğer kamu binalarında enerji yönetimine yönelik politikaların geliştirilmesine ve uygulanmasına rehberlik edebilecek nitelikte bir örnek teşkil etmektedir.

Anahtar kelimeler: Enerji verimliliği, Enerji yönetimi, Elektrik tüketim tahmini, Makine öğrenmesi yaklaşımları

Machine Learning Approaches for Energy Management in Public Buildings

Abstract: The high standards of welfare achieved in modern life have made electrical energy an indispensable element of daily activities. The success of energy policies depends on accurate planning and effective management of energy demand. Ensuring electricity supply security, improving energy efficiency, and reducing the economic impact of energy costs all rely on precise energy demand forecasts and efficient decision-making processes. This underscores the strategic importance of energy consumption forecasting. In this study, the annual electricity consumption of three district governorship buildings in Erzurum province was modeled using various machine learning techniques, including long short-term memory (LSTM), k-nearest neighbor (KNN), gradient-boosted decision trees (GBDT), random forest (RF), and extreme gradient boosting (XGBoost). Performance metrics such as Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE) were calculated for each building, offering a comparative analysis of the accuracy and efficiency of these methods. The results demonstrate that certain methods achieve high forecasting performance, providing valuable insights for energy management processes in public buildings. This study serves as an example that can inform the development and implementation of energy management policies not only for district governorship buildings but also for other public facilities.

Keywords: Energy efficiency, Energy management, Electricity consumption prediction, Machine learning approaches

*Sorumlu yazar (Corresponding author): Atatürk University, Faculty of Engineering, Department of Industrial Engineering, 25240, Erzurum, Türkiye

E mail: b.turanoglu@atauni.edu.tr (B. TURANOĞLU ŞİRİN)

Vildan ARSLANTÜRK



<https://orcid.org/0009-0005-7349-6099>

Betül TURANOĞLU ŞİRİN



<https://orcid.org/0000-0002-7910-6312>

Gönderi: 16 Mayıs 2025

Received: May 16, 2025

Kabul: 26 Temmuz 2025

Accepted: July 26, 2025

Yayınlanma: 15 Eylül 2025

Published: September 15, 2025

Cite as: Arslantürk V, Turanoğlu Şirin B. 2025. Machine learning approaches for energy management in public buildings. BSJ Eng Sci. 8(5): 1415-1428.

1. Giriş

Enerji ihtiyacı her geçen gün kritik ihtiyaçlar listesinde üst sıralara doğru ilerlemektedir. Artan enerji ihtiyacını karşılamak üzere yeni enerji kaynakları bulunması gerekliliğinin yanı sıra, enerjinin üretilmesi, güvenli iletilmesi ve son kullanıcıya kadar ulaştırılan enerjinin verimli kullanılması son derece önemlidir.

Enerji açısından verimli ve sürdürülebilir binaların inşa edilmesi, çevrenin korunması açısından elzem hale gelmiştir. Çünkü binalardaki verimsizlik, dünya genelindeki enerji tüketiminin ve sera gazı emisyonlarının önemli bir kısmına neden olmaktadır. Binalar tarafından

tüketilen yüksek miktardaki enerji; iklim değişikliği, hava kirliliği ve termal kirlilik gibi ciddi çevre sorunlarına yol açmakta, bu da insanlığın varlığı üzerinde önemli etkiler yaratmaktadır. Son yıllarda, nüfus artışı ve hızlı kentleşme nedeniyle binalardaki enerji talebi önemli ölçüde artmıştır (Olu-Ajayi vd., 2022).

Bina enerji verimliliğini daha iyi anlamaya yönelik çalışmalar, birçok araştırmacının ilgisini çekmiş ve makine öğrenmesi aracılığıyla yeni gelişmelerin ortaya çıkmasına neden olmuştur. Bina enerji tüketimi tahmini, enerji tasarrufu sağlamak ve enerji kullanımını azaltmak için daha iyi kararlar alınmasında büyük önem



taşımaktadır. Ancak, hava koşulları, binanın fiziksel özellikleri ve kullanıcıların enerji kullanım alışkanlıkları gibi pek çok faktör enerji tüketimini etkilediğinden, enerji tahmini hâlâ karmaşık bir süreç olmaya devam etmektedir (Olu-Ajayi vd., 2022).

Doğru elektrik tüketimi tahmini, ulusal veya bölgesel düzeyde elektrik arz ve talep dengesi ile enerji üretim tesislerinin planlanması açısından oldukça önemlidir. Bu tahminler, gereksiz enerji üretimini ve olası güç kesintilerini önlemeye yardımcı olabilir. Örneğin; elektrik talebi olduğundan fazla tahmin edilirse, gereksiz enerji üretim tesislerinin kurulmasına ve dolayısıyla israf edilen kaynaklara yol açabilir. Öte yandan, elektrik talebinin olduğundan az tahmin edilmesi durumunda, yetersiz üretim kapasitesi güç kıtlığına ve elektrik kesintilerine neden olabilir (Hwang vd., 2020).

Hem ev ekonomisinde hem de ülke ekonomisinde enerji maliyetleri önemli bir yere sahiptir. Cumhurbaşkanlığı tarafından 17.05.2024 tarihli ve 32549 sayılı Resmî Gazete 'de yayımlanarak yürürlüğe giren 2024/7 sayılı ve "Tasarruf Tedbirleri" konulu Genelge ile enerji alımları ile ilgili maddeler de yer almaktadır. Enerjiyi verimli kullanmak için atılacak ilk adım enerji ihtiyacının bilinmesi ve doğru bir planlama yapılmasıdır.

Literatürde elektrik enerjisi tahmini yapılan birçok çalışma mevcuttur. Voronin ve Partanen (2014) tarafından yapılan çalışmada dalgacık dönüşümleri, ARIMA modelleri ve yapay sinir ağlarını (YSA) birleştirerek elektrik talebini ve fiyatını eş zamanlı tahmin eden bir model ortaya koymuştur. Cao vd. (2014) destek makinesi regresyonu (SVR) ile kuantum davranışlı parçacık sürüsü optimizasyonu (PSO) metodları birleştirilmiş ve ekonomiyle ilgili sekiz adet girdi kullanan bir enerji talep tahmin modeli önermişlerdir. Başoğlu ve Bulut (2017) elektrik tüketim tahmini için Türkiye'nin piyasa ve mevsim koşullarını da dikkate alan yapay sinir ağları ile uzman sistemlerin birlikte kullanıldığı bir hibrit model geliştirmişlerdir. Çayır vd. (2018) tarafından yapılan çalışmada, Londra'da bulunan 30 farklı evden Kasım 2011 ile Şubat 2014 zaman aralığında alınan yarım saatlik tüketim verilerinden oluşan ve bir milyon adet gözlem içeren bir veri kümesi ile yapay sinir ağları, destek vektör makineleri ve rassal orman modellerini kullanarak kısa vadeli bir tüketim tahmini yapılmıştır. He ve Lin (2018) Çin'in enerji yapısı ve talebini tahmin eden en uygun modeli saptamak amacıyla ADLeMIDAS isimli yaklaşımı geliştirmişlerdir. Wang vd. (2019) tarafından yapılan çalışmada, gerçek ısıtma enerjisi verileri ile rastgele orman (RF), aşırı gradyan artırma (XGBoost), gradyan artırma karar ağacı (GBDT), yapay sinir ağı (YSA) ve destek vektör regresyonu (SVR) uygulanarak tahmin modelleri oluşturulmuştur. Li ve Jones (2019) trafo merkezinin maksimum talebini modellemek için; müşteri sayısı, ortalama talep ve kurulu fotovoltaiik kapasite faktörlerinin bir eğilim fonksiyonu olarak aşırı değer teorisinden hareketle bir nokta süreci modeli önermişlerdir. Kazemzadeh vd. (2020) araştırmalarında,

enerji talebi tahmini için zaman serisi ve veri madenciliği tekniğine dayalı uzun vadeli hibrit bir tahmin modeli geliştirmişlerdir. Wang vd. (2020) bina enerji tüketimini tahmin etmeyi sağlayacak iyileştirilmiş hibrit bir makine öğrenmesi (Machine Learning-ML) modeli önermişlerdir. Nebati vd. (2021), Türkiye'nin 1970-2019 yılları arasındaki yıllık frekanstaki elektrik tüketim verilerini kullanarak regresyon analizi ve ARIMA'nın IMA modeli ile tüketim tahmini yapmışlardır. Filippov vd. (2021) sistem analizi yöntemlerine dayalı bir enerji talebi tahmin modeli geliştirmişlerdir. İftikhar vd. (2023) çalışmalarında, saatlik elektrik talep tahmininin detaylı bir analizini sunmak üzere yeni ayrıştırma metodlarını çeşitli tek değişkenli ve çok değişkenli zaman serisi yöntemleriyle kıyaslamışlardır. Zhou vd. (2023) hem güç üretimini hem de güç tüketimini tahmin etmek amacıyla arz-talep etkileşimi olan verimli bir model geliştirmişlerdir. Li vd. (2024) önerdikleri genetik algoritma tabanlı destek vektör makinesi yöntemiyle elektrik talep tahmini yapmışlardır. Nikseresht ve Amindavar (2024) çalışmalarında, enerji tüketim tahmini için istatistiksel yöntemlerden faydalanan ARFIMA temelli yeni bir hibrit model sunmuşlardır. Li vd. (2024), elektrik tüketim tahmini için CatBoost ve XGBoost yöntemlerini hibrit olarak kullanmış ve oldukça yüksek doğrulukla tahmin değerleri elde etmişlerdir. Lei vd. (2024), bina enerji tüketimi tahmini için EWKM, rastgele orman, SSA ve BiLSTM tabanlı evrimsel bir derin öğrenme modeli önermişlerdir. Cui vd. (2024), makine öğrenmesi ve SHAP kullanarak farklı konut bina tipleri için enerji tüketimi tahmini ve hane halkı özellik analizi yapmışlardır. Grveón vd. (2024), elektrik tüketim tahmini için klasik istatistik ve makine öğrenmesi algoritmalarını melez olarak kullanmışlardır. MAPE değeri olarak %3,2'nin altında bir tahmin doğruluğu elde etmişlerdir. Hsu vd. (2025), binalarda değişken soğutucu akışlı (VRF) sistemlerin güç tüketimi tahmini için LSTM ve ANN modellerinin karşılaştırmalı analizine dayalı bir çalışma yapmışlardır. Uddin vd. (2025), enerji tüketim tahmini için ajan tabanlı modelleme ve makine öğrenmesi yaklaşımını içeren hibrit bir yaklaşım önermişlerdir. Wang vd. (2025), küçük veri kümelerinde özellik seçimi ve elektrik tüketimi tahmini yapmak için LSTM tabanlı bir çerçeve geliştirmişlerdir. Kim vd. (2025) çalışmalarında, farklı yapay sinir ağı modelleri kullanılarak bir binadaki elektrik tüketiminin tahmin edilmesinde veri normalleştirme yöntemlerinin etkisini araştırmışlardır. Dong vd. (2025), mekansal-zamansal korelasyon ve elektrik tüketim davranış bilgilerine dayalı elektrik yükü tahmini için LSTM tabanlı yeni bir yöntem geliştirmişlerdir. Botman vd. (2025), bireysel hanelerin elektrik tüketiminin kısa vadeli tahmini için global olasılıksal bir yaklaşım önermişlerdir. Yukarıda açıklanan tüm çalışmalar, Tablo 1'de özet olarak gösterilmiştir.

Tablo 1. Literatürde incelenen çalışmalar

Yazar(lar)	Yıl	Çalışma Konusu	Yöntem
Voronin ve Partanen	2014	Elektrik talebi ve fiyatının eş zamanlı tahmini	Dalgacık dönüşümleri + ARIMA + YSA
Cao vd.	2014	Enerji talep tahmini	SVR + Kuantum davranışlı PSO
Başoğlu ve Bulut	2017	Türkiye için elektrik tüketimi tahmini	YSA + Uzman Sistem
Çayır vd.	2018	Londra'daki evlerde kısa vadeli tüketim tahmini	YSA, SVM, Rassal Orman
He ve Lin	2018	Çin enerji yapısı ve talep tahmini	ADLeMIDAS modeli
Wang vd.	2019	Isıtma enerjisi talep tahmini	RF, XGBoost, GBDT, YSA, SVR
Li ve Jones	2019	Trafo merkezi maksimum talep modellemesi	Nokta süreci modeli + EVT
Kazemzadeh vd.	2020	Uzun vadeli enerji talep tahmini	Zaman serisi + Veri madenciliği (Hibrit)
Wang vd.	2020	Bina enerji tüketimi tahmini	Geliştirilmiş hibrit ML modeli
Nebati vd.	2021	Türkiye için elektrik tüketim tahmini	Regresyon + ARIMA (IMA modeli)
Filippov vd.	2021	Enerji talebi tahmini	Sistem analizi yöntemleri
Iftikhar vd.	2023	Saatlik elektrik talep tahmini	Yeni ayrıştırma + zaman serisi yöntemleri
Zhou vd.	2023	Güç üretim ve tüketim tahmini	Arz-talep etkileşimli model
Li vd.	2024	Elektrik talep tahmini	Genetik algoritma + SVM
Nikseresht ve Amindavar	2024	Enerji tüketimi tahmini	ARFIMA temelli hibrit model
Li vd.	2024	Elektrik tüketim tahmini	CatBoost + XGBoost (Hibrit)
Lei vd.	2024	Bina enerji tüketimi tahmini	EWKM + RF + SSA + BiLSTM
Cui vd.	2024	Konut tipi tüketim tahmini ve özellik analizi	ML + SHAP
Grveón vd.	2024	Elektrik tüketim tahmini	Klasik istatistik + ML
Hsu vd.	2025	VRF sistemlerinde güç tüketimi tahmini	LSTM ve ANN
Uddin vd.	2025	Enerji tüketimi tahmini	Ajan tabanlı modelleme + ML
Wang vd.	2025	Küçük veri ile tahmin & öznitelik seçimi	LSTM tabanlı çerçeve
Kim vd.	2025	Normalleştirme yöntemlerinin YSA'ya etkisi	Farklı YSA modelleri
Dong vd.	2025	Elektrik yükü tahmini	LSTM + mekansal-zamansal korelasyon
Botman vd.	2025	Hane bazlı kısa vadeli tüketim tahmini	Global olasılıksal model

Bu çalışmada; kamuya ait kaymakamlık binalarının elektrik enerjisi ihtiyacını isabetli bir şekilde tahmin etmek, yapılan tahmin ile karar alma süreçleri için kaynak oluşturmak ve kamu kaynaklarının verimli kullanılmasını teşvik etmek amaçlanmıştır. Bu amaca ulaşmak için uzun dönemli tahmin modelleri (LSTM), k-en yakın komşu (KNN), gradyan destekli karar ağaçları (GBDT), rastgele orman (RF) ve XGBoost gibi makine öğrenmesi teknikleri kullanılmıştır.

Bu çalışmanın ana katkıları aşağıdaki gibi sıralanabilir:

- LSTM, KNN, GBDT, RF ve XGBoost gibi modellerin performansları, üç farklı kaymakamlık binası üzerinden değerlendirilmiştir.
- Elde edilen tahmin sonuçlarıyla, bazı makine öğrenmesi yöntemlerinin kamu binalarında yüksek doğrulukla enerji tahmini yapabildiği ortaya konmuştur. Bu da karar vericilere daha etkili enerji yönetimi stratejileri geliştirme fırsatı sunmaktadır.
- Kamu binalarının enerji yönetiminde makine öğrenmesi tabanlı yaklaşımların uygulanabilirliğini

göstermiş ve bu alanda politika geliştirme süreçlerine katkı sağlamıştır.

- Yerel düzeyde (Erzurum ili) gerçekleştirilen uygulama ile Türkiye'deki benzer kamu yapıları için genellenebilir örnek bir model oluşturulmuştur.

2. Materyal ve Yöntem

2.1. Veri Seti

Bu çalışmada kullanılan veri seti, Erzurum ilinde bulunan üç farklı kaymakamlık binasının 2013-2023 yılları arasındaki aylık elektrik tüketim değerleri, Erzurum iline ait ısıtma derece gün (HDD) değerleri ve aylık ortalama bulut kapallılığı (8 Okta cinsinden) değerlerinden oluşmaktadır. Toplamda 132 adet örnekten oluşan bu veri setinde tespit edilen birkaç eksik veri sütun ortalaması ile giderilmiştir. Kullanılan makine öğrenmesi yöntemlerinde veri setinin %80'lik kısmı eğitim için, %20'lik kısmı ise test için ayrılmıştır.

2.2. Makine Öğrenmesi Yöntemleri

Bu çalışmada, veri setine birden fazla makine öğrenmesi yöntemi uygulanmıştır. Bunlar; uzun dönemli tahmin modelleri (LSTM), k-en yakın komşu (KNN), gradyan destekli karar ağaçları (GBDT), rastgele orman (RF) ve aşırı gradyan artırma (XGBoost) yöntemleridir. Bu yöntemlerin tamamı, gözetimli öğrenme algoritmalarıdır. Söz konusu yöntemler, geçmişe ait etiketli verilerden (girdi özellikleri ve karşılık gelen enerji tüketimi değerleri) öğrenerek gelecekteki enerji tüketimini tahmin etmeye yönelik olarak eğitilmiştir.

2.2.1. Uzun dönemli tahmin modelleri (Long Short Term Memory-LSTM)

Yinelemeli sinir ağları (Recurrent Neural Networks-RNN), art arda dizilmiş olan sinir ağları arasında geçmiş ve geleceğe ilişkin bilgi akışının sağlandığı, bu akışın sürekli olarak tekrarlandığı ve böylece geçmişe ait veriler ile geleceğe yönelik tahmin çalışmalarında kullanılan elverişli bir yapay sinir ağı modelidir (Akkurt ve Sarıççek, 2024). Ancak RNN'de uzun zaman serilerinin eğitiminde kaybolan veya patlayan gradyan problemleri ortaya çıkmaktadır. Bu sorunu çözmek amacıyla, Hochreiter ve Schmidhuber (1996) tarafından sınırlı veri setlerindeki uzun süreli bağımlılıkları öğrenme yeteneği bulunan ve RNN'nin özel bir türü olan LSTM (Long Short Term Memory) yöntemi önerilmiştir (Hochreiter ve Schmidhuber, 1997; Goodfellow vd. 2016).

LSTM, tekrarlayan bir sinir ağı uzantısı olup uzun vadeli bilgileri hatırlamak üzere tasarlanmış bir hafıza hücresi içermektedir. Bu hücre, bilgiyi uzun bir süre muhafaza etmek üzere kullanılan bir depo görevi görmektedir. LSTM bellek hücresi, bilgiyi 0-1 arasında bir sayıya dönüştürerek bileşenlere verilecek bilgileri açıklayan bir sigmoid katmanı ve bir çarpandan müteşekkil hücre haline bilgi ekleme ve çıkarma kabiliyetine sahip olan kapıları birleştirmektedir. Sigmoid katmanı çıktısının 0 olması hiçbir bilginin geçişine izin verilmeyeceği, 1 olması ise tüm bilgilerin geçişine izin verileceği anlamı taşımaktadır (Yazıcı, 2021).

2.2.2. K-en yakın komşu (K-Nearest Neighbor-KNN) algoritması

KNN algoritması, mevcut veri setine katılan yeni veriyi en yakınındaki komşularına göre sınıflayan basit, güçlü ve parametrik olmayan bir yöntemdir (Peterson, 2009). KNN yönteminde, veri kümesine gelen yeni bir verinin ait olduğu sınıfı saptamak için sınıfı belli olan k adet komşusuna olan yakınlığı ölçülür (Özkan, 2008). Örnekler arasındaki mesafenin hesaplanmasında genellikle Öklid, Manhattan ve Chebyshev uzaklık ölçütleri esas alınır (Peker vd., 2017). Uzaklık ölçütü yardımıyla yeni verinin veri setinde yer alan tüm gözlem değerlerine olan yakınlığının hesaplanmasından sonra yakınlıklar sıralanır, en yakın k adet gözlem dikkate alınarak değerlendirilir ve yeni değer ile sınıflandırılmış veri arasındaki benzerliğe göre bir karara varılır. k değeri sınıflandırmada dikkate alınacak olan komşu sayısıdır. Veri setinin büyüklüğüne göre değişmekle birlikte 3, 5 ve 7 en sık tercih edilen k değerleridir (Silahtaroglu, 2008). k

değerinin tek sayı seçilmesindeki amaç eşitlik durumu olmasını önlemektir (Balaban ve Kartal, 2018). k değerine karar verilmesinde farklı yöntemler bulunmakla birlikte, en basit yöntem algoritmanın farklı k değerleriyle bir çok kez çalıştırılması sonucunda performansı yüksek olanın seçilmesidir (Guo vd., 2003). Veri boyutu büyüdükçe KNN algoritmasının ihtiyaç duyduğu bellek kapasitesi artacağı için daha az sayıda veri ve ilgili değişken ile sınıflandırma yapılması tavsiye edilmektedir. k değeri büyüdükçe karar sınırları düzgünleşir, ancak hesaplama yükü de artar. k değeri küçüldükçe de algoritmanın çalışma hızı yükselir, ancak bu durum gürültülü veriye hassasiyeti artırır (Taşcı ve Onan, 2016). KNN yöntemi her bir verinin sınıfını belirlemek için tüm verileri taradığı için işlem süresi uzundur. (Khan vd., 2002). Eğitim aşamasının bulunmaması yöntemin avantajı, sınıfı belirlenecek veri için tüm verinin taranması ise dezavantajdır (Gök, 2017). Küçük ve orta büyüklükteki veri kümelerinde tercih edilerek bu dezavantaj bertaraf edilebilir. Yöntemin uygulanmasının kolay olması ve basit bir matematiksel temele dayanması tahmin çalışmalarında oldukça farklı alanlardaki kullanımını yaygınlaştırmıştır.

2.2.3. Gradyan destekli karar ağaçları (Gradient-Boosted Decision Trees-GBDT)

Karar ağaçları, hesaplama maliyetlerinin düşük ve kolay yorumlanabilir olması dolayısıyla sınıflandırma ve tahmin çalışmalarında oldukça sık kullanılmaktadır (Yazıcı, 2021). GBDT, tahminlerini kademeli bir şekilde sırasıyla yapan ve zayıf öğreniciler tarafından yapılan tahminleri birleştirerek güçlü bir son tahmin elde etmeyi amaçlayan bir topluluk algoritmasıdır (Hastie vd., 2009; Balta, 2024). Genellikle ilk öğrenici ortalama bir değeri veya yaygın bir sınıfı temsil eden basit bir tahmin yapar ve sonraki her bir yeni ağaç son ağacın hatalarını düzeltmeye odaklanarak öğrenmeye devam eder. Böylece her adımda daha isabetli tahminler yapılır (Mercan, 2023; Gür vd., 2024). Belirli sayıda iterasyona ulaşıncaya veya tahmin edilen ile gerçek değer arasındaki fark (hata) eşik değerin altına düşünceye dek bu işlem tekrar edilir (Mayr vd., 2014). GBDT yöntemi, tek bir karar ağacına göre büyük ve karmaşık veri setlerini işleme esnekliği, tahmin hızı ve doğruluğu gibi güçlü yönleri ile öne çıkmaktadır (Aydın, 2023). Sınıflandırma ve regresyon problemlerinde etkili olan yöntem düşük hata oranları sağlarken yüksek yorumlamaya da olanak tanımaktadır (Wang ve Mamo, 2020).

2.2.4. Rastgele orman (Random Forest-RF)

RF yöntemi, karar ağacı temelli bir denetimli öğrenme yöntemidir. (Gültepe, 2019). RF, tek bir karar ağacı ile bir sonuç elde etmek yerine birden çok karar ağacı oluşturmada ve böylece zayıf öğrenicilerden güçlü bir öğreniciye vararak çok daha isabetli sonuçlar üretmektedir (Dev ve Eden, 2019). Bu yöntem, her bir karar ağacından bağımsız tahminler elde eder ve bu özellik yöntemin belli bir özelliğe çok güvenmesinin önüne geçerek tüm özelliklerin adil bir şekilde kullanılmasını sağlar (Breiman, 2001; Nacar ve Erdebili, 2021). Karar ağaçlarından ayrı ayrı elde edilen sonuçlar

birleştirilerek orman adına tek ve daha güvenilir bir karar verilir (Gök, 2017). Nihai tahmin ormandaki her bir ağacın gerçekleştirdiği tahminlerin ortalaması alınmak suretiyle elde edilmektedir (Kulkarni ve Sinha, 2012).

RF yönteminin aşırı öğrenme problemi yoktur. Büyük boyutlu veri kümelerine uygulanabilir olup gürültülü, aykırı veya eksik verilere karşı da oldukça güçlüdür (Sinap, 2024). Ayrıca, çok hızlıdır ve istenilen ağaç sayısı ile çalıştırılabilir.

2.2.5. Aşırı gradyan artırma (Extreme Gradient Boosting-XGBoost)

Chen ve Guestrin (2016) tarafından önerilen XGBoost yöntemi, sınıflandırma ve regresyon problemlerinde yaygın bir şekilde kullanılan gradyan temelli bir karar ağacı algoritmasıdır. XGBoost, klasik gradyan artırma algoritmasının yapılan bazı düzenlemelerle optimize edilmiş bir versiyonudur ve daha yüksek performansla çalışmaktadır.

XGBoost, temel sınıflandırıcıları doğrusal olarak üst üste bindirerek sıralı bir karar ağacı oluştur ve birden fazla zayıf öğrenciden faydalanarak güçlü bir model ortaya koyar (Mercan, 2023). Yapısında yer alan zayıf öğrenciler verinin alt kümeleri üzerinde eğitilir, modelin hatalarını azaltmak üzere her adımda yeni bir model ekler ve böylece güçlü bir öğrenci meydana getirilir (Man vd., 2023). XGBoost, amaç fonksiyonunu genişleterek algoritmanın hem doğruluğunu hem de hızını artırır (Chen ve Guestrin, 2016).

Bu yöntemin temeli, kayıp fonksiyonunu mümkün olduğunca azaltmaya ve daha iyi bir karar ağacı oluşturmaya dayanmaktadır. Bu durum yöntemi alternatiflerine göre daha etkili ve hızlı kılmaktadır (Demolli vd., 2019; Yelgeç ve Bingöl, 2022). Klasik yöntemlere göre daha uzun bir eğitim süresine ihtiyaç duymakla birlikte, büyük boyutlu verilerde ve karmaşık problemlerde gösterdiği yüksek performans XGBoost'u yüksek ölçekli proje ve veri bilimi uygulamalarında popüler hale getirmektedir (Eşidir, 2025). Diğer avantajları ise aşırı öğrenmeye dirençli olması, boş/kayıp verileri doğru yönetebilmesi ve hızlı olmasıdır. (Aydın, 2023).

2.3. Performans Metrikleri

Tahmin modellerinden birini seçerken yaygın olarak kabul edilen önemli kriterlerden biri, modelin verilere uygunluğu ve tahmin başarısının yüksek olmasıdır. Bu doğrultuda, modellerin tahmin doğruluklarını karşılaştırmak için çeşitli istatistiksel yöntemler kullanılmaktadır (Sofyalıoğlu ve Öztürk, 2013).

Tahmin doğruluğunu değerlendirmede sıklıkla başvurulan temel ölçütler ise şunlardır (Sofyalıoğlu ve

Öztürk, 2013):

- Kök Ortalama Kare Hata (Root Mean Squared Error - RMSE)
- Ortalama Mutlak Hata (Mean Absolute Error - MAE)
- Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error -MAPE)

$$RMSE = \sqrt{(1/n) \sum (y_i - \hat{y}_i)^2} \quad (1)$$

$$MAE = (1/n) \sum |y_i - \hat{y}_i| \quad (2)$$

$$MAPE (\%) = (1/n) \sum |(y_i - \hat{y}_i) / y_i| \times 100 \quad (3)$$

Burada;

y_i : Gerçek değer

$\hat{y}_i$: Tahmin edilen değer

n: Veri sayısı


Tahmin etkinliğini değerlendirmek için kullanılan tüm ölçütlerde hedef, en düşük RMSE, MAE ve MAPE değerlerine sahip bir tahmin modeline ulaşmaktır (Çuhadar, 2006). Bu ölçütler arasında, tahmin hatalarını yüzde olarak ifade etmesi nedeniyle MAPE'nin tek başına anlamlı bir değerlendirme kriteri olması, diğer ölçütlere göre bir avantaj sağlamaktadır.

Witt ve Witt (1991), MAPE değerine göre tahmin modellerini şu şekilde sınıflandırmıştır: %10'un altındaki değerler "yüksek doğruluk", %10 ile %20 arasındaki değerler ise "doğru tahmin" kategorisine girmektedir. (Witt ve Witt, 1991; Sofyalıoğlu ve Öztürk, 2013).

Bu çalışmada, kullanılan bütün yöntemlerin etkinliği RMSE, MAE ve MAPE değerlerine göre hesaplanmıştır.

3. Bulgular ve Tartışma

Bu çalışmada, Erzurum ilinde bulunan üç farklı kaymakamlık binası (Bina-1, Bina-2 ve Bina-3) için 2013-2023 yılları arasındaki aylık elektrik tüketim değerleri, aylık ortalama ısıtma derecesi gün (HDD) değerleri ve aylık ortalama bulut kapallılığı (8 Oka cinsinden) değerleri kullanılarak elektrik tüketim tahmini yapılmıştır. Tahminde kullanılan makine öğrenmesi yaklaşımları LSTM, KNN, GBDT, RF ve XGboost yöntemleridir. Bu yöntemler, varsayılan parametre ayarlarını kullanmak için scikit-learn Python paketinde kodlanmış ve çalıştırılmıştır. Elde edilen sonuçlar Tablo 2, Tablo 3 ve Tablo 4'te verilmiştir. Bu tablolarda, tüm yöntemlere ait RMSE, MAE ve MAPE değerleri bulunmaktadır. Ayrıca Şekil 1, kullanılan metodolojinin akış şemasını göstermektedir.



Şekil 1. Kullanılan metodolojinin akış şeması.

Tablo 2. Bina-1 için yöntemlerin performans karşılaştırması

Yöntemler	RMSE	MAE	MAPE (%)
LSTM	490,66	439,64	8,34
KNN (k=3)	1194,55	927,14	13,08
GBDT	1277,71	1008,4	14,11
RF	1267,61	1009,38	14,29
XGBoost	1344,41	1049,70	15,34

Tablo 3. Bina-2 için yöntemlerin performans karşılaştırması

Yöntemler	RMSE	MAE	MAPE (%)
LSTM	2792,74	2387,44	8,58
KNN (k=6)	7041,25	4891,49	12,50
GBDT	5381,97	4059,40	10,70
RF	8226,91	5867,01	14,84
XGBoost	8759,37	6158,82	15,94

Tablo 4. Bina-3 için yöntemlerin performans karşılaştırması

Yöntemler	RMSE	MAE	MAPE (%)
LSTM	924,36	861,48	11,18
KNN (k=4)	1004,72	745,68	9,64
GBDT	970,27	731,46	9,48
RF	1065,47	811,58	10,42
XGBoost	1316,85	948,19	11,90

Tablo 2’de görüldüğü gibi, Bina-1 için en iyi performansı özellikle zaman serisi verilerinde güçlü olan LSTM modeli göstermiştir. KNN algoritması, LSTM’ye kıyasla

daha düşük bir performans sergilerken, ağaç tabanlı yöntemler (GBDT, RF, XGBoost) daha yüksek hata değerleriyle geride kalmıştır. Bu durum, elektrik tüketiminin geçmiş verilere dayalı zaman serisi yapısını yansıtırken, LSTM’nin bu tür verilere olan üstünlüğünü ortaya koymaktadır. Genel olarak, LSTM’nin Bina-1’in elektrik tüketim tahmini için en uygun model olduğu söylenebilir.


Tablo 3’de Bina-2 için çalıştırılan yöntemlerin sonuçları gösterilmiştir. Bu sonuçlara göre, yine LSTM yöntemi diğer yöntemlere kıyasla en düşük hatayı sağlayarak en iyi performansı sergilemiştir. GBDT yöntemi, daha düşük doğruluğa sahip olsa da LSTM’nin hemen ardından gelmiştir. KNN, RF ve XGBoost ise tahmin performansı açısından diğerlerinden geride kalmıştır. Özellikle RF ve XGBoost’un yüksek hata metrikleri, bu modellerin bu bina için daha az etkili olduğunu ortaya koymaktadır.

Tablo 4 ise, Bina-3 için kullanılan yöntemlerin performansını göstermektedir. Bu tablodaki sonuçlar, tahmin doğruluğu açısından diğer binalara göre farklı bir dengeyi ortaya koymaktadır. LSTM, RMSE ve MAE açısından diğer yöntemlere yakın değerler sunarken, MAPE (%11.18) ile özellikle göreceli hata oranında daha düşük performans göstermiştir. Bu kez GBDT (%9.48) ve KNN (%9.64) MAPE açısından daha iyi sonuçlar vererek dikkat çekmiştir. Ancak RF ve özellikle XGBoost, daha yüksek hata metrikleriyle diğer yöntemlerin gerisinde kalmıştır.


Şekil 2 ve Şekil 3’deki grafikler, sırasıyla Bina-1 ve Bina-2 için en düşük hata değerine sahip olan LSTM modelinin tahminlerini göstermektedir. Bu tahminlerin

genel olarak gerçek tüketim değerlerini iyi takip ettiği görüldü de, ani dalgalanmalardan kaynaklı sapmalar mevcuttur. Geleceğe yönelik tahminler daha stabil bir yapı sergilemekte, ancak uzun vadeli mevsimsellik ve trendleri yeterince yansıtmadığı dikkat çekmektedir. Bunların temel nedeni, veri setindeki tüketim verilerinin mevsimsellik dışında başka faktörlerden de etkilenebileceğini göstermektedir. Örneğin; hava durumu, ekonomik koşullar, pandemi gibi olağanüstü durumlar tüketimde ciddi dalgalanmalara yol açabilir. Bazı ayların değerleri aşırı yüksek veya düşük olabilir, bu da modelin genelleme yeteneğini zorlaştırabilir.


Şekil 4 ise, Bina-3 için en düşük hata değerini veren GBDT modelinin test setindeki elektrik tahmin sonuçlarını göstermektedir. Buna göre, GBDT modelinin genel eğilimleri yakalamakta başarılı olduğu söylenebilir. Özellikle bazı zirve noktalarında tahminlerin gerçek değerlere oldukça yakın olduğu dikkat çekmektedir. Ancak, model bazı durumlarda dalgalanmaları tam olarak yakalayamamıştır. Bu durum, modelin uç değerlere yeterince duyarlı olmadığını göstermektedir. Buna rağmen, GBDT ile yapılan tahminler gerçek değerlerin ortalamasına doğru yakınsama eğilimindedir.



Şekil 2. Bina-1'in LSTM yöntemine göre aylık elektrik tüketim tahmini.




Şekil 3. Bina-2'nin LSTM yöntemine göre aylık elektrik tüketim tahmini.




Şekil 4. Bina-3'ün GBDT yöntemi ile test setindeki elektrik tüketim tahmini sonuçları.

Şekil 5, Şekil 6 ve Şekil 7, sırasıyla Bina-1, Bina-2 ve Bina-3 için test setindeki gerçek değerler ile tahmin değerlerin RF, KNN, GBDT ve XGboost yöntemlerine göre karşılaştırılmasını göstermektedir. Bu şekillere bakıldığında genel olarak, söz konusu yöntemlerin


tahmin değerleri birbirlerine oldukça yakındır. Bunun dışında gerçek değerler ile tahmin değerleri arasında, bazı noktalar hariç diğer noktalarda önemli bir fark olmadığı söylenebilir.



Şekil 5. Bina-1 için test setindeki gerçek değerler ile tahmin değerlerinin yöntemlere göre karşılaştırılması.




Şekil 6. Bina-2 için test setindeki gerçek değerler ile tahmin değerlerinin yöntemlere göre karşılaştırılması.




Şekil 7. Bina-3 için test setindeki gerçek değerler ile tahmin değerlerinin yöntemlere göre karşılaştırılması.

Şekil 8, Şekil 9 ve Şekil 10, sırasıyla Bina-1, Bina-2 ve Bina-3 için tüm yöntemlerin performans metriklerine göre karşılaştırılmasını göstermektedir. Şekil 8'e göre, Bina-1 için en iyi yöntem olan LSTM modeli ile diğer yöntemlere göre oldukça düşük performans değerleri elde edildiği söylenebilir. Şekil 9'a göre, Bina-2 için yine en iyi performans değerleri LSTM modeli ile elde edilmiştir. Bu modele en yakın değerler, GBDT yöntemi tarafından üretilmiştir. Şekil 10'a bakıldığında ise, Bina-


3 için kullanılan tahmin modellerine ait performans metriklerinden özellikle MAPE değerinin tüm yöntemlerde birbirine çok yakın olduğu görülmektedir. Fakat yine en iyi MAPE değeri (%9,48), GBDT yöntemi ile elde edilmiştir. Bu değere en yakın MAPE değeri ise %9,64 ile KNN yöntemi olmuştur. Bu sonuçlara göre, Bina-3'e ait verilerin Bina-1 ve Bina-2'den daha tutarlı olduğunu söylenebilir.



Şekil 8. Bina-1 için yöntemlerin performans metriklerine göre karşılaştırılması.



Şekil 9. Bina-2 için yöntemlerin performans metriklerine göre karşılaştırılması.



Şekil 10. Bina-3 için yöntemlerin performans metriklerine göre karşılaştırılması.

Bu çalışmada, kullanılan makine öğrenmesi yöntemleri (LSTM, KNN, GBDT, RF, XGBoost), kamu binalarının elektrik tüketim tahmininde farklı performanslar göstermiştir. Elde edilen RMSE, MAE ve MAPE değerleri üzerinden yapılan karşılaştırmalar sonucunda, özellikle LSTM ve GBDT modellerinin daha başarılı tahminler sunduğu görülmüştür. Benzer şekilde, Wang vd. (2020) tarafından yapılan bir çalışmada, RF, GBDT, SVR, KNN ve XGBoost yöntemleri bina enerji tüketiminin tahmini için kullanılmış; MAPE değerleri sırasıyla %9,71, %8,72, %11,20, %8,47 ve %9,30 olarak rapor edilmiştir. Bu bulgular, çalışmamızda GBDT ve KNN'nin başarılı sonuçlar üretmesiyle örtüşmektedir. Ayrıca, Liu vd. (2020) kamu binalarına yönelik gerçekleştirdikleri çalışmada SVM modelini kullanarak aylık tüketim verileriyle yaklaşık %97 R^2 değeri elde etmişlerdir. Bu durum, kamu binalarında makine öğrenmesi tabanlı yöntemlerin yüksek doğrulukla tahmin yapabildiğini göstermektedir. Dash vd. (2021), ev içi enerji tahmini için RNN-GBRT yöntemini önermiş ve yüksek tahmin başarısı rapor etmiştir. Bu çalışma, melez modellerin enerji tüketim tahmininde etkili olduğunu ortaya koymuştur. Bu bağlamda, çalışmamızda LSTM gibi zaman serisi modellerinin güçlü performans sergilemesi literatürdeki eğilimlerle paralellik göstermektedir. Öte yandan, Soyler ve Izgi (2022), İstanbul'daki hastaneler için gerçekleştirdikleri enerji tahmin çalışmasında, lineer regresyon modeli ile

yaklaşık %9,87 MAPE değeri elde etmişlerdir. Bu sonuç, daha karmaşık modellerin doğruluğunu test etmek için referans bir temel sağlamaktadır.

Tüm bu çalışmalara bakıldığında, çalışmamızda kullanılan yöntemlerin bu değerlere benzer şekilde MAPE değerleri sunması, modellerin doğruluk seviyesini ortaya koymaktadır. Yapılan karşılaştırmalar, kullanılan yöntemlerin doğruluğunu desteklemekte ve literatürdeki önceki çalışmalarla genel bir uyum içerisinde olduğunu göstermektedir. Bununla birlikte, farklı veri kümeleri, frekans düzeyleri (günlük, haftalık, aylık) ve bina türleri gibi değişkenler, tahmin performansındaki farklılıkların temel nedenleri arasında değerlendirilebilir.

4. Sonuç

Bu çalışma, Erzurum ilindeki üç farklı kaymakamlık binasının elektrik tüketim tahmininde farklı makine öğrenmesi yöntemlerinin performansını karşılaştırmıştır. Elde edilen sonuçlar, zaman serisi verilerinde güçlü bir performans sergileyen LSTM modelinin, özellikle Bina-1 ve Bina-2 için en düşük hata değerlerini sağlayarak diğer yöntemlere kıyasla daha üstün olduğunu göstermiştir. Bina-3'te ise göreceli hata oranı (MAPE) açısından GBDT ve KNN modelleri LSTM'ye göre daha başarılı sonuçlar elde etmiş, bu da farklı binaların tüketim dinamiklerinin model seçiminde önemli bir rol oynadığını ortaya koymuştur.

LSTM'nin genel üstün performansı, elektrik tüketimi gibi zaman serisi yapısına sahip verilerde daha yüksek doğrulukla çalışabildiğini ve enerji yönetimi süreçlerinde etkili bir araç olduğunu kanıtlamaktadır. Bununla birlikte, GBDT ve KNN gibi yöntemlerin belirli durumlarda daha düşük hata oranları sunabilmesi, farklı veri yapıları ve özelliklerin dikkate alınmasının model seçimini nasıl etkilediğini vurgulamaktadır.

Sonuçlar, model performanslarının, tüketim verilerindeki mevsimsellik dışında, hava durumu, ekonomik koşullar veya olağanüstü durumlar gibi dış etkenlere de duyarlı olduğunu göstermektedir. Bu durum, tahmin doğruluğunu artırmak için veri setlerinin daha geniş bir değişken yelpazesine zenginleştirilmesi gerektiğini işaret etmektedir. Özellikle ani dalgalanmalar veya uç değerler, tüm modeller için önemli bir zorluk teşkil etmiş ve gelecekte bu zorlukları aşmak için hibrit modeller veya veri ön işleme tekniklerinin kullanımı önerilmiştir.

Bu çalışma, yalnızca incelenen kaymakamlık binaları için değil, diğer kamu binalarındaki enerji yönetimi uygulamalarına da rehberlik edebilecek bir perspektif sunmaktadır. Tahmin modellerinin seçimi ve uygulanması, enerji verimliliğini artırma, maliyetleri düşürme ve sürdürülebilirlik hedeflerine ulaşma açısından kritik bir öneme sahiptir. Gelecek çalışmalar, daha geniş veri setleri ve değişkenlerle birlikte enerji tüketimini etkileyen faktörlerin kapsamlı analizine odaklanabilir. Böylelikle, kamu binalarındaki enerji yönetimi politikalarının daha sağlam temellere oturtulması sağlanabilir.

Katkı Oranı Beyanı

Yazarların katkı yüzdeleri aşağıda verilmiştir. Yazarlar makaleyi incelemiş ve onaylamıştır.

	V.A.	B.T.Ş.
K	50	50
T	40	60
Y	30	70
VTI	90	10
VAY	50	50
KT	70	30
YZ	50	50
KI	50	50
GR	30	70
PY	50	50
FA	50	50

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= Yazım, KI= kritik inceleme, GR= gönderim ve revizyon, PY= proje yönetimi, FA= fon alımı.

Çatışma Beyanı

Yazarlar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Etik Onay Beyanı

Bu çalışmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

Destek ve Teşekkür Beyanı

Bu çalışma, Atatürk Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından 14678 numaralı yüksek lisans projesi ile desteklenmiştir.

Kaynaklar

- Akkurt T, Sarıççek İ. 2024. Derin öğrenme teknikleri kullanılarak üretim sistemlerinde KPI tabanlı performans tahminleme. Gazi Univ Müh Mim Fak Derg, 39(3): 1499-1508.
- Aydın R. 2023. Satış adedini etkileyen değişkenlerin keşfi ve duyarlılık analizi uygulaması: E-ticaret örneği. Yüksek Lisans Tezi, İstanbul Teknik Univ, Lisansüstü Eğitim Enstitüsü, İstanbul, Türkiye, pp: 45-46.
- Balaban ME, Kartal E. 2018. Veri madenciliği ve makine öğrenmesi temel algoritmaları ve r dili ile uygulamaları. Çağlayan Kitabevi, İstanbul, Türkiye, 2. Baskı, pp: 56-59.
- Balta M. 2024. Rulman titreşim verilerinden derin öğrenme tabanlı hata tespiti. Yüksek Lisans Tezi, Maltepe Univ, Lisansüstü Eğitim Enstitüsü, İstanbul, Türkiye, pp: 45-85.
- Baçoğlu B, Bulut M. 2017. Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. Gazi Univ Müh Mim Fak Derg, 32(2): 575-583.
- Botman L, Lago J, Becker T, Vanthournout K, De Moor B. 2025. A global probabilistic approach for short-term forecasting of individual households electricity consumption. Appl Energy, 382: 125168.
- Breiman L. 2001. Random forests, machine learning. Kluwer Academic Publ, Dordrecht, Netherlands, 45(1): 5-32.
- Cao Z, Yuan P, Ma YB. 2014. Energy demand forecasting based on economy-related factors in China. Energy Sources Part B, 9(2): 214-219.
- Chen T, Guestrin C. 2016. XGBoost: A scalable tree boosting system. In Proc 22nd ACM SIGKDD Int Conf Knowl Discov Data Min, 13-17 Aug 2016, San Francisco, CA, USA, pp: 785-794.
- Cui X, Lee M, Koo C, Hong T. 2024. Energy consumption prediction and household feature analysis for different residential building types using machine learning and SHAP: Toward energy-efficient buildings. Energy Build, 309: 113997.
- Çayır A, Yenidoğan I, Dağ H. 2018. Konutların günlük elektrik güç tüketimi tahmini için uygun model seçimi. Fırat Univ Müh Bil Derg, 30(3): 15-21.
- Çuhadar M. 2006. Turizm sektöründe talep tahmini için yapay sinir ağları kullanımı ve diğer yöntemlerle karşılaştırmalı analizi (Antalya ilinin dış turizm talebinde uygulama). Doktora Tezi, Süleyman Demirel Univ, Sosyal Bilimler Enstitüsü, Isparta, Türkiye, pp: 45-87.
- Dash SK, Roccotelli M, Khansama RR, Fanti MP, Mangini AM. 2021. Long term household electricity demand forecasting based on RNN-GBRT model and a novel energy theft detection method. Appl Sci, 11(18): 8612.
- Demolli H, Dokuz AS, Ecemis A, Gokcek M. 2019. Wind power forecasting based on daily wind speed data using machine learning algorithms. Energy Convers Manag, 198: 111823.
- Dev VA, Eden MR. 2019. Formation lithology classification

- using scalable gradient boosted decision trees. *Comput Chem Eng*, 128: 392-404.
- Dong X, Luo Y, Yuan S, Tian Z, Zhang L, Wu X, Liu B. 2025. Building electricity load forecasting based on spatiotemporal correlation and electricity consumption behavior information. *Appl Energy*, 377: 124580.
- Eşidir KA. 2025. Makine öğrenimi modelleri ile yetişkin eğitimi analizi: modellerin karşılaştırmalı performansı. *Elektronik Sosyal Bilimler Dergisi*, 24(2): 946-964.
- Filippov SP, Malakhov VA, Veselov FV. 2021. Long-term energy demand forecasting based on a systems analysis. *Thermal Eng*, 68: 881-894.
- Goodfellow I, Bengio Y, Courville A. 2016. *Deep Learning*. MIT Press, Cambridge, UK, pp: 800.
- Gök M. 2017. Makine öğrenmesi yöntemleri ile akademik başarının tahmin edilmesi. *Gazi Univ J Sci Part C: Des Technol*, 5(3): 139-148.
- Grveón TG, Schwenzer J, Steens T, Breuing J. 2024. Electricity demand forecasting with hybrid classical statistical and machine learning algorithms: Case study of Ukraine. *Appl Energy*, 355: 122249.
- Guo G, Wang H, Bell D, Bi Y, Greer K. 2003. KNN model-based approach in classification. In *OTM Confederated Int Conf*, Catania, Sicily, Italy, 3-7 Nov 2003, pp: 986-996.
- Gültepe Y. 2019. Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim Teknol Derg*, 16: 8-15.
- Gür YE, Eşidir KA, Şimşek Aİ. 2024. Sağlık istatistiklerinin veri madenciliği teknikleri ile analizi: makine öğrenmesi algoritmaları kullanılarak genel sağlık durumunun sınıflandırılması. *Afyon Kocatepe Univ Fen Müh Bil Derg*, 24(06): 1364-1381.
- Hastie T, Tibshirani R, Friedman J. 2009. *The elements of statistical learning: data mining, inference, and prediction*. Springer Sci & Bus Media, New York, 2nd ed, pp: 758.
- He Y, Lin B. 2018. Forecasting China's total energy demand and its structure using ADL-MIDAS model. *Energy*, 151: 420-429.
- Hochreiter S, Schmidhuber J. 1996. LSTM can solve hard long time lag problems. In *Advances in Neural Inf Process Syst*, 2-5 Dec 1996, Denver, CO, USA, 9: 473-479.
- Hochreiter S, Schmidhuber J. 1997. Long short-term memory. *Neural Comput*, 9(8): 1735-1780.
- Hsu PC, Gao L, Hwang Y. 2025. Comparative study of LSTM and ANN models for power consumption prediction of variable refrigerant flow (VRF) systems in buildings. *Int J Refrig*, 169: 55-68.
- Hwang J, Suh D, Otto MO. 2020. Forecasting electricity consumption in commercial buildings using a machine learning approach. *Energies*, 13(22): 5885.
- Iftikhar H, Turpo-Chaparro JE, Canas Rodrigues P, López-Gonzales JL. 2023. Day-ahead electricity demand forecasting using a novel decomposition combination method. *Energies*, 16(18): 6675.
- Kazemzadeh MR, Amjadian A, Amraee T. 2020. A hybrid data mining driven algorithm for long term electric peak load and energy demand forecasting. *Energy*, 204: 117948.
- Khan M, Ding Q, Perrizo W. 2002. K-nearest neighbor classification on spatial data streams using P-trees. *Adv Knowl Discov Data Min*, 2336: 517-528.
- Kim YS, Kim MK, Fu N, Liu J, Wang J, Srebric J. 2025. Investigating the impact of data normalization methods on predicting electricity consumption in a building using different artificial neural network models. *Sustain Cities Soc*, 118: 105570.
- Kulkarni V, Sinha PK. 2012. Pruning of random forest classifiers: a survey and future directions. In *2012 Int Conf Data Sci Eng (ICDSE)*, IEEE, 18-20 Jul 2012, Cochin, India, pp: 64-68.
- Lei L, Shao S, Liang L. 2024. An evolutionary deep learning model based on EWKM, random forest algorithm, SSA and BiLSTM for building energy consumption prediction. *Energy*, 288: 129795.
- Li X, Jiang M, Cai D, Song W, Sun Y. 2024. A hybrid forecasting model for electricity demand in sustainable power systems based on support vector machine. *Energies*, 17(17): 4377.
- Li X, Wang Z, Yang C, Bozkurt A. 2024. An advanced framework for net electricity consumption prediction: Incorporating novel machine learning models and optimization algorithms. *Energy*, 296: 131259.
- Li Y, Jones B. 2019. The use of extreme value theory for forecasting long-term substation maximum electricity demand. *IEEE Trans Power Syst*, 35(1): 128-139.
- Liu Y, Chen H, Zhang L, Wu X, Wang XJ. 2020. Energy consumption prediction and diagnosis of public buildings based on support vector machine learning: A case study in China. *J Clean Prod*, 272: 122542.
- Man H, Huang H, Qin Z, Li Z. 2023. Analysis of a sarima-xgboost model for hand, foot, and mouth disease in xinjiang, china. *Epidemiol Infect*, 151: 200.
- Mayr A, Binder H, Gefeller O, Schmid M. 2014. The evolution of boosting algorithms. *Methods Inf Med*, 53(6): 419-427.
- Mercan V. 2023. Metinsel veriler için çok sınıflı problemlere hata düzelten kod tabanlı kolektif öğrenme yönteminin uygulanması. Yüksek Lisans Tezi, İstanbul Sabahattin Zaim Univ, Lisansüstü Eğitim Enstitüsü, İstanbul, Türkiye, pp: 54.
- Nacar EN, Erdebili B. 2021. Makine öğrenmesi algoritmaları ile satış tahmini. *Endüstri Müh*, 32(2): 307-320.
- Nebati EE, Taş M, Ertaş G. 2021. Türkiye'de elektrik tüketiminde talep tahmini: zaman serisi ve regresyon analizi ile karşılaştırma. *Avrupa Bilim Teknol Derg*, 31: 348-357.
- Nikseresht A, Amindavar H. 2024. Energy demand forecasting using adaptive ARFIMA based on a novel dynamic structural break detection framework. *Appl Energy*, 353: 122069.
- Olu-Ajayi R, Alaka H, Sulaimon I, Sunmola F, Ajayi S. 2022. Building energy consumption prediction for residential buildings using deep learning and other machine learning techniques. *J Build Eng*, 45: 103406.
- Özkan Y. 2008. Veri madenciliği yöntemleri. Papatya Yayıncılık, İstanbul, Türkiye, pp: 45-65.
- Peker M, Özkaraca O, Kesimal B. 2017. Enerji tasarruflı bina tasarımı için ısıtma ve soğutma yüklerini regresyon tabanlı makine öğrenmesi algoritmaları ile modelleme. *Bilişim Teknol Derg*, 10(4): 443-449.
- Peterson LE. 2009. K-nearest neighbor. *Scholarpedia*, 4(2): 1883.
- Silahtaroglu G. 2008. Kavram ve algoritmalarıyla temel veri madenciliği. Papatya Yayıncılık, İstanbul, Türkiye, pp: 65-96.
- Sinap V. 2024. Perakende Sektöründe Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Performans Analizi: Black Friday Satış Tahminlemesi. Selçuk Univ Sos Bil Meslek Yüksekok Derg, 27(1): 65-90.
- Sofyalıoğlu Ç, Öztürk Ş. 2013. Bir çimento firması için dönemsel satış miktarlarının tahmininde bulanık zaman serisi modellerinin karşılaştırılması. Süleyman Demirel Univ İktisadi İdari Bil Fak Derg, 18(3): 161-186.
- Soyler I, İzgi E. 2022. Electricity demand forecasting of hospital buildings in Istanbul. *Sustainability*, 14(13): 8187.
- Taşcı E, Onan A. 2016. K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*, 1(1): 4-18.

- Uddin MN, Lee M, Cui X, Zhang X. 2025. Predicting occupant energy consumption in different indoor layout configurations using a hybrid agent-based modeling and machine learning approach. *Energy Build*, 328: 115102.
- Voronin S, Partanen J. 2014. Forecasting electricity price and demand using a hybrid approach based on wavelet transform, ARIMA and neural networks. *Int J Energy Res*, 38(5): 626-637.
- Wang FK, Mamo T. 2020. Gradient boosted Regresyon model for the degradation analysis of prismatic cells. *Comput Ind Eng*, 144: 106494.
- Wang R, Lu S, Feng W. 2020. A novel improved model for building energy consumption prediction based on model integration. *Appl Energy*, 262: 114561.
- Wang R, Lu S, Li Q. 2019. Multi-criteria comprehensive study on predictive algorithm of hourly heating energy consumption for residential buildings. *Sustain Cities Soc*, 49: 101623.
- Wang W, Shimakawa H, Jie B, Sato M, Kumada A. 2025. BE-LSTM: An LSTM-based framework for feature selection and building electricity consumption prediction on small datasets. *J Build Eng*, 102: 111910.
- Witt SF, Witt CA. 1991. Tourism forecasting: Error magnitude, direction of change error, and trend change error. *J Travel Res*, 30(2): 26-33.
- Yazıcı K. 2021. Makine öğrenmesi yöntemleri kullanılarak kısa dönem rüzgâr gücü tahmini. Yüksek Lisans Tezi, Sakarya Univ, Fen Bil Enstitüsü, Sakarya, Türkiye, pp: 72.
- Yelgeç MA, Bingöl O. 2022. Ayrık dalgacık dönüşümü ve Xgboost ile rüzgâr gücü tahmini. *Uluslararası Teknol Bilim Derg*, 14(2): 58-65.
- Zhou K, Chu Y, Hu R. 2023. Energy supply-demand interaction model integrating uncertainty forecasting and peer-to-peer energy trading. *Energy*, 285: 129436.