



**Oğuz Mert Çelebi**

İskenderun Technical University, celebiom@hotmail.com,  
Hatay-Türkiye

DOI	<a href="http://dx.doi.org/10.12739/NWSA.2026.21.2.1A0504">http://dx.doi.org/10.12739/NWSA.2026.21.2.1A0504</a>
ORCID ID	0009-0003-4617-695X
Corresponding Author	Oğuz Mert Çelebi

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK YAPI GRUPLARININ ELEKTRİK TALEP GÜCÜNÜN BÖLGESEL DİVERSİTE İLE TAHMİN EDİLMESİ**

**ÖZ**

Bu çalışmanın amacı, yapı gruplarının elektrik güç ihtiyacının daha gerçekçi biçimde tahmin edilmesine yönelik veri temelli bir model geliştirmektir. Türkiye’de yapıların elektriksel güç gereksinimi mevcut mevzuatta yer alan diversite katsayılarına dayalı hesaplama yöntemleri ile belirlenmektedir. Ancak teknolojik gelişmeler, değişen kullanım alışkanlıkları ve bölgesel farklılıklar nedeniyle projelendirme aşamasında öngörülen güç değerleri ile işletme sürecinde gerçekleşen puant güç arasında önemli sapmalar oluşabilmektedir. Bu durum, gereğinden yüksek kapasiteli transformatör ve ekipman seçimine yol açarak enerji dağıtım altyapısında kapasite kullanım verimliliğini azaltmaktadır. Çalışmada farklı bölgesel özelliklere sahip transformatörlerden elde edilen maksimum güç verileri analiz edilmiş ve demografik, bölgesel ve kullanıcı tipine ilişkin değişkenleri içeren bir veri seti oluşturulmuştur. Oluşturulan veri seti kullanılarak çeşitli makine öğrenmesi modelleri geliştirilmiş ve model performansları karşılaştırılmıştır. Elde edilen bulgular, önerilen yaklaşımın enerji talep tahminlerinde daha dengeli kapasite planlamasına olanak sağlayabileceğini göstermektedir.

**Anahtar Kelimeler:** Elektrik Talep Tahmini, Diversite Katsayısı, Makine Öğrenmesi, Elektrik Dağıtım Sistemleri, Transformatör Kapasite Planlaması

**ESTIMATION OF ELECTRICAL DEMAND OF BUILDING GROUPS USING REGIONAL DIVERSITY-BASED MACHINE LEARNING METHODS**

**ABSTRACT**

This study aims to develop a data-driven model for more realistic estimation of the electrical power demand of building groups. In Turkey, the electrical power requirements of buildings are determined using calculation methods based on diversity coefficients defined in existing regulations. However, due to technological developments, changing consumption habits, and regional differences, significant discrepancies may occur between the power values estimated during the project design phase and the peak power observed during operation. This situation leads to the selection of transformers and equipment with capacities higher than required and reduces capacity utilization efficiency in the electricity distribution infrastructure. In this study, maximum power data obtained from transformers located in regions with different characteristics were analyzed, and a dataset including demographic, regional, and user-type variables was created. The dataset used in this study consists of maximum power measurements obtained from 780 distribution transformers located in seven different regions. Various machine learning models were developed using this dataset, and their performances were compared. The findings indicate that the proposed approach can enable more balanced capacity planning in electricity demand estimation, improve infrastructure investment efficiency and support data-driven capacity planning in electricity distribution systems.

**Keywords:** Electricity Demand Forecasting, Diversity Coefficient, Machine Learning, Electricity Distribution Systems

**How to Cite:**

Çelebi, O.M., (2025). Makine öğrenmesi yöntemleri kullanılarak yapı gruplarının elektrik talep gücünün bölgesel diversite ile tahmin edilmesi. Engineering Sciences, 21(2):15-26, DOI: 10.12739/NWSA.2026.21.2.1A0504.

## 1. GİRİŞ (INTRODUCTION)

Elektrik dağıtım sistemlerinde altyapı planlamasının temel unsurlarından biri, yapıların elektriksel güç ihtiyacının doğru biçimde belirlenmesidir. Elektrik talebinin doğru tahmin edilmesi, transformatör kapasitesi seçimi, şebeke planlaması ve yatırım optimizasyonu açısından kritik öneme sahiptir [1]. Türkiye’de yapıların elektriksel güç gereksinimi, Elektrik İç Tesisleri Yönetmeliği kapsamında tanımlanan hesaplama yöntemleri ve diversite katsayılarına dayalı eşzamanlılık faktörleri kullanılarak belirlenmektedir. Ancak değişen yaşam alışkanlıkları, teknolojik gelişmeler ve bölgesel tüketim farklılıkları nedeniyle projelendirme aşamasında hesaplanan güç değerleri ile işletme sürecinde gerçekleşen puant güç değerleri arasında önemli sapmalar oluşabilmektedir. Bu durum, dağıtım şebekelerinde gereğinden yüksek kapasiteli transformatörlerin seçilmesine ve altyapı yatırımlarında kaynakların verimsiz kullanılmasına neden olabilmektedir.

Enerji talep tahmini ve bina enerji tüketim profillerinin modellenmesi üzerine literatürde çok sayıda çalışma bulunmaktadır [2]. Bu çalışmaların önemli bir bölümü, bina ölçeğinde elektrik tüketim desenlerinin belirlenmesine ve enerji yönetim sistemlerinde kullanılacak tahmin modellerinin geliştirilmesine odaklanmaktadır. Elektrik yük tahmini üzerine yapılan çalışmalar enerji planlaması ve dağıtım sistemlerinin işletilmesi açısından önemli karar destek araçları sunmaktadır [3]. Yapay sinir ağları, kümeleme yöntemleri ve optimizasyon algoritmaları kullanılarak gerçekleştirilen çalışmalar, elektrik yük tahminlerinde veri temelli yöntemlerin yüksek doğruluk sağlayabildiğini göstermektedir [4]. Ayrıca akıllı sayaç verileri kullanılarak tüketim profillerinin karakterize edilmesi, kullanıcı davranışlarının analiz edilmesi ve enerji talep modellerinin geliştirilmesi konusunda önemli araştırmalar yapılmıştır [5]. Son yıllarda gerçekleştirilen çalışmalar ise üretken modellerin, büyük veri analizi ve gelişmiş makine öğrenmesi tekniklerinin enerji tüketim tahminlerinde önemli avantajlar sunduğunu ortaya koymaktadır [4 ve 6].

Bununla birlikte, mevcut çalışmaların büyük bir bölümü bina veya kullanıcı ölçeğinde enerji tüketim tahmini üzerine yoğunlaşmakta olup, elektrik dağıtım şebekesi planlamasında kullanılan proje gücü hesaplamaları ile gerçekleşen güç arasındaki farklılıkların veri temelli yöntemlerle modellenmesine yönelik çalışmalar sınırlı kalmaktadır. Özellikle bölgesel özellikler, demografik değişkenler ve kullanıcı tiplerinin birlikte değerlendirildiği modellerin dağıtım altyapısı planlamasında kullanımı yeterince ele alınmamıştır.

Bu çalışmada, farklı bölgesel özelliklere sahip transformatörlerden elde edilen gerçek güç tüketim verileri kullanılarak yapı gruplarının elektrik talebinin tahmin edilmesine yönelik makine öğrenmesi temelli bir yaklaşım geliştirilmiştir. Bu çalışma, bölgesel diversiteyi, demografik değişkenleri ve makine öğrenmesi yöntemlerini elektrik dağıtım altyapısı kapasite planlaması bağlamında birlikte ele alarak literatüre özgün bir yaklaşım sunmaktadır.

Çalışmanın temel katkıları aşağıdaki şekilde özetlenebilir:

- Proje aşamasında hesaplanan güç değerleri ile gerçekleşen puant güç değerleri arasındaki ilişkinin saha verileri kullanılarak analiz edilmesi
- Bölgesel, demografik ve kullanıcı tipine bağlı değişkenleri içeren veri seti ile farklı makine öğrenmesi modellerinin karşılaştırılması
- Enerji dağıtım sistemlerinde daha gerçekçi kapasite planlamasına katkı sağlayabilecek veri temelli bir tahmin yaklaşımının önerilmesi

Elde edilen bulgular, önerilen yöntemin elektrik dağıtım altyapısında kapasite kullanım verimliliğini artırabilecek ve yatırım planlamasına destek sağlayabilecek bir araç olarak kullanılabilirliğini göstermektedir.

Bu çalışma, bölgesel çeşitlilik, demografik değişkenler ve makine öğrenmesi yöntemlerini elektrik dağıtım altyapısı kapasite planlaması bağlamında birlikte ele alarak literatüre özgün bir katkı sunmaktadır.

## 2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Elektrik dağıtım sistemlerinde altyapı planlamasının en kritik aşamalarından biri, yapı gruplarının elektrik talep gücünün doğru şekilde belirlenmesidir. Talep gücünün doğru tahmin edilmesi, transformatör kapasitesi seçimi, şebeke planlaması ve yatırım optimizasyonu açısından büyük önem taşımaktadır [7 ve 8]. Türkiye’de yapıların elektriksel güç gereksinimi, Elektrik İç Tesisleri Yönetmeliği kapsamında tanımlanan diversite katsayılarına dayalı hesaplama yöntemleri kullanılarak belirlenmektedir. Ancak mevcut yöntemler, değişen tüketim alışkanlıkları, bölgesel özellikler ve demografik farklılıklar gibi faktörleri yeterince dikkate almamaktadır. Bu durum, projelendirme aşamasında hesaplanan güç değerleri ile işletme sürecinde gerçekleşen puant güç değerleri arasında önemli sapmaların oluşmasına neden olmaktadır [3]. Sonuç olarak enerji dağıtım sistemlerinde gereğinden yüksek kapasiteli transformatörlerin seçilmesi, kapasite kullanım verimliliğinin düşmesi ve altyapı yatırımlarında maliyet artışı gibi sorunlar ortaya çıkabilmektedir.

Bu çalışmanın temel problemi, yapı gruplarının elektrik talep gücünün mevcut hesaplama yöntemleri ile yeterli doğrulukta tahmin edilememesidir. Çalışmanın hipotezi, bölgesel, demografik ve kullanıcı tipine bağlı değişkenleri içeren veri temelli makine öğrenmesi modellerinin kullanılmasyla, yapı gruplarının gerçek elektrik talebinin daha doğru biçimde tahmin edilebileceği yönündedir [9]. Bu doğrultuda, farklı bölgesel özelliklere sahip transformatörlerden elde edilen gerçek güç tüketim verileri analiz edilmiş ve proje aşamasında hesaplanan güç değerleri ile işletme sürecinde gerçekleşen puant güç değerleri arasındaki ilişki veri temelli yöntemler kullanılarak incelenmiştir. Çalışmada farklı makine öğrenmesi algoritmaları kullanılarak geliştirilen modellerin performansları karşılaştırılmış ve enerji talep tahmini açısından en uygun model belirlenmeye çalışılmıştır.

Bu araştırma, elektrik dağıtım sektöründe veri temelli karar destek yaklaşımlarının geliştirilmesine katkı sağlamayı amaçlamaktadır [10]. Önerilen yaklaşım sayesinde transformatör kapasite seçimlerinin daha gerçekçi yapılması, enerji dağıtım altyapısında kapasite kullanım verimliliğinin artırılması ve yatırım planlamasında kaynakların daha etkin kullanılması mümkün olabilecektir. Ayrıca geliştirilen modelin yalnızca elektrik dağıtım sistemleri için değil, imar planlaması ve altyapı master planı hazırlıkları gibi farklı mühendislik alanlarında da uygulanabilir bir yöntem sunabileceği değerlendirilmektedir. Bu yönüyle çalışma, enerji dağıtım sistemlerinde veri odaklı planlama yaklaşımlarının geliştirilmesine katkı sağlayan önemli bir araştırma niteliği taşımaktadır.

### Önemli Noktalar (Highlights)

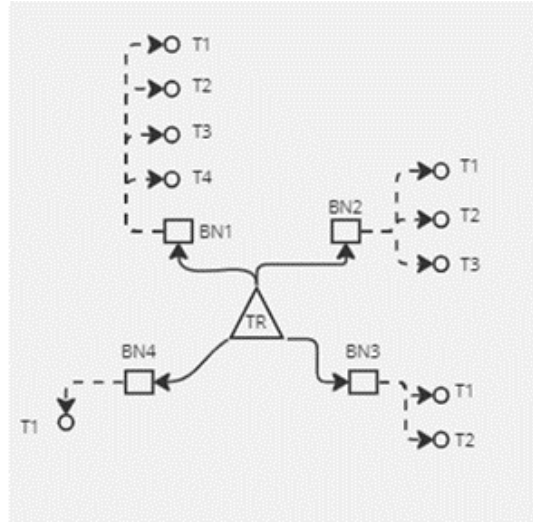
- Gerçek saha verilerine dayalı olarak yapı gruplarının elektrik talep gücünü tahmin eden makine öğrenmesi temelli bir model geliştirilmiştir.
- Bölgesel, demografik ve kullanıcı tipine bağlı değişkenlerin enerji talebi üzerindeki etkisi analiz edilmiştir.
- Önerilen modelin enerji dağıtım sistemlerinde daha dengeli transformatör kapasite planlaması sağlayabileceği gösterilmiştir.

### 3. ANALİTİK ÇALIŞMA (ANALYTICAL STUDY)

Bu bölümde, yapı gruplarının elektrik talep gücünün tahmin edilmesine yönelik geliştirilen veri seti, kullanılan modelleme yaklaşımı ve analiz süreci açıklanmaktadır. Çalışmada gerçek saha verilerine dayalı olarak enerji talep tahminine yönelik makine öğrenmesi modelleri geliştirilmiş ve model performansları karşılaştırılmıştır.

#### 3.1. Veri Setinin Oluşturulması (Dataset Construction)

Çalışmada kullanılan veri seti, Türkiye’de faaliyet gösteren bir elektrik dağıtım şirketinin sorumluluk bölgesinde yer alan farklı demografik ve coğrafi özelliklere sahip farklı illerde bulunan transformatörlerden elde edilmiştir. Analiz kapsamında toplam 780 adet transformatöre ait iki yıllık maksimum güç tüketim verileri incelenmiştir. Her bir transformatör için maksimum puant güç değerleri, transformatör gücüne oranlanarak doluluk oranları hesaplanmıştır. Veri seti oluşturulurken her bir transformatöre bağlı binalar ve bu binalarda bulunan tesisatlar dikkate alınmıştır. Binalara ait proje güçleri, Elektrik İç Tesisleri Yönetmeliği’nde belirtilen hesaplama yöntemleri kullanılarak belirlenmiştir. Bunun yanı sıra, veri setine kullanıcı tipi, mesken sayısı, ticari kullanıcı gücü ve bölgesel sınıflandırma gibi değişkenler de eklenmiştir. Transformatörler buldukları bölgenin yerleşim özelliklerine göre kentsel, kentaltı ve kırsal olmak üzere üç farklı kategori altında sınıflandırılmıştır.



Şekil 1. Transformatör hizmet bölgesi ve yapı bağlantı yapısına ait örnek şematik gösterim  
(Figure 1. Schematic representation of a transformer service area and building connections)

Bu çalışmada dağıtım şebekesindeki talep gücü tahmini veri temelli makine öğrenmesi yöntemleri kullanılarak gerçekleştirilmiştir [11 ve 12]. Geleneksel güç sistemi analizlerinde kullanılan analitik yöntemlerden farklı olarak, bu çalışmada transformatör ölçümleri, yapı türleri ve bölgesel demografik değişkenler kullanılarak tahmin modelleri oluşturulmuştur. Elektrik yük tahmini üzerine yapılan çalışmalar, makine öğrenmesi ve veri madenciliği yöntemlerinin enerji talep tahmininde yüksek doğruluk sağlayabildiğini göstermektedir [8 ve 9]. Veri setinin zenginleştirilmesi amacıyla bölgesel ve demografik özellikleri temsil eden ek değişkenler de modele dahil edilmiştir. Bu kapsamda yaş dağılımı, gelir düzeyi, eğitim seviyesi, hane başına düşen kişi sayısı ve konut özellikleri gibi değişkenler kullanılarak model girdileri genişletilmiştir.

### 3.2. Makine Öğrenmesi Modelleri (Machine Learning Models)

Çalışmada yapı gruplarının elektrik talep gücünü tahmin edebilmek amacıyla farklı makine öğrenmesi modelleri kullanılmıştır. İlk aşamada doğrusal olmayan ilişkilerin modellenebilmesi amacıyla yapay sinir ağı tabanlı bir model oluşturulmuştur. Yapay sinir ağı modeli, giriş katmanı, iki gizli katman ve çıkış katmanından oluşan çok katmanlı bir yapı kullanılarak eğitilmiştir [13]. Model performansının artırılması amacıyla karar ağacı tabanlı ansambl öğrenme yöntemleri de değerlendirilmiştir. Bu kapsamda Random Forest, gradyan artırma temelli XGBoost ve kategorik verilerle etkin çalışabilen CatBoost algoritmaları kullanılmıştır [14, 15 ve 16]. Her bir model aynı veri seti üzerinde eğitilmiş ve tahmin performansları karşılaştırılmıştır.

### 3.3. Model Performans Değerlendirmesi (Model Performance Evaluation)

Geliştirilen modellerin performansı hata metrikleri kullanılarak değerlendirilmiştir. Model tahmin doğruluğunu ölçmek amacıyla ortalama mutlak yüzde hata ve kök ortalama kare hata metrikleri kullanılmıştır [17]. Bu metrikler, model tarafından tahmin edilen değerler ile gerçek puant güç değerleri arasındaki farkı ölçmek için yaygın olarak kullanılan performans göstergeleridir. Farklı algoritmalar kullanılarak geliştirilen modellerin performansları karşılaştırıldığında, kategorik verilerin işlenmesinde güçlü bir yapıya sahip olan CatBoost modelinin diğer modellere kıyasla daha düşük hata değerleri verdiği görülmüştür. Bu sonuç, önerilen veri temelli yaklaşımın enerji talep tahmini açısından daha gerçekçi sonuçlar üretebildiğini göstermektedir.

## 4. BULGULAR VE TARTIŞMA (FINDINGS AND DISCUSSION)

Bu bölümde çalışmada geliştirilen makine öğrenmesi modellerinin performans sonuçları ve elde edilen bulguların elektrik dağıtım sistemleri açısından değerlendirilmesi sunulmaktadır. Analizler, farklı bölgesel özelliklere sahip transformatörlerden elde edilen gerçek güç tüketim verileri kullanılarak gerçekleştirilmiştir.

### 4.1. Transformatör Doluluk Analizi (Transformer Loading Analysis)

Çalışma kapsamında incelenen 780 adet transformatöre ait maksimum güç tüketim verileri analiz edilmiştir. Elde edilen sonuçlar, transformatörlerin önemli bir kısmının kapasitesinin oldukça altında çalıştığını göstermektedir. Analiz sonuçlarına göre transformatörlerin büyük bölümü %0 ile %40 doluluk oranı aralığında yoğunlaşmaktadır. Bununla birlikte, %100 ve üzeri doluluk oranına sahip transformatörlerin oranı oldukça düşük seviyede kalmaktadır. Bu durum, mevcut hesaplama yöntemleri ile belirlenen proje güçlerinin çoğu zaman gerçek talebinin olduğundan yüksek tahmin edildiğini göstermektedir. Sonuç olarak, dağıtım sistemlerinde gereğinden yüksek kapasiteli transformatörlerin seçilmesi söz konusu olmakta ve bu durum enerji altyapısında kapasite kullanım verimliliğinin düşmesine neden olmaktadır. Ayrıca düşük doluluk oranları, transformatörlerde boşa kayıpların artmasına ve yatırım maliyetlerinin gereksiz şekilde yükselmesine yol açabilmektedir.

### 4.2. Makine Öğrenmesi Model Sonuçları (Machine Learning Model Results)

Çalışmada yapı gruplarının elektrik talep gücünün tahmin edilmesi amacıyla farklı makine öğrenmesi algoritmaları kullanılmıştır. Yapay sinir ağı, Random Forest, XGBoost ve CatBoost modelleri aynı veri seti üzerinde eğitilmiş ve model performansları karşılaştırılmıştır. Elde edilen sonuçlara göre, yapay sinir ağı modeli belirli bir doğruluk seviyesine ulaşmasına rağmen veri setinde bulunan kategorik değişkenleri yeterince etkin şekilde temsil edememiştir. Random Forest modeli daha

kararlı sonuçlar üretmesine rağmen bazı durumlarda tahmin hatalarının arttığı gözlemlenmiştir. XGBoost modeli ise hata oranlarını azaltmakla birlikte veri setinin yapısı nedeniyle sınırlı bir iyileşme sağlamıştır.


Model performanslarının karşılaştırılması sonucunda en başarılı sonuçların CatBoost algoritması ile elde edildiği görülmüştür. CatBoost modelinin özellikle kategorik verileri etkin şekilde işleyebilmesi, model doğruluğunun artmasında önemli bir rol oynamıştır. Performans değerlendirmeleri sonucunda CatBoost modelinin ortalama mutlak yüzde hata ve kök ortalama kare hata değerleri açısından diğer modellere kıyasla daha iyi sonuçlar verdiği belirlenmiştir. Bu sonuçlar, veri temelli makine öğrenmesi yöntemlerinin enerji talep tahmini açısından geleneksel hesaplama yöntemlerine kıyasla daha başarılı olabileceğini göstermektedir [18 ve 19].

#### **4.3. Elektrik Dağıtım Sistemleri Açısından Değerlendirme (Implications for Electricity Distribution Systems)**

Elde edilen bulgular, önerilen modelin elektrik dağıtım sistemlerinde kapasite planlamasının daha gerçekçi yapılmasına katkı sağlayabileceğini göstermektedir. Özellikle yapı gruplarının elektrik talebinin daha doğru tahmin edilmesi, transformatör kapasitesinin daha dengeli seçilmesine ve şebeke yatırımlarının daha etkin planlanmasına olanak sağlayabilir. Çalışma kapsamında elde edilen sonuçlar, mevcut durumda birçok transformatörün kapasitesinin önemli bir bölümünün kullanılmadığını ortaya koymaktadır. Makine öğrenmesi tabanlı model kullanılarak yapılan kapasite tahminleri ise transformatör doluluk oranlarının daha dengeli dağıldığını göstermektedir. Bu durum, elektrik dağıtım altyapısında kapasite kullanım verimliliğini artırabilecek önemli bir avantaj sağlamaktadır. Bunun yanı sıra daha doğru kapasite planlaması sayesinde enerji altyapı yatırımlarının maliyet etkin şekilde yapılması mümkün olabilecektir. Gereğinden yüksek kapasitede seçilen ekipmanların azaltılması, elektrik dağıtım şirketlerinin yatırım bütçelerini daha verimli kullanmasına katkı sağlayabilir. Bu nedenle önerilen yaklaşımın, elektrik dağıtım sistemlerinde veri temelli planlama süreçlerinin geliştirilmesi açısından önemli bir potansiyel taşıdığı değerlendirilmektedir.


#### **5. SONUÇ VE ÖNERİLER (CONCLUSION AND RECOMMENDATIONS)**

Bu çalışmada, yapı gruplarının elektrik talep gücünün daha gerçekçi biçimde tahmin edilmesine yönelik veri temelli bir makine öğrenmesi yaklaşımı geliştirilmiştir. Çalışmanın temel motivasyonu, mevcut projelendirme yöntemleri ile hesaplanan güç değerleri ile işletme sürecinde gerçekleşen puant güç değerleri arasında oluşan farklılıkların elektrik dağıtım sistemlerinde kapasite kullanım verimliliğini olumsuz etkilemesidir. Gerçek saha verileri kullanılarak gerçekleştirilen analizler sonucunda, incelenen transformatörlerin önemli bir bölümünün kapasitesinin düşük doluluk oranlarında çalıştığı belirlenmiştir. Transformatör doluluk oranlarının dağılımı incelendiğinde, Şekil 2'de görüldüğü üzere birçok transformatörün %40'ın altında kapasite kullanımına sahip olduğu tespit edilmiştir.



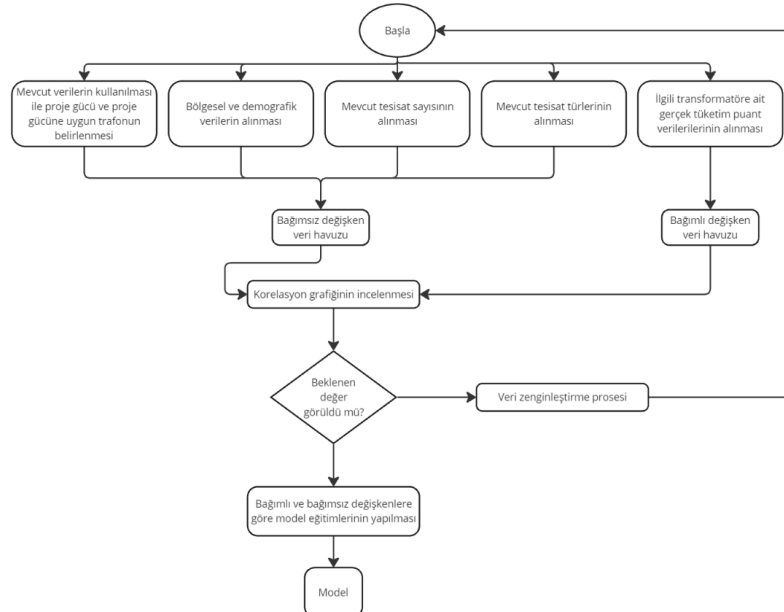
Şekil 2. İncelenen transformatörlerin doluluk oranı dağılımı ve yıllık kullanım profili  
(Figure 2. Distribution of transformer loading ratios and annual utilization profiles)

Şekil 3'de verilen yıllık doluluk oranı dağılımları incelendiğinde bu durumun yıl boyunca benzer şekilde devam ettiği görülmektedir. Bu bulgular, mevcut hesaplama yöntemlerinin birçok durumda gerçek enerji talebini olduğundan yüksek tahmin ettiğini göstermektedir.



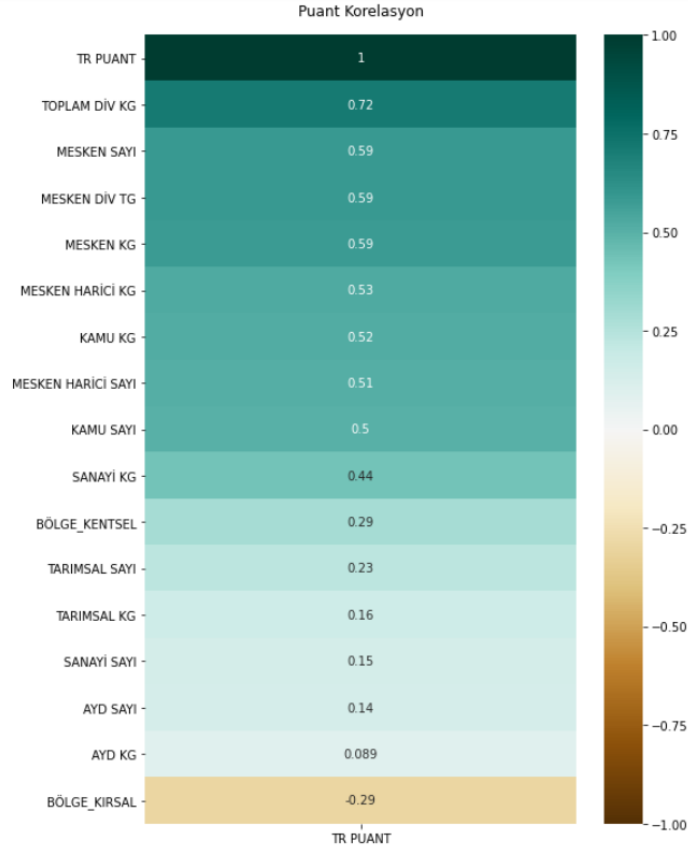
Şekil 3. Transformatör yıllık doluluk dağılımları  
(Figure 3. Annual transformer loading distributions)

Çalışma kapsamında oluşturulan veri seti ve analiz süreci Şekil 4'te sunulmuştur. Korelasyon analizleri sonucunda mesken sayısı, mesken dışı kullanıcı gücü ve diversite katsayıları gibi değişkenlerin punt güç ile güçlü ilişki gösterdiği belirlenmiştir.



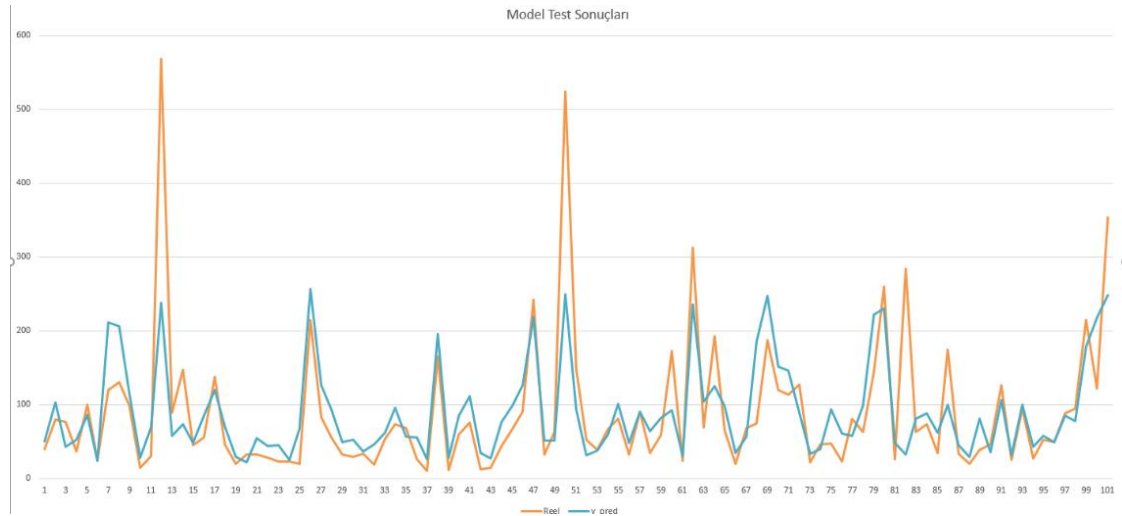
Şekil 4. Mevcut veri analiz süreci  
(Figure 4. Workflow of the current data analysis process)

Değişkenler arasındaki ilişkiler Şekil 5'te sunulan korelasyon ısı haritası ile görselleştirilmiştir.



Şekil 5. Korelasyon ısı haritası  
(Figure 5. Correlation heatmap)

Makine öğrenmesi modellerinin performans karşılaştırması sonucunda, kullanılan algoritmalar arasında en başarılı sonuçların CatBoost modeli ile elde edildiği görülmüştür. Model tarafından üretilen tahmin değerleri ile gerçek puant güç değerlerinin karşılaştırılması Şekil 6'da sunulmaktadır.



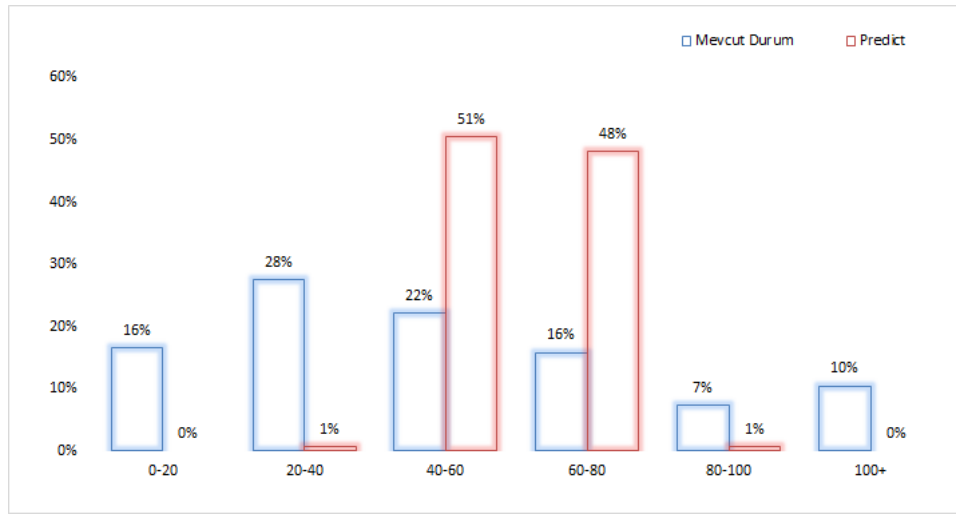
Şekil 6. YSA model çıktısı ve gerçek değerlerin karşılaştırılması  
(Figure 6. Comparison between ANN model predictions and actual values)

Farklı algoritmaların performans sonuçları, MAPE ve RMSE değerleri Tablo 1’de sunulmuş olup, CatBoost modelinin diğer modellere göre daha düşük hata değerlerine sahip olduğu belirlenmiştir.

Tablo 1. Makine öğrenmesi modellerinin performans karşılaştırması  
(Table 1. Performance comparison of machine learning models)

Model	MAPE	RMSE
Yapay Sinir Ağı	60	41
Random Forest	57	72
XGBoost	38	40
CatBoost	25	35

Ayrıca model çıktılarının transformatör doluluk oranlarına etkisi Şekil 7’de gösterilmekte olup, önerilen model kullanıldığında kapasite kullanımının daha dengeli bir dağılım gösterdiği görülmektedir.



Şekil 7. CatBoost modeli kullanılarak elde edilen tahmini doluluk oranları ile mevcut reel doluluk oranlarının karşılaştırılması  
(Figure 7. Comparison between CatBoost predicted loading ratios and actual loading ratios)

Bunun yanı sıra geliştirilen modelin pratik uygulamalarda kullanılabilirliğini göstermek amacıyla kullanıcı etkileşimine sahip bir demo arayüz tasarlanmıştır. Model çıktılarının kullanıcı tarafından analiz edilebilmesini sağlayan bu arayüzün örnek ekran görüntüleri Şekil 8’de sunulmaktadır. Söz konusu arayüz, elektrik dağıtım şirketlerinin farklı veri setleri ile model çıktısını değerlendirmesine ve altyapı planlaması süreçlerinde karar destek aracı olarak kullanılmasına olanak sağlamaktadır.

<p>MESKEN_SAYI: 10 MESKEN_TG: 200,0</p> <p>SANAYI_SAYI: 0 SANAYI_KG: 0,0</p> <p>TARIMSAL_SAYI: 0 TARIMSAL_KG: 0,0</p> <p>BN_SAYI: 2 BOLGE_KENTSEL: 1</p> <p>BOLGE_KIRSAL: 0 KENTALTI: 0</p> <p>il: ANKARA ilce: ÇANKAYA</p> <p>mah: YAŞAMKENT</p> <p>Model Tahmini: "62.78547"</p>	<p>0 0,0</p> <p>TARIMSAL_SAYI: 0 TARIMSAL_KG: 0,0</p> <p>BN_SAYI: 2 BOLGE_KENTSEL: 1</p> <p>BOLGE_KIRSAL: 0 KENTALTI: 0</p> <p>il: ÇANKIRI ilce: MERKEZ</p> <p>mah: YENI</p> <p>Model Tahmini: "50.91197"</p>	<p>0 0,0</p> <p>TARIMSAL_SAYI: 0 TARIMSAL_KG: 0,0</p> <p>BN_SAYI: 2 BOLGE_KENTSEL: 1</p> <p>BOLGE_KIRSAL: 0 KENTALTI: 0</p> <p>il: ZONGULDAK ilce: DEVREK</p> <p>mah: ÇAY</p> <p>Model Tahmini: "42.846657"</p>
--	---	---

Şekil 8. Geliştirilen karar destek arayüzüne ait örnek ekran görüntüleri  
(Figure 8. Example screenshots of the developed decision support interface)

Elde edilen bulgular, veri temelli makine öğrenmesi modellerinin elektrik dağıtım sistemlerinde kapasite planlamasının iyileştirilmesine katkı sağlayabileceğini göstermektedir [20]. Özellikle yapı gruplarının elektrik talebinin daha doğru tahmin edilmesi, transformatör kapasite seçimlerinin daha gerçekçi yapılmasına ve altyapı yatırımlarının daha verimli planlanmasına olanak sağlayabilir. Bu çalışmada geliştirilen yaklaşımın yalnızca elektrik dağıtım sistemleri için değil, aynı zamanda imar planlaması ve altyapı master planlarının hazırlanması gibi farklı mühendislik uygulamalarında da kullanılabileceği değerlendirilmektedir. Veri temelli tahmin modellerinin altyapı planlamasına entegrasyonu, kamu kaynaklarının daha etkin kullanılmasına katkı sağlayabilir. İlgili dağıtım şirketinin yatırım verileri dikkate alındığında, önerilen yaklaşımın transformatör kapasite seçiminin optimize edilmesine katkı sağlayarak 2024 birim fiyatları ile yaklaşık 200 milyon TL düzeyindeki yatırım kaynağının alternatif altyapı iyileştirmelerine yönlendirilebilmesine olanak sağlayabileceği değerlendirilmektedir. Gelecek çalışmalar kapsamında veri setinin farklı coğrafi bölgeleri kapsayacak şekilde genişletilmesi ve gerçek zamanlı enerji tüketim verilerinin modele dahil edilmesi önerilmektedir. Ayrıca farklı makine öğrenmesi yöntemlerinin ve hibrit model yaklaşımlarının değerlendirilmesi, enerji talep tahmin doğruluğunun daha da artırılmasına katkı sağlayabilir. Sonuç olarak, bu çalışma elektrik dağıtım sistemlerinde veri temelli talep tahmini yaklaşımlarının uygulanabilirliğini ortaya koymakta ve elektrik altyapı planlamasında daha verimli, veri odaklı ve sürdürülebilir kapasite yönetimi için uygulanabilir bir metodoloji sunmaktadır.

#### SEMBOLLER

- Tr** : Transformatör  
**BN<sub>n</sub>** : n'inci bina enerjilendirme noktası  
**T<sub>n</sub>** : Yapı içerisindeki n'inci bağımsız tüketim noktası  
**kVA** : Kilovoltamper, görünür güç birimi  
**kW** : Kilowatt, aktif güç birimi  
**KG** : Kurulu güç  
**TG** : Talep gücü

#### **ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)**

Yazarlar çıkar çatışması bildirmemişlerdir.

#### **FİNANSAL AÇIKLAMA (FINANCIAL DISCLOSURE)**

Bu araştırmada finansal destek alınmamıştır.

#### **ETİK STANDARTLAR BEYANI (DECLARATION OF ETHICAL STANDARDS)**

Makalenin yazarı bu çalışmada kullanılan materyal ve yöntemler için etik kurul izni ve/veya yasal-özel izin almıştır.

#### **KAYNAKLAR (REFERENCES)**

- [1] Ceylan, O. ve Ozturk, B., (2020). Application of artificial neural networks in power distribution systems for load prediction. *International Journal of Electrical Power & Energy Systems*, 117:1-9.
- [2] Diaz-Acevedo, J.A., Grisales-Noreña, L.F., and Escobar, A., (2019). A method for estimating electricity consumption patterns of buildings to implement energy management systems. *Journal of Building Engineering*, 25:1-10.
- [3] Hahn, H., Meyer-Nieberg, S., and Pickl, S., (2009). Electric load forecasting methods: Tools for decision making. *European Journal of Operational Research*, 199(3):902-907.
- [4] Wang, X., Zhang, C., and Li, Y., (2018). Neural network approaches for electric load forecasting in smart grids. *IEEE Transactions on Smart Grid*, 9(3):1983-1993.
- [5] McLoughlin, F., Duffy, A., and Conlon, M., (2015). A clustering approach to domestic electricity load profile characterisation using smart metering data. *Applied Energy*, 141:190-199.
- [6] Wang, Z. and Hong, T., (2020). Generating realistic building electrical load profiles through generative adversarial networks. *Energy and Buildings*, 224:1-12.
- [7] Willis, H.L., (2002). *Power distribution planning reference book*. New York: Marcel Dekker.
- [8] Hong, T. and Fan, S., (2016). Probabilistic electric load forecasting: A tutorial review. *International Journal of Forecasting*, 32(3):914-938.
- [9] Deb, C., Zhang, F., Yang, J., Lee, S., and Shah, K., (2017). Time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74:902-924.
- [10] Fan, C., Xiao, F., and Wang, S., (2014). Development of prediction models for building energy consumption. *Energy and Buildings*, 75:17-26.
- [11] Zhang, G., Patuwo, B.E., and Hu, M.Y., (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1):35-62.
- [12] Dong, B., Cao, C., and Lee, S.E., (2005). Applying support vector machines to predict building energy consumption in tropical region. *Energy and Buildings*, 37(5):545-553.
- [13] Khosravi, A., Nahavandi, S., Creighton, D., and Atiya, A., (2013). Comprehensive review of neural network-based prediction intervals and new advances. *IEEE Transactions on Neural Networks and Learning Systems*, 22(9):1341-1356.
- [14] Breiman, L., (2001). Random forests. *Machine Learning*, 45(1):5-32.
- [15] Chen, T. and Guestrin, C., (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.

- [16] Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A.V., and Gulin, A., (2018). CatBoost: Unbiased boosting with categorical features. *Advances in Neural Information Processing Systems*, 31: 6638-6648.
- [17] Hyndman, R.J. and Koehler, A.B., (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4):679-688.
- [18] Li, K., Hu, C., Liu, G., and Xue, W., (2015). Building electricity consumption prediction using optimized artificial neural networks and principal component analysis. *Energy and Buildings*, 108:106-113.
- [19] Zhang, C., Ma, L., Han, X., and Zhao, T., (2023). Improving building energy consumption prediction using occupant-building interaction inputs and improved swarm intelligent algorithms. *Journal of Building Engineering*, 70:1-12.
- [20] Kang, X., An, J., and Yan, D., (2023). A systematic review of building electricity use profile models. *Energy and Buildings*, 279:1-15.