Mühendislik Bilimleri ve Tasarım Dergisi
14(2), 318-329, 2026
e-ISSN: 1308-6693

Journal of Engineering Sciences and Design
DOI: 10.21923/jesd.1862245

Araştırma Makalesi Research Article

HETEROJEN VERİ KAYNAKLARI VE ZAMANSAL MODELLER İLE GÜN ÖNCESİ TRANSFORMATÖR KESİNTİ RİSKİNİN TAHMİNİ İÇİN BİR ÖNGÖRÜCÜ BAKIM ÇERÇEVESİ

Tugay Eren GÜZELYOL[1*], Yavuz ATEŞ[2]

[1] Celal Bayar Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, Manisa, Türkiye
[2] Yıldız Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, İstanbul, Türkiye

Anahtar Kelimeler

Dağıtım Şebekeleri, Kestirimci Bakım, Makine Öğrenmesi, Transformatör Arızası, Zaman Serisi Modelleme.

Öz

Elektrik dağıtım şebekelerinde meydana gelen plansız kesintiler, şebeke güvenilirliğini düşürmekte ve işletme maliyetlerini artırmaktadır. Literatürde transformatör arızalarına yönelik çalışmalar çoğunlukla DGA ve durum indeksi temelli analizlere odaklanmakta olup, gerçek saha verileri ve meteorolojik değişkenler kullanılarak günlük kesinti riski tahmini yapan sınırlı sayıda çalışma bulunmaktadır. Bu çalışmada, İzmir ve Manisa illerinde bulunan 34 güç transformatörüne ait 2021–2024 yılları arasındaki 8.671 kesinti kaydı, bölgesel meteorolojik veriler ve varlık temelli teknik parametreler ile entegre edilerek bir gün önceden arıza riski tahmini gerçekleştirilmiştir. Çalışma kapsamında doğrusal, ağaç tabanlı ve gradyan artırmalı yaklaşımları temsil eden seçili makine öğrenmesi modelleri karşılaştırmalı olarak değerlendirilmiştir. Modeller zaman serisi çapraz doğrulama stratejisi ile eğitilmiş ve 2024 yılının son çeyreği ayrılmış test seti üzerinde analiz edilmiştir. Performans değerlendirmesinde dengesiz sınıf yapısını dikkate alan G-Mean metriği temel alınmış olup, gradyan artırmalı modellerin G-Mean değerinde 0.627 ve ROC-AUC değerinde 0.663 performans sergilediği görülmüştür. Elde edilen bulgular, gerçek saha verileri üzerinde günlük kesinti risk tahmini için metodolojik bir karşılaştırma çerçevesi sunmakta ve dağıtım şebekelerinde kestirimci bakım stratejilerinin geliştirilmesine katkı sağlamaktadır.

A PREDICTIVE MAINTENANCE FRAMEWORK FOR DAY-AHEAD TRANSFORMER OUTAGE RISK ESTIMATION USING HETEROGENEOUS DATA AND TEMPORAL MODELS

Keywords

Distributin Networks, Machine Learning, Predictive Maintenance, Time-Series Modeling, Transformer Outage.

Abstract

Unplanned outages in electricity distribution networks reduce system reliability and increase operational costs. Existing studies on transformer failures predominantly focus on Dissolved Gas Analysis (DGA) and condition index–based long-term health assessment approaches, while studies performing day-ahead operational risk prediction using real field outage records integrated with meteorological variables remain limited.In this study, day-ahead failure risk prediction is performed by integrating 8,671 outage records from 34 power transformers located in İzmir and Manisa provinces between 2021 and 2024 with regional meteorological data and asset-specific technical parameters. Selected machine learning models representing linear, tree-based, and gradient boosting approaches are comparatively evaluated. The models are trained using a time-series cross-validation strategy and assessed on an independent test set corresponding to the last quarter of 2024.Considering the imbalanced nature of the dataset, G-Mean is adopted as the primary evaluation metric. On the test set, gradient boosting–based models achieve a G-Mean of 0.627 and a ROC-AUC of 0.663. The findings provide an operationally applicable decision-support framework for day-ahead outage risk prediction based on real field data and contribute to the development of predictive maintenance strategies in distribution networks.

Alıntı / Cite

Güzelyol, T.E., Ateş, Y (2026). Heterojen Veri Kaynakları ve Zamansal Modeller ile Gün Öncesi Transformatör Kesinti Riskinin Tahmini için Bir Öngörücü Bakım Çerçevesi, Mühendislik Bilimleri ve Tasarım Dergisi, 14(2), 318-329.

Yazar Kimliği / Author ID (ORCID Number)
T.Eren GÜZELYOL, 0009-0008-2216-3181
Y.ATEŞ, 0000-0002-4168-0861

Makale Süreci / Article Process	
Başvuru Tarihi / Submission Date	12.01.2026
Revizyon Tarihi / Revision Date	05.03.2026
Kabul Tarihi / Accepted Date	24.03.2026
Yayım Tarihi / Published Date	30.06.2026

[*] İlgili yazar / Corresponding author: tugayerenguzelyol@gmail.com, +90 507 591 70 98

A PREDICTIVE MAINTENANCE FRAMEWORK FOR DAY-AHEAD TRANSFORMER OUTAGE RISK ESTIMATION USING HETEROGENEOUS DATA AND TEMPORAL MODELS

Tugay Eren GÜZELYOL[1†], Doç. Dr. Yavuz ATEŞ[2]

[1] Celal Bayar Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, Manisa, Türkiye
[2] Yıldız Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, İstanbul, Türkiye

Highlights

- A data-driven day-ahead transformer outage risk prediction framework is developed using real distribution network data.
- The model integrates meteorological variables, asset-specific technical parameters, and historical outage records.
- A structured comparison of representative linear, tree-based, and gradient boosting models is conducted under time-series validation.
- The proposed framework supports proactive maintenance planning and contributes to SAIDI/SAIFI performance improvement

Purpose and Scope

This study aims to develop and comparatively evaluate machine learning models for day-ahead power transformer outage risk prediction in distribution networks. By focusing on short-term operational forecasting using real outage records and meteorological variables, the study seeks to enhance grid reliability and support data-driven maintenance decision-making processes.

Design/methodology/approach

The study utilizes 8,671 outage events recorded between 2021 and 2024 from 34 transformers located in İzmir and Manisa, Türkiye. These records are integrated with regional meteorological data and transformer-specific technical parameters.The proposed pipeline includes outlier handling, time-series–based lag and rolling feature engineering, scaling procedures, and class imbalance mitigation strategies.To ensure methodological clarity and interpretability, selected representative models from linear, tree-based, and gradient boosting families (Logistic Regression, Random Forest, XGBoost, and LightGBM) are comparatively evaluated. Models are trained using time-series cross-validation and assessed on a strict out-of-sample test set corresponding to the last quarter of 2024. Considering the imbalanced nature of outage data, G-Mean is adopted as the primary evaluation metric.

Findings

Gradient boosting models demonstrate the most balanced performance in terms of sensitivity and specificity, achieving a test G-Mean of 0.619 and ROC-AUC of 0.665. The integration of meteorological and asset-level data improves model robustness and operational relevance. The framework produces interpretable risk scores that can be directly incorporated into maintenance planning workflows.

Research limitations/implications

The dataset is limited to 34 transformers within two distribution regions in Türkiye. Therefore, further validation across different geographical contexts and asset categories is required to assess broader generalizability. Future studies may incorporate real-time streaming data and adaptive learning mechanisms to enhance dynamic risk prediction.

Practical implications

The proposed approach provides a structured decision-support tool for proactive maintenance scheduling. By enabling day-ahead outage risk estimation, distribution companies can improve resource allocation efficiency, reduce unplanned downtime, and better comply with regulatory reliability indicators such as SAIDI and SAIFI.

Social Implications

Reducing transformer-related outages contributes to improved service continuity, economic productivity, and overall quality of life. The framework supports more resilient and sustainable distribution network operations.

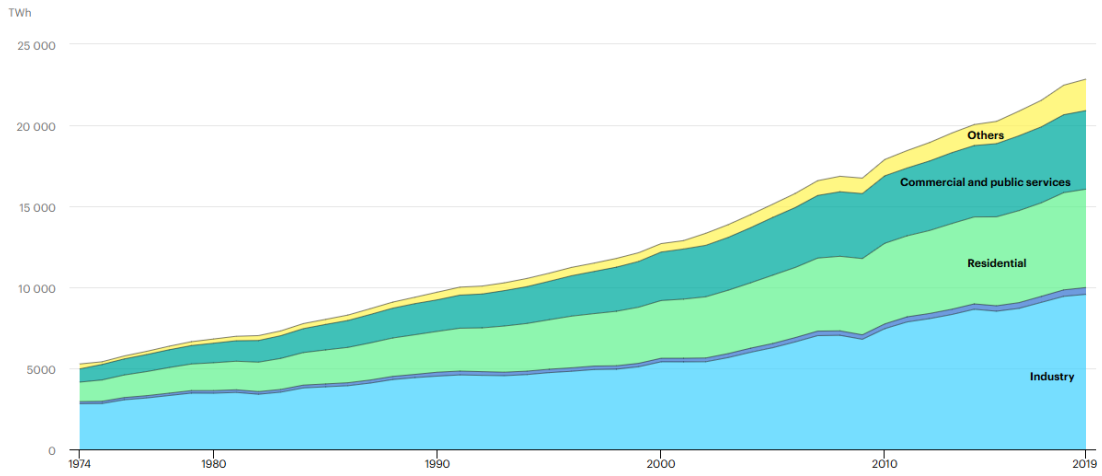
Originality

This study introduces an operationally focused day-ahead outage risk prediction framework based on real field data, integrating meteorological and asset-level information within a time-series evaluation setting. Unlike studies centered on long-term condition assessment (e.g., DGA-based analysis), this work emphasizes short-term operational forecasting under class imbalance conditions and provides a structured comparative evaluation of representative machine learning approaches.

† Corresponding author: tugayerenguzelyol@gmail.com, +90 507 591 70 98

1. Giriş (Introduction)

Güvenilir, yüksek kaliteli ve kesintisiz elektrik arzı, modern ekonomiler ve toplumlar için temel bir gereklilik olmaya devam etmektedir (Akcanca ve Taşkın, 2013). Artan elektrik tüketimi, hızlı kentleşme, sektörlerin elektrifikasyonu ve dijital altyapıların yaygınlaşması, dağıtım şebekeleri üzerindeki yükü giderek artırmaktadır. Şekil 1'de görüldüğü üzere, küresel ölçekte elektrik tüketimi özellikle sanayi, konut ve ticari sektörlerde düzenli bir artış eğilimi göstermektedir (The International Energy Agency (IEA), 2021). Bu artış, dağıtım sistemlerinde süreklilik ve güvenilirlik gereksinimlerini daha kritik hâle getirmektedir.



Şekil 1 elektrik tüketiminin yıllara göre sektör bazında artışı (Increase in electricity consumption by sector over the years)(The International Energy Agency (IEA), 2021)

Bu bağlamda, dağıtım seviyesinde meydana gelen plansız transformatör kesintileri, hizmet sürekliliğini zayıflatmakta ve düzeltici bakım maliyetlerini artırmaktadır. Ayrıca bu kesintiler, SAIDI (Sistem Ortalama Kesinti Süresi) ve SAIFI (Sistem Ortalama Kesinti Sıklığı) gibi regülasyon temelli performans göstergeleri açısından dağıtım şirketleri için uyumsuzluk riski oluşturmaktadır (Akcanca ve Taşkın, 2013), (Papic vd., 2014). İklim değişikliği ve aşırı hava olayları da bu riski artıran önemli faktörler arasında yer almaktadır. Konvektif fırtınalar, şiddetli yağışlar, ısı dalgaları ve yıldırım gibi meteorolojik olayların kesinti sıklığı ve süresi üzerindeki etkileri literatürde kapsamlı biçimde raporlanmıştır (Forsberg vd., 2023), (Visakh & Selvan, 2023), (Campbell, 2013).

Literatürde transformatör arızalarının değerlendirilmesine yönelik çalışmalar ağırlıklı olarak çözünmüş gaz analizi (DGA), durum indeksi temelli sağlık değerlendirmeleri ve uzun dönemli bakım optimizasyonu yaklaşımlarına odaklanmaktadır. Bu çalışmalar varlık sağlığının izlenmesi açısından önemli katkılar sunmakla birlikte, günlük operasyonel karar destek mekanizmalarına doğrudan entegre edilebilecek kısa vadeli arıza risk tahmin modelleri sınırlı kalmaktadır. Özellikle gerçek saha kesinti kayıtlarının meteorolojik ve varlık temelli parametrelerle bütünleşik biçimde ele alındığı ve zaman serisi doğrulama yaklaşımı ile değerlendirildiği çalışmalar görece azdır.

Küresel ölçekte elektrik sistemleri yapısal bir dönüşüm sürecinden geçmektedir. Yenilenebilir enerji kaynaklarının artışı, ulaşım ve ısınmanın elektrifikasyonu ile veri merkezlerinin büyümesi, talep profillerini ve şebeke işletme dinamiklerini daha değişken hâle getirmiştir. Bu dönüşüm, dağıtım seviyesinde kestirimci bakım uygulamalarını tercihe bağlı bir optimizasyon aracı olmaktan çıkararak, arz güvenliği ve maliyet kontrolü açısından temel bir gereklilik hâline getirmektedir.

Bu çalışma, Türkiye'nin İzmir ve Manisa illerinde bulunan 34 güç transformatörüne ait 2021–2024 yılları arasındaki gerçek kesinti kayıtlarını meteorolojik veriler ve varlık temelli teknik parametrelerle entegre ederek, bir gün önceden arıza riski tahmini gerçekleştirmektedir. Çalışma kapsamında doğrusal, ağaç tabanlı ve gradyan artırmalı yaklaşımları temsil eden seçili makine öğrenmesi modelleri karşılaştırmalı olarak değerlendirilmiştir. Modeller zaman serisi çapraz doğrulama stratejisi ile eğitilmiş ve bağımsız bir test seti üzerinde analiz edilmiştir. Bu yönüyle çalışma, uzun dönemli sağlık değerlendirme yaklaşımlarından ayrışarak, günlük operasyonel bakım planlamasına yönelik veri temelli bir karar destek çerçevesi sunmaktadır.

2. Literatür Taraması (Literature Review)

Dağıtım şebekelerinde hava koşullarına bağlı kesinti modelleme çalışmaları son yıllarda önemli ölçüde artmıştır. Özellikle aşırı hava olaylarının şebeke güvenilirliği üzerindeki etkileri; SAIDI ve SAIFI göstergeleri bağlamında analiz edilmiştir (Akcanca ve Taşkın, 2013), (Campbell, 2013). ABD, Çin ve Avrupa odaklı çalışmalarda meteorolojik değişkenler ile kesinti oranları arasındaki ilişkiler ağaç tabanlı ve regresyon modelleri ile modellenmiştir (Yuyama vd., 2018), (Ren vd., 2021), (Taylor vd., 2023a), (Doostan & Chowdhury, 2020). Bununla birlikte bu çalışmaların önemli bir bölümü iletim hattı veya müşteri bazlı kesinti oranlarına odaklanmakta; ekipman seviyesinde arıza riski modellemesi sınırlı kalmaktadır.

Geleneksel önleyici bakım stratejileri, periyodik kontrollerle arıza ortaya çıktıktan sonra müdahale etmeye odaklanmakta ve bu durum plansız elektrik kesinti sürelerinin ve bakım maliyetlerinin artmasına, vardiya planlamalarında eksikliklere yol açmaktadır (Zaldivar vd., 2023). Bu yetersizliği gidermek amacıyla literatürde kestirimci bakım yaklaşımı ön plana çıkarak, makine öğrenmesi ve derin öğrenme yöntemleriyle çok boyutlu veri analizine dayalı öngörü modelleri geliştirilmiştir (Qian vd., 2020), (Rexhepi, 2017), (Z. Xu vd., 2022).

Transformatör odaklı kestirimci bakım çalışmalarında ise ağırlıklı olarak çözünmüş gaz analizi (DGA) ve izolasyon sağlığı temelli yaklaşımlar benimsenmiştir (Qian vd., 2020), (Gamel vd., 2024),. LSTM tabanlı zaman serisi tahminleri (F. Xu vd., 2025), (Zhao vd., 2023), (Thomas & K.V., 2023), entropi ağırlıklı TOPSIS ve gri model yaklaşımları (Jin-Qiang, 2019) ve derin sinir ağları ile DGA sınıflandırmaları (Gamel vd., 2024) literatürde yer almaktadır. Ancak bu çalışmalar genellikle sınırlı örneklem büyüklüğü, laboratuvar veya fabrika çıkış verileri ve kısa dönemli izleme pencereleri ile sınırlandırılmıştır. Gerçek saha kesinti kayıtlarının meteorolojik değişkenlerle bütünleşik ele alındığı çalışmalar nispeten azdır.

Elektrik kesintileri, şebekede yürütülen planlı bakım faaliyetlerinden veya şebekede meydana gelen beklenmedik durumlar sonucu oluşan plansız durumlardan kaynaklanabilir. Planlı kesintiler genellikle şebeke iyileştirmeleri, ekipman yenileme veya rutin bakım faaliyetlerini içermekte olup, genellikle önceden kullanıcıya bildirilen programlı müdahalelerdir. Plansız kesintiler ise genellikle öngörülemeyen teknik arızalar, hava koşullarına bağlı dış etkenler veya insan kaynaklı yönetimsel hatalardan kaynaklanmaktadır (Campbell, 2013), (Tuttokmağı & Kaygusuz, 2019). Bu noktada, plansız kesintileri önceden tahmin etmek ve müdahale etmek üzere geliştirilen kestirimci bakım yaklaşımları literatürde yoğun şekilde incelenmektedir.

PACME Çalışma Grubu tarafından yapılan çalışmada, bağımlı ve ortak mod kesintilerin elektrik sistemlerindeki güvenilirlik analizlerinde ihmal edilen ancak kritik öneme sahip bileşenler olduğu ortaya koyulmuş ve zaman serisi tabanlı kestirimci bakım ile anomali tahmin modelleri bağlamında çevresel ve sistemik risklerin daha doğru değerlendirilmesi için bir kavramsal çerçeve sunulmuştur (Papic vd., 2014).

Kestirimci bakım uygulamalarında yapay zekâ teknolojilerinin kullanımına ilişkin temel bileşenler, güvenilirlik gereksinimleri ve geleceğe dönük eğilimler sistematik biçimde ele alınan bir başka çalışmada; sensör verilerinin ön işlenmesi, makine öğrenmesi ve derin öğrenme algoritmaları, karar verme modülleri, iletişim ve entegrasyon altyapısı ile kullanıcı arayüzü ve raporlama katmanları tanımlanarak kapsamlı bir bakış sunulmuştur (Ucar vd., 2024). Bu çalışmaya ek olarak, arıza verilerinin LS-SVM ile zaman serisi tahmini ve iki katmanlı optimizasyonla maliyet ile plansız kesinti kayıplarının birlikte minimize edilmesi sağlanmıştır (Jian & Tianyuan, 2015). Özellikle arıza-kesinti-maliyet fonksiyonunun kullanımı, bakım frekansının hem ekonomik hem de operasyonel etkilerini eş zamanlı değerlendirme imkânı sunarak, kestirimci bakım süreçlerinin gerçek dünya uygulamalarında optimize edilmesine güçlü bir metodolojik katkı sağlamaktadır.

Bir başka çalışmada ise izolatörlerin durum indekslerine dayalı öngörücü bakım metodolojisiyle bakım kaynaklarının etkin dağıtımına imkân tanınmıştır. Polimer izolatörlerin çok boyutlu fiziksel ve kimyasal testlerinden elde edilen verileri birden fazla durum indeksine dönüştürerek, kalan ömür tahmininde esnek ve kapsamlı bir yaklaşım sunulmuştur. Bu indeks tabanlı bakım stratejisi, saha uygulamalarında bakım kaynaklarının etkin dağıtımını sağlayarak operasyonel fayda yaratmakta ve bakım zamanlamasını optimize ederek ekipman sağlığı izlemi açısından oldukça önemlidir (Norouzi, 2025).

Bunun yanı sıra, trafo buşing izolasyon durumu üzerinden arıza eğilimini tahmin etmeyi amaçlayan bir çalışmada, bilgi entropisi ile belirlenmiş göstergelerin ağırlıklandırılması için "Entropy-Weight TOPSIS" yöntemi kullanılmıştır; güncel test verilerinin ideal izolasyon durumlarına olan uzaklığı niceliksel olarak hesaplanmış ve elde edilen yakınlık derecelerinden oluşan zaman serisi verisi, gri model ile ileriye dönük olarak öngörülmüştür (Jin-Qiang, 2019). Ancak bu çalışma sadece buşing arızalarına odaklanmış ve veri büyüklüğü açısından sınırlı üç test kaydı üzerinde yürütülmüş olması nedeniyle genellenebilirliği açısından kısıtlıdır.

Transformatörlerdeki izolatörler ve burçların izolasyon durumu üzerinden yapılan çalışmalardan farklı olarak, güç transformatörlerindeki arızaların önceden tespiti amacıyla, trafo yağındaki çözünmüş gaz (Dissolved Gas Analysis, DGA) verilerinin zaman serisi özelliklerini kullanarak LSTM sinir ağı tabanlı bir tahmin modeli geliştirilmiştir. Bu çalışmada, bir aylık DGA izleme verisinden hareketli pencere yöntemiyle oluşturulan eğitim ve test kümeleri üzerinde pencere uzunlukları (3, 6, 12, 20) ile LSTM katman sayısı ve düğüm sayısı (tek katman–6/12/20 düğüm, iki katman–12 düğüm) deneysel olarak karşılaştırılmıştır. Model performansı, beş gaz için hesaplanan MAPE ve RMSE metrikleri ile değerlendirilmiş ve en düşük bileşik hata skorunu veren tek katmanlı, 12 düğümlü yapı tercih edilmiştir. Çalışma, veri setinin nispeten küçük olması, eksik veri tamamlama yöntemlerinin basit interpolasyonla sınırlı olması ve modelin gerçek zamanlı uygulamalarda genellenebilirliğinin henüz test edilmemiş olması gibi sınırlamalara işaret etmiştir (Qian vd., 2020).

Bu çalışmaya ek olarak, güç transformatörlerinin fabrika çıkışı DGA verilerine dayalı arıza tanı tahminlerinde sınıf dengesizliği sorununu aşmak amacıyla SMOTE ile oluşturulan sentetik örnekler ve derin sinir ağı (DNN) mimarisi hibrit bir yaklaşımla birleştirilmiştir. Araştırmada, transformatörlerden elde edilen veri seti SMOTE uygulamasıyla dengeye kavuşturulmuş; ardından çok katmanlı DNN modeli, yüksek seviyeli özellik çıkarımı yaparak %98,22 eğitim ve %94,6 test doğruluğu elde edilmiştir (Gamel vd., 2024).

Belçika elektrik iletim şebekesinde farklı zaman dilimlerinde yapılması planlanan bakım faaliyetlerinin güvenli şekilde gerçekleştirilip gerçekleştirilemeyeceğini tahmin etmek amacıyla; karar ağaçları, SVM ve Naive Bayes gibi sınıflandırma algoritmaları karşılaştırılmıştır. En yüksek başarıyı %98,4 doğruluk oranı ile Random Forest algoritması göstermiştir. Yöntem; sistemdeki yük, hava durumu ve üretim koşulları gibi parametrelere dayanarak bakım faaliyetlerinin riskli olup olmadığını ikili sınıflandırma problemi olarak modellemiştir (Toubeau vd., 2022).

Bilimsel açıdan dağıtım varlıklarının kestirimci bakımı; güç sistemi güvenilirliği, istatistiksel öğrenme ve yöneylem araştırmasının kesişiminde konumlanmaktadır. Literatürde çözünmüş gaz analizi (DGA), kesinti süresi modellemesi ve altyapı kırılganlık haritalaması; genelleştirilmiş doğrusal modellerden ağaç tabanlı ve yinelemeli sinir ağlarına uzanan geniş bir yöntem setiyle ele alınmıştır (Doostan & Chowdhury, 2020), (Qian vd., 2020), (Ucar vd., 2024). Ayrıca; literatürde dağıtım şebekelerinde hava durumu güdümlü kesinti analizi çoğunlukla ekstrem hava koşulları (kasırga, sel, fırtına vb.) için yapılmıştır (Zhou vd., 2014), (Taylor vd., 2023b), (Forsberg vd., 2023), (Visakh & Selvan, 2023), (Cruz & Munasinghe, 2023). (Fatima vd., 2024). Etkili sayılabilecek bazı çalışmalar sınırlı ortak değişken kümelerine dayanmaktadır. Bu durum mevsimler, coğrafyalar ve varlık türleri arasında genellenebilirliği kısıtlamaktadır. Sınıf dengesizliği problemi elektrik kesinti tahmin çalışmalarında temel metodolojik zorluklardan biridir. SMOTE tabanlı veri dengeleme (Gamel vd., 2024) ve maliyet duyarlı öğrenme yaklaşımları (Doostan & Chowdhury, 2020) literatürde önerilmiştir. Ancak zaman serisi doğrulama stratejileri ile birlikte, ekipman bazlı ve meteorolojik değişkenlerle zenginleştirilmiş dengesiz veri modellemesi çalışmalarının sayısı sınırlıdır (Wang vd., 2021).

Literatürdeki çalışmalar; meteorolojik veriler, arıza kayıtları ve varlık metaverilerinin entegrasyonu, sınıf dengesizliğiyle başa çıkma, zaman serisi modelleme ve çeşitli algoritmaların karşılaştırılması gibi temalar etrafında şekillenmektedir. Genel olarak bu çalışmalar ayrı ayrı ele alındığı görülmektedir. Ayrıca; meteorolojik verilerle yapılan çalışmaların ekstrem hava muhalefetlerine odaklanması veya bölgesel tahmin yapması, transformatör arızaları için DGA ve izleme metodolojilerinin uygulanması ve dengesiz veri seti ile çalışılmasına yönelik sentetik veri üretimi (SMOTE) metodolojisine odaklanılması gözlemlenmiştir.

Bu çalışma kapsamında sunulan ise; dengesiz sınıf yapısını dikkate alan G-Mean metriği temel alınması, bölgesel veya ekstrem hava koşulu şartı koşulmaksın geçmiş kesinti verileri, hava durumu verileri ve varlık envanter verileriyle güç transformatörlerinde gün öncesi kesinti tahmini yapılmasını kapsamaktadır. Çalışma kapsamında doğrusal, ağaç tabanlı ve gradyan artırmalı yaklaşımları temsil eden seçili makine öğrenmesi modelleri karşılaştırmalı olarak değerlendirilmiştir.

3. Yöntem (Method)

3.1 Problem Tanımı (Problem Definition)

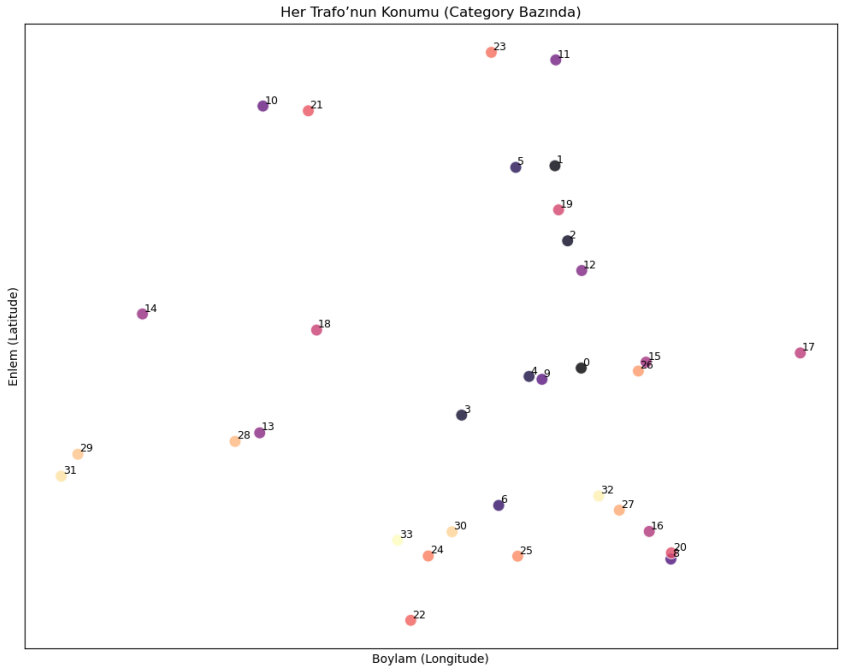
Makale kapsamında yapılan çalışmada dağıtım şebekelerinde transformatör seviyesinde bir gün önceden kesinti var/yok tahmini problemine odaklanmaktadır. Problem, ikili sınıflandırma (binary classification) çerçevesinde ele alınmıştır. Makalenin amacı, her bir transformatör için $t + 1$ günü itibarıyla kesinti oluşma olasılığını tahmin ederek operasyonel karar destek mekanizmasına katkı sağlamaktır. Veri yapısının zamana bağımlı ve sınıf dengesiz olması nedeniyle modelleme süreci bu iki temel kısıt dikkate alınarak tasarlanmıştır.

3.2 Veri Seti ve Özellik Yapısı (Dataset and Feature Structure)

Çalışmada, İzmir ve Manisa illerinde bulunan 34 güç transformatörüne ait 2021–2024 yılları arasındaki 8.671 kesinti kaydı kullanılmıştır. Kesinti olayları meteorolojik değişkenler ve transformatörlere ait teknik parametreler ile entegre edilmiştir. Toplam veri seti 48.213 günlük (trafo sayısı x zaman) gözlemden oluşmaktadır.

- Kullanılan değişkenler üç ana grupta toplanmaktadır:
- Meteorolojik değişkenler (sıcaklık, hissedilen sıcaklık, rüzgâr hızı, güneşlenme süresi vb.)
- Varlık temelli teknik parametreler
- Zamansal türetilmiş özellikler (lag ve rolling istatistikleri)

Veri seti sınıf dengesizliği içermektedir; kesinti gözlemleri toplam veri içinde azınlık sınıfı oluşturmaktadır.



Şekil 2 Transformatörlerin haritalandırılması (Mapping of the transformers)

Şekil 2'ye göre konumsal olarak transformatöre mesafeleri incelendiğinde 8 numaralı ve 20 numaralı transformatörlerin konum olarak yakın olduğu tespit edilmiştir. 4,9,15 ve 26 numaralı transformatörler için de benzer bir durum bulunmaktadır.

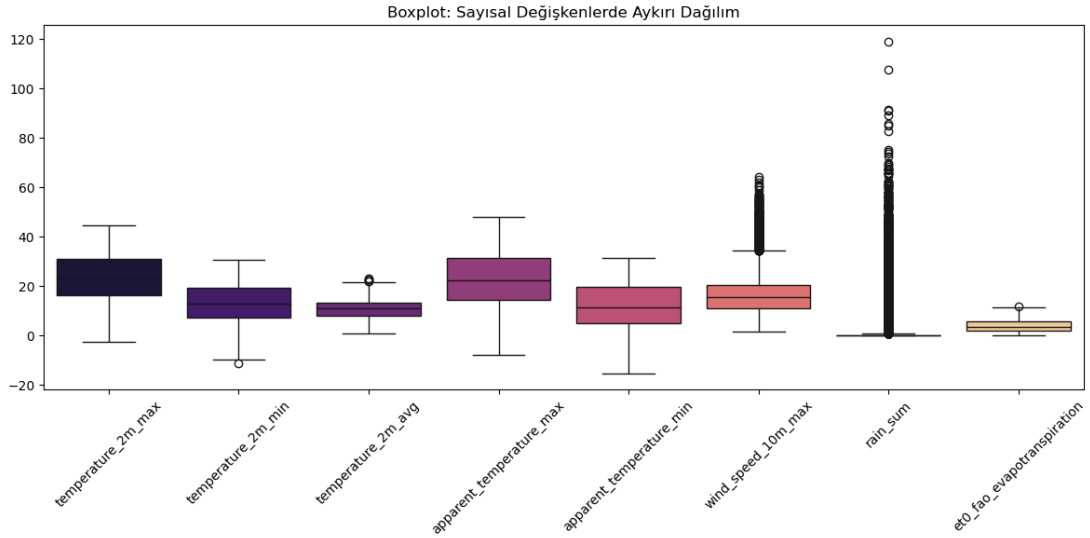
3.2 Veri Ön İşleme Süreci (Data Preprocessing Process)

Veri ön işleme adımları tek bir boru hattı (pipeline) yapısı altında sistematik olarak uygulanmıştır:

- Eksik ve tutarsız veri kontrolü
- Aykırı değer analizi
- Kategorik değişken kodlama
- Ölçekleme
- Sınıf dengesizliği stratejileri

3.3.1 Aykırı Değer Analizi (Outlier Analysis)

Sayısal değişkenlerde aykırı değer dağılımları BoxPlot analizi ile incelenmiştir (Şekil-3). Aykırı gözlemler doğrudan silinmemiş; bunun yerine aykırı durumu gösteren ek bir gösterge (veriler Boolean tabanlı yeni bir değişken aracılığıyla işaretlenmiş) değişken oluşturulmuştur. Böylece modelin uç davranış örüntülerini öğrenmesine imkân tanınmıştır.



Şekil-3: Sayısal değişkenlerde aykırı dağılımın boxplot ile gösterimi (Illustration of outlier distribution in numerical variables using box plot)

3.3.2 Kategorik Değişken Kodlama (Categorical Variable Encoding)

Doğal sıralama içermeyen kategorik değişkenler için One-Hot Encoding uygulanmıştır. Bu yöntem, özellikle doğrusal modellerde sahte sıralama etkisinin önüne geçmek amacıyla tercih edilmiştir.

3.3.3 Ölçekleme (Scaling)

Sürekli değişkenler için Robust Scaler ve Min-Max Scaler yöntemleri denenmiş; zaman serisi yapısı korunarak ölçekleme yalnızca eğitim verisi üzerinde öğrenilmiş ve test setine uygulanmıştır.

3.3.4 Sınıf Dengesizliği Yönetimi (Class Imbalance Management)

Kesinti verisinin dengesiz yapısı nedeniyle üç farklı strateji değerlendirilmiştir:

- Rastgele alt örnekleme (undersampling)
- SMOTE ile sentetik örnek üretimi
- Sınıf ağırlıklandırma (class_weight)

Bu stratejiler model bazında karşılaştırmalı olarak test edilmiş; nihai model seçiminde test performansı esas alınmıştır.

3.4 Zamansal Özellik Çıkarımı (Temporal Feature Extraction)

Kısa dönemli bağımlılıkları (mevsimsellik, sezonsallık ve haftalık döngüleri) yakalayabilmek amacıyla aşağıdaki zamansal özellikler türetilmiştir:

- Gecikmeli değişkenler (lag features)
- Hareketli ortalamalar, kayan pencere (rolling mean)
- Hareketli standart sapma değerleri

Bu yapı, özellikle meteorolojik değişkenlerin gecikmeli etkilerini modelleyebilmek amacıyla tasarlanmıştır.

3.5 Model Seçim Stratejisi (Model Selection Strategy)

Bu çalışmada, farklı karar sınırı ve öğrenme paradigmasını temsil eden dört model ailesi seçilmiştir:

- Lojistik Regresyon → Doğrusal karar sınırı (baseline model)
- Random Forest → Bagging temelli ağaç topluluğu
- XGBoost → Gradyan artırma yaklaşımı
- LightGBM → Histogram tabanlı optimize edilmiş gradyan artırma
- Gradient Boosting -> Temel Gradyan artırma yaklaşımı

Model seçimi, literatürde yaygın kullanılan ancak farklı hipotez uzaylarını temsil eden yöntemlerin sistematik karşılaştırılmasına dayanmaktadır. Amaç, model çeşitliliğini artırmak değil; temsili algoritmalar üzerinden metodolojik karşılaştırma yapmaktır.

3.6 Hiper parametre Optimizasyonu (Hyperparameter Optimization

Tüm modeller için hiper parametre optimizasyonu Optuna kütüphanesi kullanılarak yürütülmüştür. Optimizasyon süreci zaman serisi çapraz doğrulama yapısı içinde gerçekleştirilmiştir. Erken durdurma (early stopping) ve aşırı uyumu önleyici parametreler (regularization, subsampling oranları vb.) dikkate alınmıştır.

3.7 Zaman Serisi Doğrulama Stratejisi (Time Series Validation Strategy)

Veri sızıntısını önlemek amacıyla klasik rastgele çapraz doğrulama yerine Time-Series Split (TSS) uygulanmıştır.

- Eğitim verisi artan pencere mantığıyla bölünmüştür.
- 2024 yılının son çeyreği tamamen bağımsız test seti olarak ayrılmıştır.
- Nihai performans değerlendirmesi yalnızca bu out-of-sample test seti üzerinde yapılmıştır.

Bu yaklaşım, modellerin zamana bağlı genelleme kabiliyetini ölçmeyi amaçlamaktadır.

3.8 Performans Metrikleri (Performance Metrics)

Sınıf dengesizliği nedeniyle doğruluk (accuracy) metriği tercih edilmemiştir.

Birincil değerlendirme metriği olarak G-Mean kullanılmıştır. G-Mean, pozitif ve negatif sınıfların başarı oranlarının geometrik ortalaması anlamına gelip sınıflar arası dengeyi gözetmektedir :

$$G\ MEAN = \sqrt{Duyarlılık\ x\ Özgüllük} = \sqrt{\frac{TP}{TP+FN}} \times \sqrt{\frac{TN}{TN+FP}} \quad (1)$$

Bu metrik, azınlık ve çoğunluk sınıfları arasındaki dengeyi ölçmektedir.

Destekleyici metrikler olarak “ROC-AUC” , “Recall” ve “Karışıklık matrisi analizi” değerlendirilmiştir. Model karşılaştırmaları test seti performansları üzerinden gerçekleştirilmiştir.

4. Sonuç (Conclusion)

Makine öğrenmesi algoritmaları için oluşturulan eğitim veri setleri 2024 yılının son çeyreği için manuel olarak denenmiş olup daha sonrasında çapraz doğrulama yapılması için TSS uygulaması da yapılmıştır. Modelleme sürecinde zaman bağımlılığını dikkate alan doğrulama stratejisi uygulanmış ve nihai performans değerlendirmesi 2024 yılının son çeyreğini içeren bağımsız dış test seti üzerinden yapılmıştır.

Modelleme çerçevesinde doğrusal ve topluluk temelli makine öğrenmesi algoritmaları (Logistic Regression, Random Forest, XGBoost, LightGBM ve Gradient Boosting) karşılaştırmalı olarak değerlendirilmiştir. Sınıf dengesizliği problemi; SMOTE, undersampling ve class_weight yaklaşımları ile ele alınmış, hiper parametre optimizasyonu Optuna aracılığıyla gerçekleştirilmiştir.

Tablo-1’de optimize edilmiş modellerin 2024-Q4 dış test seti üzerindeki G-Mean ve ROC-AUC performansları sunulmaktadır. Sonuçlar, gradyan artırmalı yöntemlerin tutarlı biçimde daha dengeli performans sunduğunu göstermektedir. Threshold değeri özelinde yapılan optimizasyon sonuçlarında temel alınan 0,5 değerinden daha

küçük, azınlık sınıfa (kesinti olma durumuna) yönelik eğilimleri belirlenmiştir.

Tablo 1. Model performans değerlendirmeleri (Model Performance Evaluations)

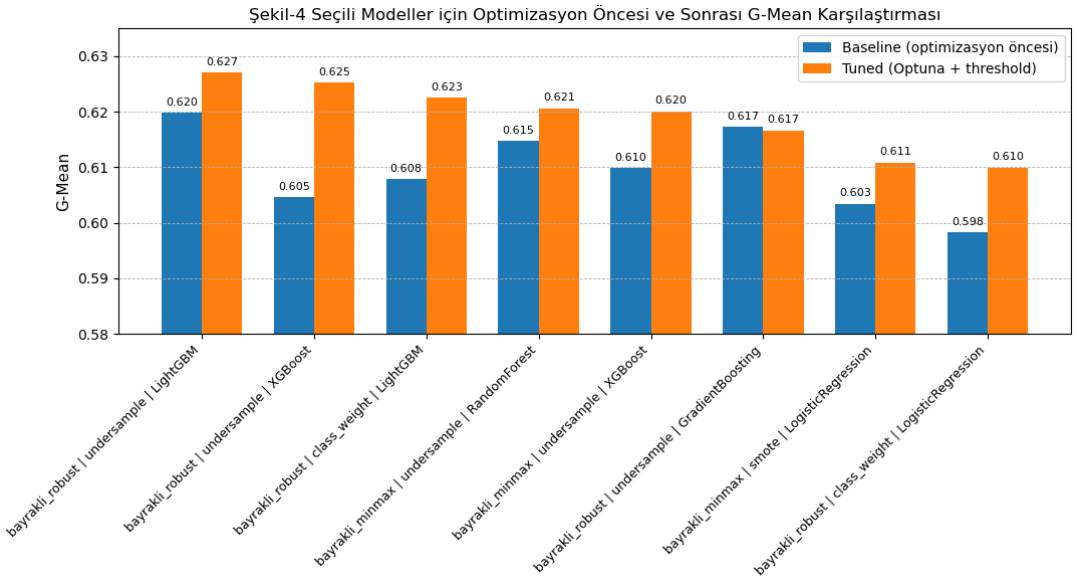
Varyant	Örnekleme	Model	G-Mean	ROC-AUC	Optimum Threshold
bayrakli_robust	undersample	LightGBM	0.627	0.663	0.48
bayrakli_robust	undersample	XGBoost	0.625	0.662	0.48
bayrakli_robust	class_weight	LightGBM	0.623	0.663	0.16
bayrakli_minmax	undersample	Random Forest	0.621	0.660	0.44
bayrakli_minmax	undersample	XGBoost	0.620	0.663	0.45
bayrakli_robust	undersample	Gradient Boosting	0.617	0.664	0.44
bayrakli_minmax	smote	Lojistik Regresyon	0.611	0.653	0.44
bayrakli_robust	class_weight	Lojistik Regresyon	0.610	0.655	0.15

Elde edilen G-Mean değerlerinin sınırlı düzeyde kalması, yalnızca kullanılan yeniden örnekleme stratejilerinin yetersizliğine değil, aynı zamanda mevcut öznitelik setinin kesinti oluşumunu ayırt etme kapasitesinin sınırlı olmasına da işaret etmektedir. SMOTE, undersampling ve class_weight gibi yaklaşımlar azınlık sınıfının öğrenme sürecindeki temsilini iyileştirmiş olsa da sınıflar arasındaki ayrımı belirleyen temel bilgi içeriği mevcut değişken setiyle sınırlı kalmış olabilir. Özellikle meteorolojik değişkenler ve varlık temelli teknik parametreler, güç transformatörlerinde meydana gelen kesintilerin operasyonel, çevresel ve ekipman temelli tüm nedenlerini tam olarak temsil etmemektedir. Bu nedenle, model performansındaki sınırın yalnızca örnekleme yöntemlerinden değil, mevcut verinin temsil gücünden de kaynaklandığı değerlendirilmektedir. En yüksek test performansı:

- LightGBM (Robust + Undersample) → G-Mean: 0.627, ROC-AUC: 0.663
- XGBoost (Robust + Undersample) → G-Mean: 0.625, ROC-AUC: 0.662 olarak elde edilmiştir.

G-Mean değerlerinin 0.61–0.63 bandında kümelenmesi, modelin hem duyarlılık (azınlık sınıfı yakalama) hem de özgüllük (yanlış alarm kontrolü) açısından dengeli bir performans sunduğunu göstermektedir. ROC-AUC değerlerinin 0,66 seviyesinde olması ise modelin sınıfları ayırt etme kapasitesinin rastgele tahmine kıyasla anlamlı ölçüde yüksek olduğunu ortaya koymaktadır.

Bu sonuçlar, hava durumu ve varlık temelli özniteliklerin birlikte kullanımının, tekil meteorolojik modellemelere kıyasla daha istikrarlı bir ayırt etme gücü sağladığını göstermektedir.



Şekil-4 Seçili modeller için optimizasyon öncesi ve sonrası G-Mean karşılaştırması (Comparison of G-Mean values before and after optimization for selected models)

Şekil-4'te, optimizasyon öncesi ve Optuna + eşik ayarı sonrası G-Mean değerleri karşılaştırmalı olarak sunulmuştur. Görselde her model için başlangıç ve iyileştirilmiş performans arasındaki değişim eğim diyagramı ile gösterilmektedir. Optimizasyon sonrası:

- XGBoost ve LightGBM modellerinde belirgin iyileşme,
- Random Forest ve Logistic Regression modellerinde sınırlı fakat tutarlı artış,
- Gradient Boosting modelinde dengeli performans korunumu gözlemlenmiştir.

Bu durum, hiper parametre optimizasyonunun özellikle gradyan artırmalı yöntemlerde anlamlı katkı sağladığını göstermektedir. Bununla birlikte, optimizasyon sonrası elde edilen artışların makul seviyede olması, modelin aşırı öğrenme üretmediğini ve test setinde genellenebilirliğini koruduğunu göstermektedir.

Elde edilen G-Mean değerleri klasik doğruluk (accuracy) metriği ile karşılaştırıldığında daha gerçekçi bir değerlendirme sunmaktadır. Veri setinin dengesiz yapısı göz önüne alındığında, yüksek doğruluk değerleri yanıltıcı olabilmekte; azınlık sınıfı yakalama başarısı operasyonel açıdan daha kritik hâle gelmektedir.
Bu bağlamda:

- Model deterministik "kesin arıza tahmini" üretmemektedir.
- Model, transformatör bazlı risk önceliklendirme aracı olarak konumlandırılmıştır.
- Amaç, bakım ekiplerinin saha planlamasını destekleyecek bir risk skoru üretmektir.

Bu yaklaşım, literatürde yaygın olan uzun dönemli DGA temelli sağlık tahminlerinden ayrışmakta ve kısa vadeli operasyonel karar destek çerçevesi sunmaktadır.

Elde edilen G-Mean değerleri 0.60–0.63 bandında kümelenmektedir. Bu sonuç, modelin deterministik ve yüksek doğruluklu bir arıza tahmin sistemi olmaktan ziyade, transformatör bazlı kısa vadeli risk önceliklendirme aracı olarak değerlendirilmesi gerektiğini göstermektedir. Amaç, kesin arıza tahmini üretmek değil; bakım planlamasında yüksek riskli varlıkların önceliklendirilmesini sağlayacak bir karar destek bileşeni geliştirmektir.
Analizler, meteorolojik değişkenlerin tek başına güçlü bir ayırt edicilik üretmediğini; ancak varlık temelli teknik parametrelerle birlikte kullanıldığında daha dengeli bir performans sağladığını göstermektedir. Bu durum, dağıtım şebekelerinde kesinti oluşumunun çok faktörlü yapısını desteklemektedir.

5. Gelecek Çalışmalar (Future Work)

Mevcut veri yapısı, doğrudan neden–sonuç ilişkisi kurarak mücbir sebep modellemesi veya regülatif raporlama düzeyinde bilimsel kanıt üretmek için yeterli değildir. Çalışma, operasyonel risk tahmini odaklı bir çerçeve sunmaktadır.

Model performansının artırılabilmesi için gelecek çalışmalarda akıllı sayaç verileri, transformatör doluluk oranları, geçmiş bakım kayıtları, manevra ve anahtarlama logları, son kullanıcı türü ve yük profili bilgileri ile SCADA ve röle kayıtlarının modele entegre edilmesi hedeflenmektedir. Bu veri kaynaklarının birlikte değerlendirilmesiyle, mevcut yapıya kıyasla daha kapsamlı ve bütünleşik bir veri temeli oluşturulabileceği düşünülmektedir.

Bu veri kaynaklarının entegrasyonu ile yalnızca meteorolojik değil, teknik ve operasyonel parametrelere dayalı çok katmanlı bir kestirimci bakım sistemi geliştirilebilecektir. Ayrıca, uzamsal bağımlılıkların modellenmesi, olasılıksal risk tahmini yaklaşımları ve gerçek zamanlı veri akışına dayalı adaptif öğrenme mekanizmaları gelecekte önemli araştırma alanları olarak öne çıkmaktadır.

Sonuç olarak, bu çalışma enerji dağıtım sistemlerinde transformatör bazlı kısa dönemli kesinti riskinin veri odaklı yöntemlerle modellenebileceğini göstermekte; operasyonel karar süreçlerine entegre edilebilir bir analitik çerçeve sunmaktadır. Genişletilmiş veri entegrasyonu ve farklı şebeke koşullarında yapılacak doğrulama çalışmaları ile yaklaşımın literatüre ve uygulamaya katkısının daha da güçlenmesi beklenmektedir. Oluşturulan mevcut modellerde ilgili eklemeler ile dağıtım şebekelerinde kullanılan "Kesinti Yönetim Sistemi" (OMS) ile entegre bir karar sistemi oluşturulması gelecek çalışmalarda hedeflenmektedir.

References

Akcanca, M. A., & Taşkın, S. (2013). Akıllı Şebeke Uygulanabilirliği Açısından Türkiye Elektrik Enerji Sisteminin İncelenmesi. *Akıllı Şebekeler ve Türkiye Elektrik Şebekesinin Geleceği Sempozyumu*, 131–135. www.emo.org.tr/ekler/a4d6c5a3223642b_ek.pdf

Campbell, R. J. (2013). Weather-related power outages and electric system resiliency. *The Transformation of Electrical Power: Key Issues*, 103–118.

Cruz, E., & Munasinghe, T. (2023). Exploring Power Outage Prediction Using Weather and Socioeconomic Data in the Southeastern Part of the United States. *Proceedings - 2023 IEEE International Conference on Big Data, BigData 2023*, 6138–6142. https://doi.org/10.1109/BigData59044.2023.10386519

Doostan, M., & Chowdhury, B. (2020). Predicting lightning-related outages in power distribution systems: A statistical approach. *IEEE Access*, *8*, 84541–84550. https://doi.org/10.1109/ACCESS.2020.2991923

Fatima, K., Shareef, H., Costa, F. B., Bajwa, A. A., & Wong, L. A. (2024). Machine learning for power outage prediction during hurricanes: An extensive review. *Engineering Applications of Artificial Intelligence*, *133*(PB), 108056. https://doi.org/10.1016/j.engappai.2024.108056

Forsberg, S., Thomas, K., & Bergkvist, M. (2023). Power grid vulnerability analysis using complex network theory: A topological study of the Nordic transmission grid. *Physica A: Statistical Mechanics and its Applications*, *626*, 129072. https://doi.org/10.1016/j.physa.2023.129072

Gamel, S. A., Ghoneim, S. S. M., & Sultan, Y. A. (2024). Improving the accuracy of diagnostic predictions for power transformers by employing a hybrid approach combining SMOTE and DNN. *Computers and Electrical Engineering*, *117*(April), 109232. https://doi.org/10.1016/j.compeleceng.2024.109232

Jian, L., & Tianyuan, T. (2015). LS-SVM based substation circuit breakers maintenance scheduling optimization. *International Journal of Electrical Power and Energy Systems*, *64*, 1251–1258. https://doi.org/10.1016/j.ijepes.2014.09.013

Jin-Qiang, C. (2019). Fault Prediction of a Transformer Bushing Based on Entropy Weight TOPSIS and Gray Theory. *Computing in Science and Engineering*, *21*(6), 55–62. https://doi.org/10.1109/MCSE.2018.2882357

Norouzi, H. (2025). Flexible assessment of line polymer insulators based on condition indexes. *Electric Power Systems Research*, *238*(October 2024), 111145. https://doi.org/10.1016/j.epsr.2024.111145

Papic, M., Agarwal, S., Bian, J., Billinton, R., Dent, C., Dobson, I., Jirutitijaroen, P., Li, W., Menten, T., Mitra, J., Schneider, A., Singh, C., & Vadlamudi, V. V. (2014). Effects of dependent and common mode outages on the reliability of bulk electric system - Part I: Basic concepts. *IEEE Power and Energy Society General Meeting*, *2014-Octob*(October). https://doi.org/10.1109/PESGM.2014.6938967

Qian, L., Qingzhao, T., Qinghui, Z., & Tianqi, W. (2020). Research on power transformer fault prediction model based on LSTM neural network. *Proceedings - 2020 International Conference on Robots and Intelligent Systems, ICRIS 2020*, 702–705. https://doi.org/10.1109/ICRIS52159.2020.00175

Ren, H., Hou, Z. J., Ke, X., Huang, Q., & Makatov, Y. (2021). Analysis of Weather and Climate Extremes Impact on Power System Outage. *IEEE Power and Energy Society General Meeting*, *2021-July*, 1–5. https://doi.org/10.1109/PESGM46819.2021.9637938

Rexhepi, V. (2017). An Analysis of Power Transformer Outages and Reliability Monitoring. *Energy Procedia*, *141*, 418–422. https://doi.org/10.1016/j.egypro.2017.11.053

Taylor, W. O., Cerrai, D., Wanik, D., Koukoula, M., & Anagnostou, E. N. (2023a). Community power outage prediction modeling for the Eastern United States. *Energy Reports*, *10*(August), 4148–4169. https://doi.org/10.1016/j.egyr.2023.10.073

Taylor, W. O., Cerrai, D., Wanik, D., Koukoula, M., & Anagnostou, E. N. (2023b). Community power outage prediction modeling for the Eastern United States. *Energy Reports*, *10*(October), 4148–4169. https://doi.org/10.1016/j.egyr.2023.10.073

The International Energy Agency (IEA). (2021). *No Title*. https://www.iea.org/data-and-statistics/charts/world-electricity-final-consumption-by-sector-1974-2019.

Thomas, J. B., & K.V., S. (2023). Neural architecture search algorithm to optimize deep Transformer model for fault detection in electrical power distribution systems. *Engineering Applications of Artificial Intelligence*, *120*(July 2022), 105890. https://doi.org/10.1016/j.engappai.2023.105890

Toubeau, J. F., Pardoen, L., Hubert, L., Marenne, N., Sprooten, J., De Grève, Z., & Vallée, F. (2022). Machine learning-assisted outage planning for maintenance activities in power systems with renewables. *Energy*, *238*. https://doi.org/10.1016/j.energy.2021.121993

Tuttokmağı, Ö., & Kaygusuz, A. (2019). *Araştırma Makalesi / Research Article Büyük Ölçekli Elektrik Kesintilerinin İncelenmesi Investigation of Large Scale Power Blackouts*. *8*(2), 664–676.

Ucar, A., Karakose, M., & Kırımça, N. (2024). *applied sciences Artificial Intelligence for Predictive Maintenance Applications :*

Visakh, A., & Selvan, M. P. (2023). Analysis and mitigation of the impact of electric vehicle charging on service disruption of distribution transformers. *Sustainable Energy, Grids and Networks*, *35*, 101096. https://doi.org/10.1016/j.segan.2023.101096

Wang, S., Sun, H., Kim, K. J., Guo, J., & Nikovski, D. (2021). Solving Bernoulli Bandit Problems for Weather-relative Overhead Distribution Line Failures Forecasting. *IEEE Power and Energy Society General Meeting*, *2021-July*, 0–4. https://doi.org/10.1109/PESGM46819.2021.9638153

Xu, F., Zhou, L., Zhou, Y., Ai, X., & Liu, Q. (2025). Power outage data management platform based on big data analysis technology. *Procedia Computer Science*, *261*, 976–982. https://doi.org/10.1016/j.procs.2025.04.489

Xu, Z., Liu, J., Fan, W., Wang, Y., Luan, L., & Zhou, K. (2022). An Power Outage Prediction Method Based on XGBoost with Improved Objective Function. *Proceedings - 2022 37th Youth Academic Annual Conference of Chinese Association of Automation, YAC 2022*, 1560–1565. https://doi.org/10.1109/YAC57282.2022.10023921

Yuyama, A., Kajitani, Y., & Shoji, G. (2018). Simulation of operational reliability of thermal power plants during a power crisis: Are we underestimating power shortage risk? *Applied Energy*, *231*(February), 901–913.

https://doi.org/10.1016/j.apenergy.2018.09.089

Zaldivar, D. A., Sanchez, A. M., & Romero, A. A. (2023). A comprehensive methodology for the optimization of condition-based maintenance in power transformer fleets. *Electric Power Systems Research*, *220*(March). https://doi.org/10.1016/j.epsr.2023.109374

Zhao, T., Satoshi, E., Yue, M., Jensen, M., Marschilok, A., Nugent, B., Cerruti, B., & Spanos, C. (2023). On Learning-Based Model for Dynamic Granular Prediction of Power Outages Under Extreme Events. *2023 IEEE PES Innovative Smart Grid Technologies Latin America, ISGT-LA 2023*, 445–449. https://doi.org/10.1109/ISGT-LA56058.2023.10328277

Zhou, Q., Zhang, J., Yang, Z., & Yang, Y. (2014). Distribution network outage pre-warning analytics under extreme weather conditions. *China International Conference on Electricity Distribution, CICED*, *2014-Decem*(Ciced), 1190–1194. https://doi.org/10.1109/CICED.2014.6991895