

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**YÜKSEK GERİLİM HATLARINDA YILDIRIM ELEKTROMANYETİK
DARBELERİNİN OLUŞTURDUĞU ARIZALARIN MAKİNE ÖĞRENMESİ
YÖNTEMİYLE TAHMİNLENMESİ**

Ahmet Yaşar YOLDAŞ

**FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ**

ANABİLİM DALI

DOKTORA TEZİ

MAYIS 2025

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YÜKSEK GERİLİM HATLARINDA YILDIRIM ELEKTROMANYETİK
DARBELERİNİN OLUŞTURDUĞU ARIZALARIN MAKİNE ÖĞRENMESİ
YÖNTEMİYLE TAHMİNLENMESİ**

Ahmet Yaşar YOLDAŞ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
DOKTORA TEZİ

MAYIS 2025

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YÜKSEK GERİLİM HATLARINDA YILDIRIM ELEKTROMANYETİK
DARBELERİNİN OLUŞTURDUĞU ARIZALARIN MAKİNE ÖĞRENMESİ
YÖNTEMİYLE TAHMİNLENMESİ**

Ahmet Yaşar YOLDAŞ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
DOKTORA TEZİ

Bu tez, 09/05/2025 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Prof. Dr. Şükrü ÖZEN (Danışman)

Prof. Dr. Mesud KAHRİMAN

Prof. Dr. Övünç POLAT

Doç. Dr. Hamza Feza CARLAK

Dr. Öğr. Üyesi Gürkan BİLGİN

ÖZET

YÜKSEK GERİLİM HATLARINDA YILDIRIM ELEKTROMANYETİK DARBELERİNİN OLUŞTURDUĞU ARIZALARIN MAKİNE ÖĞRENMESİ YÖNTEMİYLE TAHMİNLENMESİ

Ahmet Yaşar YOLDAŞ

Doktora Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Şükrü ÖZEN

Mayıs 2025; 105 sayfa

Enerji iletim hatları, yıldırım elektromanyetik darbelerine bağlı olarak ciddi arızalar ve enerji kesintileriyle karşı karşıya kalmaktadır. Geleneksel yöntemler yıldırım kaynaklı arızaların önlenmesi konusunda belirli başarılar sağlamış olsa da karmaşık meteorolojik değişkenler ve coğrafi faktörler nedeniyle tahmin performansları sınırlı kalmaktadır. Bu çalışmada, enerji iletim hatlarında yıldırım kaynaklı arızaların tahmini için Rastgele Orman Algoritması ve XGBoost algoritmalarının birleşimiyle oluşturulan hibrit model önerilmektedir. Model, 2015-2022 yılları arasında Antalya bölgesinde toplanan 360.000 yıldırım verisi ve 713 yıldırım kaynaklı arıza kaydı kullanılarak eğitilmiştir.

Veri işleme sürecinde, eksik veri yönetimi, aykırı değer analizi ve özellik mühendisliği gibi teknikler uygulanmıştır. Modelin performansı, doğruluk, F1-skor, AİK-EAA ve Karışıklık Matrisi gibi metriklerle değerlendirilmiş ve hibrit modelin %93 doğruluk oranı ile geleneksel yöntemlere kıyasla üstün performans gösterdiği belirlenmiştir. Ayrıca, önerilen modelin hatalı pozitif ve hatalı negatif oranlarını azalttığı ve özellikle kritik arıza senaryolarında yüksek başarı sağladığı gözlemlenmiştir. Çalışmanın bulguları, hibrit makine öğrenmesi modellerinin enerji iletim hatlarındaki yıldırım kaynaklı arızaların tahmini için güçlü bir alternatif sunduğunu göstermektedir. Literatüre bütüncül mühendislik parametrelerini kullanarak tahmin yapan hibrit algoritma olarak girecek modelin, gelecekte farklı coğrafi bölgelerde test edilmesi, ek meteorolojik değişkenlerin entegrasyonu ve gerçek zamanlı uygulamalara uyarlanması önerilmektedir.

ANAHTAR KELİMELE: Enerji İletim Hattı, Hibrit Model, Makine Öğrenmesi, Random Forest, Tahmin, XGBoost, Yapay zekâ, Yıldırım.

JÜRİ: Prof. Dr. Şükrü ÖZEN

Prof. Dr. Mesud KAHRİMAN

Prof. Dr. Övünç POLAT

Doç. Dr. Hamza Feza CARLAK

Dr. Öğr. Üyesi Gürkan BİLGİN

ABSTRACT

PREDICTION OF LIGHTNING-INDUCED FAULTS IN HIGH VOLTAGE TRANSMISSION LINES USING MACHINE LEARNING METHODS

Ahmet Yaşar YOLDAŞ

PhD Thesis in Electrical and Electronics Engineering

Supervisor: Prof. Dr. Şükrü ÖZEN

May 2025; 105 pages

Power transmission lines are exposed to severe faults and power outages due to lightning-induced electromagnetic pulses. Although traditional methods have achieved certain success in preventing lightning-related faults, their prediction performance remains limited due to complex meteorological variables and geographical factors. In this study, a hybrid model is proposed for predicting lightning-induced faults in power transmission lines by combining the Random Forest Algorithm and the XGBoost algorithm. The model was trained using 360,000 lightning records and 713 lightning-induced fault events collected in the Antalya region between 2015 and 2022.

During the data preprocessing stage, techniques such as missing data handling, outlier analysis, and feature engineering were applied. The model's performance was evaluated using metrics such as accuracy, F1-score, ROC-AUC, and confusion matrix. The results showed that the hybrid model achieved a 93% accuracy rate, significantly outperforming traditional methods. Furthermore, the proposed model demonstrated reduced false positive and false negative rates and showed high success particularly in critical fault scenarios. The findings of this study suggest that hybrid machine learning models offer a powerful alternative for predicting lightning-induced faults in power transmission lines. The proposed model, which integrates comprehensive engineering parameters for prediction, is expected to make a novel contribution to the literature. Future studies are recommended to test the model in different geographical regions, incorporate additional meteorological variables, and adapt it for real-time applications.

KEYWORDS: Artificial Intelligence, Hybrid Model, Lightning, Machine Learning, Prediction, Random Forest, Transmission Line, XGBoost.

COMMITTEE: Prof. Dr. Şükrü ÖZEN

Prof. Dr. Mesud KAHRİMAN

Prof. Dr. Övünç POLAT

Assoc. Prof. Dr. Hamza Feza CARLAK

Asst. Prof. Dr. Gürkan BİLGİN

ÖNSÖZ

Yıldırım, havai enerji iletim hatlarındaki arıza kaynaklarının başında gelmektedir ve literatürde bu arızaları önleyebilmek için farklı uygulamalar bulunmaktadır. Bu çalışma ile yıldırım kaynaklı havai enerji iletim hatlarında meydana gelen arızalar makine öğrenmesi yöntemleriyle incelenmiş ve ortaya konan hibrit model ile arıza tahminleri yapılmıştır. Eğitim setinden bağımsız güncel verilerle elde edilen sistem test edilmiş ve %93 oranında başarıya ulaşılmıştır.

Doktora çalışmalarım boyunca yol gösteren danışman hocam Prof. Dr. Şükrü ÖZEN'e teşekkür ederim. Zorlandığım zaman küçük dokunuşlarla yönümü bulmama yardımcı olan Prof. Dr. Selçuk HELHEL'e tüm yardımları için minnettarım. Akademik süreçte algoritmalarla ilgili yönlendirici fikirlerini paylaşan Doç. Dr. H. Feza CARLAK'a ve ayrıca bu süreçte yanımda olan Dr. Kayhan ATEŞ'e müteşekkirim.

Son olarak, hayatımın her anında yanımda olan, motive eden, destekleyen Eşim ve en yakın arkadaşım Simge Nur YOLDAŞ'a, oynamak için sabırla bekleyen kızım Melek Naz YOLDAŞ'a, bilginin yolundan gitmemi öğütleyen Babam Hasan YOLDAŞ'a, asla hak yeme, asla hakkını yedirme düsturuyla beni büyüten Annem Seher YOLDAŞ'a minnettarım.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ	iii
AKADEMİK BEYAN	vi
SİMGELER VE KISALTMALAR.....	vii
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ	xiii
1. GİRİŞ.....	1
1.1. Yıldırımın EİH'leri Üzerindeki Etkileri ve Riskleri	3
1.2. Yapay Zekâ ve Makine Öğrenmesi	4
1.3. Tez Çalışmasının Literatüre Katkısı.....	4
1.4. Tezin Yapısı	6
2. KAYNAK TARAMASI.....	7
2.1. Yıldırım Tahmini İçin Kullanılan Geleneksel Yöntemler.....	7
2.2. MÖ Tabanlı Yıldırım Tahmin Modelleri	9
2.3. Hibrit Modellerin Kullanımı	14
2.4. Literatür Tarama Özeti	18
3. MATERYAL VE METOT.....	20
3.1. Araştırma Tasarımı ve Kapsamı.....	20
3.1.1. Çalışmanın hipotezi ve amacı	20
3.1.2. Hibrit modelin tercih gerekçesi	20
3.1.3. Yıldırımın Antalya bölgesindeki enerji iletim hatlarına etkileri	21
3.2. Elektromanyetik Alan Kavramı	22
3.3. Yıldırım Teorisi.....	24
3.3.1. Yıldırım oluşum süreci.....	24
3.3.2. Yıldırım matematik modelleri	26
3.3.3. İletim hattı yıldırım modeli	30
3.3.4. Master, Uman Lin ve Standler modeli	30
3.3.5. Gezen akım kaynağı modeli.....	31
3.3.6. Geliştirilmiş iletim hattı modeli	32
3.3.7. Üssel olarak zayıflayan iletim hattı modeli.....	32

3.3.8. Doğrusal akım zayıflaması ile geliştirilmiş iletim hattı	32
3.3.9. Diendorfer – Uman modeli	33
3.3.10. Mühendislik modellerinin genellenmesi.....	33
3.4. Kublaj Modeli	34
3.4.1. Rusck modeli.....	35
3.4.2. Taylor modeli	37
3.4.3. Agrawal modeli	37
3.4.4. Rachidi modeli	39
3.5. Yıldırım Aşırı Gerilimleri Etkileyen Unsurlar	43
3.5.1. Çoklu iletken	43
3.5.2. Koruma iletkeni.....	44
3.5.3. Toprak direnci	45
3.5.4. Yıldırımın darbesinin konumu	46
3.5.5. Hat uzunluğu ve direk yüksekliği.....	47
3.5.6. Korona etkisi	48
3.5.7. Yıldırım parametrelerinin etkileri	49
3.6. Veri Setleri ve Kaynakları.....	50
3.7. Veri Ön İşleme ve Özellik Mühendisliği	50
3.7.1. Eksik veri yönetimi	50
3.7.2. Aykırı değer analizi	51
3.7.3. Özellik Seçimi ve Dönüşümü.....	51
3.7.4. Veri bölünmesi	51
3.8. Hibrit Modelin Oluşturulması	53
3.8.1. Algoritma seçimi ve gerekçesi	53
3.8.2. Model entegrasyonu	55
3.8.3. Hiperparametre optimizasyonu	56
3.9. Model Eğitimi ve Test Süreci.....	57
3.9.1. Çapraz doğrulama	57
3.9.2. Eğitim süreci	57
3.9.3. Model eğitimi	58
3.9.4. Test süreci	59
3.10. Performans değerlendirme ve hata analizi	59

3.10.1. Kullanılan metrikler.....	59
3.10.2. Hatalı pozitif ve hatalı negatif oranlarının azaltılması	60
3.10.3. Diğer algoritmalarla karşılaştırma	62
3.11. Etik ve Çalışma Sınırlılıkları.....	63
3.11.1. Etik konular ve veri gizliliği	63
3.11.2. Modelin coğrafi ve teknik sınırlılıkları.....	63
4. BULGULAR	64
4.1. Veri Setinin Görselleştirilmesi ve Ön Analiz.....	64
4.1.1. Korelasyon matrisi ve analizi.....	64
4.1.2. Yoğunluk grafikleri ile değişken dağılımı	64
4.1.3. 3 boyutlu saçılım değerlendirme	65
4.1.4. Histogramlar ile değişkenlerin dağılımı.....	66
4.2. Modelin Eğitilmesi ve Test Edilmesi	66
4.2.1. Veri bölünmesi	66
4.2.2. Model performans değerlendirme metrikleri	67
4.2.3. Aşırı öğrenme analizi	69
4.3. Hibrit Model ile Karşılaştırmalar	70
4.3.1. ROA ve XGBoost birleşiminin etkisi.....	70
4.3.2. Diğer makine öğrenimi algoritmaları ile karşılaştırmalar	71
4.4. Modelin Baskın ve Çekinik Yönleri.....	73
4.4.1. Model gelişimi için atılan adımlar	74
4.5. Hata Analizi ve İyileştirme Önerileri	75
4.5.1. Modelin en yüksek doğruluk sağladığı senaryolar.....	75
4.5.2. Modelin hatalı tahmin yaptığı durumların analizi.....	76
4.5.3. Alternatif özellik mühendisliği yaklaşımı	77
4.6. Güncel Verilerle Arıza Analizi.....	79
4.6.1. Modelin güncel zamanlı kullanımı.....	79
4.6.2. Güncel zamanlı test senaryoları ve sonuçları.....	80
5. TARTIŞMA.....	82
5.1. Model Performansının Değerlendirilmesi	82
5.2. Modelin Literatürdeki Yeri ve Karşılaştırmalar	84
5.3. Hatalı Pozitif ve Hatalı Negatif Yanlışlarının Etkisi.....	85

5.3.1. Hata analizi sonrası model gelişimi için öneriler	86
5.4. Modelin Güçlü Yönleri	87
5.5. Modelin Dezavantajları	89
6. SONUÇ	90
6.1. Çalışmanın Temel Bulguları	90
6.2. Çalışmanın Katkıları	90
6.3. Öneriler.....	91
7. KAYNAKLAR.....	93
8. EKLER	101
ÖZGEÇMİŞ	



AKADEMİK BEYAN

Doktora Tezi olarak sunduğum “Yüksek Gerilim Hatlarında Yıldırım Elektromanyetik Darbelerinin Oluşturduğu Arıza İndekslerinin Yapay Zekâ Kullanılarak Tahminlerinin Yapılması” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

09/05/2025

Ahmet Yaşar YOLDAŞ

SİMGELER VE KISALTMALAR

Simgeler

J	: Youden indeksi
A	: Amper
V	: Volt
Ω	: Ohm
E	: Elektrik alan
B	: Manyetik akı
H	: Manyetik alan
D	: Elektrik akı yoğunluğu
J_e	: Elektriksel akım yoğunluğu
J_m	: Manyetik gerilim yoğunluğu
ϵ	: Elektriksel geçirgenlik
μ	: Manyetik geçirgenlik
Ω	: Ohm
$\emptyset$	: Skaler potansiyel
c	: Işık hızı
v	: Birim hacim başına yük yoğunluğu
σ_e	: Elektriksel iletkenlik
σ_m	: Manyetik direnç
G	: Admitans
$^{\circ}C$	: Celcius derece
δ	: Sentetik örnek başına farklı skaler
$\mathcal{L}$	: Optimizasyon fonksiyonu
λ	: hiperparametre

Kısaltmalar

AIK	: Alıcı İşlem Karakteristiği
ATP	: Alternatif Transient Programı
CBS	: Coğrafi Bilgi Sistemi
CNN	: Evrimsel Sinir Ağı
CSI	: Kritik Başarı İndeksi
DN	: Doğru Negatif
DP	: Doğru Pozitif
DVM	: Destek Vektör Makinesi
EAA	: Eğri Altı Alan
EFIE	: Elektrik Alan İntegral Denklemi
EİH	: Enerji İletim Hattı
EMTP	: Elektromanyetik Transient Programı
FFNN	: İleri Beslemeli Yapay Sinir Ağı
GA	: Genetik Algoritma
HN	: Hatalı Negatif
HP	: Hatalı Pozitif
IAHP	: Analitik Hiyerarşi Süreci
IEEE	: Elektrik ve Elektronik Mühendisleri Enstitüsü
IoT	: Nesnelerin interneti
KDE	: Kernel Çekirdek Yoğunluk Tahmini
KNN	: K En Yakın Komşu Algoritması
L1	: Lasso Regresyonu
L2	: Ridge Regresyonu
LDA	: Doğrusal Ayrım Analizi
LPAS	: Yıldırım Tahmin Uyarı Sistemi

LR	: Lojistik Regresyon Algoritması
LSTM	: Uzun Kısa Vadeli Bellek
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hatası
MGM	: Meteoroloji Genel Müdürlüğü
MÖ	: Makine Öğrenmesi
NWP	: Sayısal Hava Tahmini
RMSE	: Kök Ortalama Kare Hatası
RNM	: Tekrarlayan Bellek Ağı
ROA	: Rastgele Orman Algoritması
SCADA	: Merkezi Denetleme ve Veri Toplama Sistemi
SCE-RCNN	: Şekil Bilinçli Bağlam Kodlamalı Bölge Tabanlı Evrişimsel Sinir Ağı
SHAP	: Shapley Toplamsal Açıklamalar
SHO	: Showalter İndeksi
SMOTE	: Sentetik Azınlık Aşırı Örnekleme Tekniği
SPD	: Gerilim Koruyucu Cihaz
TEİAŞ	: Türkiye Elektrik İletim Anonim Şirketi
TEM	: Transvers Elektromanyetik Model
UHV	: Ultra Yüksek Gerilim
XGBoost	: Aşırı Gradyan Arttırımı
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ

“Simgeler ve Kısaltmalar” başlığında belirtilmeyenler, tezin içerisinde açıklanmıştır. Eşitlikler ise metinde parantez içerisinde eşitlik numarası ile belirtilmiştir.

ŞEKİLLER DİZİNİ

Şekil 1.1. Antalya Bölgesi 2021 yılı 10 kA ve üzeri yıldırımlar.	1
Şekil 1.2. Türkiye yıldırım yoğunluk haritası (Öztopal 2017).	2
Şekil 2.1. Pafudur konumlandırmasının etkisi (Bedoi vd. 2010).....	8
Şekil 2.2 a) İdeal şartlar için MAPE: %0, 62 m b) Değişen tepe akımı ve iletken olmayan zemin koşullarında MAPE: %12,5 290 m hassasiyet (Nicora vd. 2024).	10
Şekil 2.3. a) yıldırım koridoru 1,5km b) yıldırım koridoru 2 km c) yıldırım koridoru 3km d) yıldırım koridoru 5 km (Xie vd. 2019).	11
Şekil 2.4. Transformer modelinin yıldırım tahmin performansı (Adiaksa vd. 2024).	13
Şekil 2.5. (a) sinyallerin zaman-mekân karakteristiği, (b) MÖ modelinin lokalizasyon başarısı (Karami vd. 2020).....	18
Şekil 2.6. (a) yıldırım konumunu ne kadar doğru tahmin ettiği (b) yıldırım konumu tahminleri (Karami vd. 2020).....	18
Şekil 3.1. Kayıplı iletim hattı genel devre gösterimi.	23
Şekil 3.2. (a-c) Adım lidere ait ilk geri dönüş darbesi, (d-f) 2.liderin 4.geri dönüş darbesi, (g-i) ardıl liderin 5.geri dönüş darbesi (Jiang vd. 2015).	25
Şekil 3.3. Adım lider ile yıldırımın oluşumu (Yoldaş, 2019).	26
Şekil 3.4. 10/350µs Yıldırım darbesinin Heidler fonksiyonu ile gerçekçi modellemesi.	28
Şekil 3.5. Bruce-Golde modeline göre geri dönüş darbe akım modeli (Djalel vd. 2007).	29
Şekil 3.6. Bruce- Golde modelinde süreksiz geri dönüş darbe akımı (Djalel vd. 2007).	30
Şekil 3.7. İdeal devre modeli.	35
Şekil 3.8. Rusck iletim hattı kublaj modeli.....	36

Şekil 3.9. Eş iletim hattı modeli.....	37
Şekil 3.10. Agrawal kuplaj devresi modeli.	39
Şekil 3.11. Rachidi modeli iletim hattı.	40
Şekil 3.12. Chowdhuri-Gross iletim hattı kublaj modeli.	41
Şekil 3.13. IEEE 1410 standardına göre yıldırım akım grafiği.	42
Şekil 3.14. Rusck ve Agrawal modellerine göre iletim hattı tepkisi.	43
Şekil 3.15. İletken sayısına göre indüklenen aşırı gerilimler.....	44
Şekil 3.16. Topraklama aralığına göre koruma iletkeninin etkinliği.	45
Şekil 3.17. Sonlu toprak iletkenliğinde indüklenen aşırı gerilim profili.....	46
Şekil 3.18. Darbe mesafesine göre indüklenen gerilim ve gecikme süresi.....	47
Şekil 3.19. Hat yüksekliğine göre indüklenen aşırı gerilim.....	48
Şekil 3.20. SMOTE ile azınlık sınıfını dengeme.	52
Şekil 4.1. Korelasyon matrisi ile değişkenler arasındaki bağıntı analizi.	64
Şekil 4.2. Yıldırım akımı ve arızadan açma durumu yoğunluk grafiği.	65
Şekil 4.3. Yıldırım, direnç ve izolatör boyu arasındaki ilişki.	65
Şekil 4.4. Histogram değerlendirme grafikleri.	66
Şekil 4.5. ROA ve XGBoost Karışıklık matrisi.	67
Şekil 4.6. AİK-EAA eğrisi ve doğruluk analizi.	68
Şekil 4.7. ROA ve XGBoost önem özellik karşılaştırması.	69
Şekil 4.8. (a) Aşırı öğrenme kontrolü, (b) L1/L2 düzenlemesi sonrası.	70
Şekil 4.9. Hibrit model karışıklık matrisi.	70
Şekil 4.10. Hibrit model AİK-EAA görseli.	71
Şekil 4.11. Tüm modeller için AİK Eğrisi.	72
Şekil 4.12. Tüm modellerin doğruluk oranı karşılaştırma tablosu.....	73
Şekil 4.13. Modelin hata dağılımı.....	73

Şekil 4.14. SHAP özellik önem grafiği.....	74
Şekil 4.15. Güçlendirilmiş modele ilişkin karışıklık matrisi.	75
Şekil 4.16. Model doğruluk oranı karşılaştırması.	76
Şekil 4.17. Hibrit modele ilişkin duyarlılık – kesinlik eğrisi.	77
Şekil 4.18. SHAP etki analizi (Arı sürüsü grafiği).	77
Şekil 4.19. Seçili değişkenler için korelasyon matrisi.	78
Şekil 4.20. Yeni özelliklerin model performansına etkisi grafiği.....	78
Şekil 4.21. Manuel veri girişi ile model sonuç örnekleri.....	79
Şekil 5.1. Kalibrasyon (güven) eğrisi.	83
Şekil 5.2. ROA, XGBoost ve GA güven eğrisi karşılaştırması.	84
Şekil 5.3. Hibrit model hatalı sınıflandırma oranı.	86
Şekil 5.4. Hibrit modelin optimizasyon sonuçları.	87
Şekil 5.5. Hibrit model hata dağılımı.....	88
Şekil 5.6. İşlem süresi karşılaştırması.....	88


ÇİZELGELER DİZİNİ

Çizelge 2.1. Öne çıkan modellerin performans özeti.....	14
Çizelge 2.2. (a) Erken uyarı yönteminin performansı (b) iletim hatları için yıldırım erken uyarı yönteminin performansı (Huo vd. 2024).....	16
Çizelge 2.3. Çalışma performansı için değerlendirme metrikleri (Rafı vd. 2024)	16
Çizelge 2.4. Model performans çizelgesi (Doostan ve Chowdhury 2020).....	17
Çizelge 2.5. Karşılaştırma Tablosu.....	19
Çizelge 3.1. Kullanılan Algoritmaların Karşılaştırması	21
Çizelge 3.2. Eğitim ve test için kullanılan girdiler	21
Çizelge 3.3. ROA için optimize edilen hiperparametreler.....	56
Çizelge 3.4. XGBoost için optimize edilen parametreler	56
Çizelge 3.5. Optimizasyon öncesi ve sonrası model karşılaştırması	56
Çizelge 3.6. Kullanılan metriklere ait tablo	59
Çizelge 3.7. Hibrit Modelin Karışıklık Matrisi ve Temel Metrikleri	61
Çizelge 3.8. Farklı Algoritmaların Karşılaştırılması.....	62
Çizelge 4.1. ROA ve XGBoost karşılaştırması.....	68
Çizelge 4.2. Eşik değere göre duyarlılık tablosu	71
Çizelge 4.3. Seçilen modellerin karşılaştırmalı tablosu.....	72
Çizelge 4.4. Güncel zamanlı veri ile modelin test sonuçları.....	80
Çizelge 5.1. Model karşılaştırma tablosu.....	85

1. GİRİŞ


Doğal afetlerin neden olduğu arızalar karşısında EİH hassas bir yapıya sahiptir. Yıldırım, EİH’de yüksek genlikli akım ve gerilim darbeleri oluşturarak ciddi sistem arızalarına neden olmaktadır. Yıldırım elektromanyetik darbesi, enterkonnekte sistem içinde belirli bir alan boyunca yayılarak hassas ekipmanlarda izolasyon delinmesine, bozulmasına ve ikincil arızalara neden olabilmektedir. Bu etki, sadece doğrudan yıldırım düşmesiyle değil, EİH’ye yakın mesafedeki darbelerde de ciddi seviyelerde geçici aşırı gerilimlerin oluşmasına yol açar; bu da EİH’de meydana gelebilecek arızalar için büyük bir risk faktörüdür. Bu arızalar, enerji kesintilerine, teçhizat hasarına ve ekonomik kayıplara neden olmaktadır. Günümüzde, EİH’nin yıldırım kaynaklı hasarlardan korunması büyük bir mühendislik problemi olarak ele alınmaktadır. Geleneksel koruma yöntemleri yıldırımın etkilerini azaltmada belirli başarılar sağlasa da yıldırım kaynaklı arızaların tahmini konusunda hala önemli eksiklikler bulunmaktadır. Bu tezde ele alınan temel problem, mevcut yöntemlerle yıldırım elektromanyetik darbeleri kaynaklı EİH arızalarının yeterince öngörülememesidir. Ortaya konan hipotez, ROA ve XGBoost algoritmalarının birleştirildiği hibrit bir makine öğrenmesi modeli kullanılarak, yıldırım kaynaklı arızaların tahmin edilmesidir.

Bu çalışmada ROA’nın genelleme kapasitesi ile XGBoost’un gradyan optimizasyonunu birleştiren hibrit bir model tasarlanmıştır. Hibrit model, çevresel faktörlerin yanı sıra mühendislik değişkenlerini de hesaba katarak yıldırım tahmini doğruluğunu artırmaktadır. ROA’nın yüksek genelleme kapasitesi ile XGBoost’un hata azaltma yeteneği bir araya getirilerek, yıldırım kaynaklı arızaların daha yüksek doğrulukla tahmin edilmesi hedeflenmiştir. ROA ve XGBoost algoritmalarını birleştiren hibrit modelin, tekil modellere kıyasla daha yüksek doğruluk sağladığı ortaya konmuştur. Model, 2015-2022 yılları arasında Antalya bölgesinde toplanan 360.000 yıldırım kaydı ile eşleştirilip filtrelenen 713 yıldırım kaynaklı EİH arıza verisi kullanılarak eğitilmiştir. Şekil 1.1’de Antalya sınırlarına düşen 2021 yılına ait 10 kA ve üzeri yıldırımlar gösterilmektedir. Aynı görselde yıldırım şiddeti arttıkça çember çapı büyümektedir.



Şekil 1.1. Antalya Bölgesi 2021 yılı 10 kA ve üzeri yıldırımlar.

Oluşturulan hibrit model, sınıflandırma ve tahmin konusunda yüksek başarıya sahip makine öğrenme yöntemleri ile karşılaştırılmıştır. Hibrit modelin eğitilmesi için ihtiyaç duyulan veriler iki farklı kaynaktan temin edilmiştir. Bunlardan ilki 2015-2022 yılları arasında bu çalışmaya esin kaynağı olan Antalya şehri sınırlarına düşen, Meteoroloji Bölge Müdürlüğü'nden elde edilen 360.000'den fazla yıldırım verisidir. Antalya Türkiye ortalamasının yaklaşık 10 katı yıldırım almaktadır (Öztopal 2017). Ayrıca Türkiye'nin yıldırım yoğunluğu en yüksek olan bölgesi de Antalya – Fethiye arasında kalan kısımdır. Şekil 1.2'de Türkiye yıldırım yoğunluk haritası paylaşılmıştır. Kullanılan yıldırım verilerinin içinde koordinatlı yıldırımın düştüğü yükseklik, akım şiddeti, koordinat bilgisi, tarih, saat ve dakika bulunmaktadır. Çalışmada kullanılan ikinci veri kaynağı, TEİAŞ tarafından sağlanan, 2015-2022 yılları arasında meydana gelen yıldırım kaynaklı EİH arıza kayıtlarıdır. Bu veri seti, yıldırım düşen hatların konumlarını, arızanın meydana geldiği tarihi ve saatini, etkilenen bileşenleri (izolatör, direk, trafo vb.) ve olay sonrası bakım sürelerini içermektedir. Bu arızaların tarih ve saati tanımlı olup, koordinatlı yıldırım verisi ile EİH güzergâhı üst üste bindirilerek oluşturulan yıldırım koridoru haritası içinde kalan yıldırım verileri filtrelenmiştir. Filtrelenen yıldırım verilerinin saat ve tarihi ile EİH'de meydana gelen arızaların saat ve tarihleri eşleştirilmiştir. Bu şekilde yıldırım kaynaklı 713 arıza elde edilmiştir. Koordinatları bilinen yıldırımların akım şiddeti ve yıldırımın düştüğü noktadaki direklerin topraklama dirençleri, kotları, direk tiplerine ait veriler elde edilmiştir. Sunulan hibrit model 2015-2022 arasında toplanan yıldırım ve arıza verileri temel alınarak eğitilmiştir.



Şekil 1.2. Türkiye yıldırım yoğunluk haritası (Öztopal 2017).

Lee ve Cho (2022), Hasrod vd. (2024) tarafından yapılan çalışmalar tek bir modelin belirli koşullarda yeterli doğruluk sağlayamayacağını göstermiştir. Bu çalışmalar, farklı algoritmaların kombinasyonunu içeren hibrit modellerin potansiyel avantajlarını tam olarak ortaya koymamaktadır. MÖ tabanlı modeller, büyük veri setlerinden öğrenerek daha hassas tahminler yapabilmektedir. Modelin başarısı, yalnızca geçmiş meteorolojik verilerle değil, aynı zamanda EİH'ye ait mühendislik parametreleriyle eğitilmiş olmasına dayanmaktadır. Bu nedenle, bu çalışmada önerilen hibrit model, yalnızca geçmiş yıldırım verilerini değil, aynı zamanda EİH altyapısına ait teknik değişkenleri de hesaba katarak geleneksel modellere kıyasla daha yüksek doğruluk

sağlamaktadır (Jun 2017; Bouchard vd. 2023). Çalışmanın temel motivasyonu, mevcut yöntemlerin eksikliklerini gidererek enerji şebekelerinin güvenilirliğini artıracak, yeni yapılacak EİH için ise güzergâh belirlenmesinde kullanılacak yenilikçi bir yaklaşım sunmaktır.

1.1. Yıldırımın EİH'leri Üzerindeki Etkileri ve Riskleri

EİH gibi yüksek yapılar, yıldırımın doğal hedefleri arasında yer almakta ve bu nedenle yıldırıma karşı koruma önlemleri büyük önem taşımaktadır. Literatürde, yıldırım kaynaklı EİH arızalarının %70'inin ani aşırı gerilimlerden kaynaklandığı belirtilmiştir (He vd. 2015). Bu nedenle, enerji sistemlerinde yıldırım riskini azaltmaya yönelik hem pasif hem de aktif koruma yöntemleri kullanılmaktadır. Yıldırım düşmelerine karşı savunmasız olan EİH'leri ve bu hatlarda meydana gelen ani gerilim değişimleri, sistem stabilitesini tehlikeye atabilmektedir. Visacro ve Silveria (2015), Goud vd. (2018), Duan vd. (2024) tarafından yapılan çalışmalarda, yıldırım düşmelerinin EİH'deki dengesizliklere yol açtığını ve yüksek gerilim hatlarının yıldırıma karşı özellikle hassas olduğunu göstermektedir. Bu nedenle, EİH'nin yıldırıma karşı korunması için hem geleneksel yöntemler hem de veri odaklı tahmin sistemleri üzerine araştırmalar hız kazanmıştır (Bao vd. 2021). Yıldırım düşmesi, enerji sistemlerindeki çeşitli bileşenlere zarar vererek ciddi kesintilere ve maddi kayıplara neden olabilir. ABD'de yapılan araştırmalara göre, yıldırım çarpmaları yıllık ortalama 5 milyar dolarlık enerji kaybına neden olmaktadır (Baraniuk 2024).

Yıldırım; ekipman hasarına, iletken kopması sonucu direklerde deformasyona, izolatör kırılması veya delinmesi sonucu iletkenin konsola düşmesine ve güç transformatörlerini doğrudan etkileyerek büyük mekanik ve termal strese yol açar. Bu durum, iletkenlerin erimesi ve kopması sonucu direklerin dengesiz yüklenmesiyle devrilmesine, izolatörlerin kırılması ile çevreye ve canlıya zarar gelmesi, şalt sahasındaki transformatör vb. anahtarlama ve ölçüm yapan teçhizatların arızalanması ile sonuçlanabilir. 2022 yılında Japonya'da yaşanan bir fırtına sırasında EİH'ne düşen yıldırımlar nedeniyle fabrikayı besleyen hatta arıza oluşmuş ve hat devre dışı kalmıştır. Bu olay sonucu çip fabrikası üretim kapasitesinin %90'ını kaybetmiştir (Dobberstein 2022). Bu tür olaylar, enerji altyapısının yıldırım riskine karşı ne kadar kırılgan olduğunu ve yüksek maliyetli sonuçlarını ortaya koymaktadır. Ayrıca yıldırım darbeleri, EİH'de yüksek gerilimler ve ani dalgalanmalar oluşturarak sistemde geçici aşırı gerilimlere yol açabilir. Bu aşırı gerilimler, izolasyonları bozarak elektriksel atlamalara, faz-faz ve faz-toprak arızalarına sebep olabilir. Yapılan çalışmalar, yıldırım çarpmalarından kaynaklanan ani gerilim yükselmelerinin, enerji şebekelerinde yıllık yaklaşık %30 oranında kesintiye sebep olduğunu göstermektedir (Doostan ve Chowdhury 2020).

Bunun yanı sıra, yıldırım güç kalitesi problemlerine yol açarak tüketicilere sağlanan elektrikte ani gerilim dalgalanmalarına ve kısa süreli kesintilere neden olabilir. Hassas elektronik cihazlar bu tür değişimlerden olumsuz etkilenebilir, veri kaybına veya sistem hatalarına yol açabilir. Özellikle sanayi bölgelerinde, bu tür gerilim dalgalanmaları büyük ekonomik kayıplara neden olabilmektedir. Tayvan'daki çip üretim tesisleri, yıldırım kaynaklı kısa süreli elektrik dalgalanmaları nedeniyle milyonlarca dolarlık üretim kaybı yaşamıştır (Shilov 2020).

Topraklama problemleri, yıldırım düşmesi sırasında oluşan Yüksek akımlar,

topraklama sistemlerinde istenmeyen potansiyel farklarına neden olabilir. Bu durum, özellikle şalt sahasında çalışan personelin güvenliği için ciddi riskler oluşturabilir ve topraklama sisteminin etkinliğini azaltabilir (Vallejo vd. 2023). Bunun yanı sıra, şiddetli yıldırım darbelerinin kuru bitki örtüsünü tutuşturarak yangın çıkmasına neden olabileceği durumlar da meydana gelmektedir. Ayrıca, ahşap direkler veya binalar yıldırım etkisiyle yanma riski taşımaktadır. EİH altındaki yangınlar, elektrik şebekesinin arz ve güvenliği açısından da büyük bir tehdit oluşturmaktadır (Mitchell 2013).

Enerji altyapısında güvenliği sağlamak ve kesintileri en aza indirmek için yıldırım tahmini üzerine yapılan çalışmalar giderek artmaktadır. Geleneksel koruma yöntemleri, yıldırımın etkilerini azaltmada belirli bir başarı sağlasa da MÖ ve YZ tabanlı modeller sayesinde yıldırım kaynaklı arızalar önceden tahmin edilerek daha etkin önlemler alınabilmektedir. MÖ ve YZ algoritmaları, büyük veri setleri kullanarak yıldırım olaylarını tahmin etme konusunda güçlü bir alternatif sunmaktadır. Geliştirilen hibrit modellerin, yıldırım kaynaklı EİH arızalarını tahmin etme başarısını artırdığı ve bakım süreçlerini optimize etmek için kullanılabileceği yapılan çalışmalarda ortaya konmuştur. Han vd. (2021) çalışmasında özellikle ROA ve XGBoost gibi karar ağaçları tabanlı algoritmaların, EİH’de yıldırım kaynaklı arızaları tahmin etmek için son yıllarda yoğun olarak kullanıldığı belirtilmektedir. Yapılan çalışmalar, bu algoritmaların yüksek doğruluk oranları sunduğunu ve geleneksel yöntemlere kıyasla daha güvenilir tahminler yaptığını göstermektedir.

1.2. Yapay Zekâ ve Makine Öğrenmesi

Modern YZ uygulamaları yalnızca veriye dayalı modeller değil, aynı zamanda istatistiksel ve kuramsal temeller üzerinde de yükselmektedir (Dadashova 2021). Bu çalışmada kullanılan veri seti, 360.000 yıldırım kaydı kullanılarak elde edilen 713 arıza vakasını içeren Türkiye’nin en kapsamlı yıldırım-arıza ilişkisi analizidir. Geleneksel istatistiksel modeller, belirli hava koşullarını analiz ederken, MÖ büyük veri setlerinden öğrenerek daha karmaşık ilişkileri tespit edebilir. Bu bağlamda, çalışmada geliştirilen hibrit model, EİH’de yıldırım kaynaklı arızaları öngörmek için ROA ve XGBoost algoritmalarının birleşiminden oluşan bir yaklaşıma dayanmaktadır.

2000’li yıllardan itibaren büyük veri ve güçlü hesaplama sistemlerinin gelişmesi sayesinde YSA ve derin öğrenme alanlarındaki ilerlemeler, çeşitli alanlarda devrim yaratmıştır. Modern çağda YZ sağlıktan finans sektörüne, otonom sistemlerden enerji altyapılarına kadar geniş bir yelpazede kullanılmakta ve giderek daha fazla insan yaşamına entegre olmaktadır. Enerji sektöründe büyük veri analitiği ve MÖ, sistem güvenilirliğini artırmak ve bakım süreçlerini analiz etmek amacıyla yaygın olarak kullanılmaktadır (Entezari vd. 2023). Geleneksel istatistiksel modeller sıklıkla belirli hava koşullarını analiz ederken, MÖ modelleri büyük miktarda veriyi kullanarak daha karmaşık ilişkileri tespit edebilir.

1.3. Tez Çalışmasının Literatüre Katkısı

Bu tez çalışması, EİH’de yıldırım kaynaklı arızaların önceden tahmin edilmesiyle, enerji şebekesindeki güç kalitesinin artırılması ve beklenmedik kesintilerin en aza indirilmesini amaçlamaktadır. Bunun için yıldırım kaynaklı EİH arızalarının hibrit bir MÖ yöntemiyle tahmin edilmesi, işletmede bulunan EİH’nin zayıf noktalarının önceden

tespit edilmesi ve yeni yapılacak EİH için yıldırıma karşı işletme koşullarında iyileştirmeler yapılarak daha sağlıklı bir koruma yöntemi sunulmasıdır. Bununla birlikte ekonomik kayıpların, arıza ve bakım için harcanan zamanın azaltılması hedeflenmektedir.

Literatürde tekil model üzerine yapılan çalışmalar bulunurken (Raheem vd. 2023, Nicora vd. 2024), yapılan çalışmalar göstermektedir ki tek başına kullanılan modeller, belirli coğrafi bölgelerde ve atmosferik koşullarda yeterli doğruluğa ulaşmayabilmektedir. Özellikle yıldırımın oluşma mekanizmasının değişkenliği, kullanılan modelin adaptasyon kapasitesini doğrudan etkileyebilmektedir (Guastavino vd. 2022). Bu çalışma ise mevcut literatürde eksikliği hissedilen üç temel noktayı ele almaktadır: İlk olarak, yıldırım tahmininde sadece meteorolojik değişkenlere odaklanan geleneksel modeller yerine, EİH'lerine ait mühendislik değişkenleri de analiz edilmiştir. İkinci olarak, ROA ve XGBoost gibi farklı YZ yöntemleri birleştirilerek, tekil modellerin eksiklikleri giderilmeye çalışılmıştır. Üçüncü olarak CBS ile entegrasyon sağlanarak, yıldırım tahminlerinin bölgesel bazda değerlendirilmesi mümkün hale getirilmiştir. Bu yönleriyle çalışma, yalnızca mevcut hatların korunmasına değil, aynı zamanda yeni hatların planlanmasında da yenilikçi bir yaklaşım sunmaktadır.

Bu çalışmada önerilen hibrit model, RO ve XGBoost algoritmalarının güçlü yönlerini birleştirerek yıldırım kaynaklı arızaları daha yüksek doğrulukla tahmin etmeyi amaçlamaktadır. Model, yalnızca geçmiş yıldırım verilerini değil, aynı zamanda izolatör tipi, topraklama direnci, işletme gerilimi gibi EİH'ne özgü teknik parametreleri de içeren zengin bir veri kümesi kullanmaktadır. Bu yönüyle çalışma, MÖ algoritmalarının yalnızca meteorolojik faktörlere değil, mühendislik değişkenlerine dayalı tahmin gücünü artırmaya yönelik bir yaklaşım sunmaktadır. Ayrıca, modelin uygulanabilirliğini artırmak adına CBS tabanlı veri işleme teknikleri ile entegrasyonu sağlanmıştır. Böylece, EİH'nin yıldırıma karşı en zayıf noktalarının belirlenmesi için bölgesel risk analizine dayalı bir yöntem de elde edilebilir.

ROA, veri içindeki önemli değişkenleri belirleyerek daha iyi genelleştirme yaparken, XGBoost, hata oranlarını düşürerek tahmin gücünü artırmaktadır. Bu kombinasyon, yıldırım kaynaklı arızaların daha doğru tahmin edilmesine olanak tanımaktadır. Çalışmanın literatüre katkısı sadece model doğruluğunu artırmakla sınırlı kalmamaktadır. Aynı zamanda, enerji sektöründe uygulanabilirliği artırmak amacıyla model çıktılarının bakım planlaması süreçlerine entegrasyonu üzerine uygulamalı değerlendirmeler yapılmıştır. Bu çalışma, yalnızca teorik bir katkı sağlamakla kalmamış, aynı zamanda enerji sektöründe uygulanabilirliği yüksek bir model geliştirmiştir.

Hipotez şu alt başlıklarla sorgulanmıştır:

1. MÖ tabanlı hibrit model, tek başına kullanılan ROA veya XGBoost algoritmalarından daha yüksek doğruluk oranı sunar mı?
2. Model, hatalı pozitif ve hatalı negatif oranlarını azaltarak güvenilir bir tahmin performansı sağlar mı?
3. Arıza tahmini için en kritik değişkenler nelerdir ve modelin karar mekanizmasını hangi özellikler daha fazla etkiler?
4. Modelin EİH'de gerçek dünya koşullarına uygulanabilirliği nedir?

Modelin başarısı, doğruluk, AİK-EAA, kesinlik, duyarlılık ve F1-skor metrikleri ile ölçülmüştür. Bulgular, önerilen hibrit modelin tekil MÖ algoritmalarına göre daha yüksek doğruluk ve daha düşük hata oranı sunduğunu göstermiştir. Geliştirilen hibrit model, enerji şirketlerinin bakım planlamalarını optimize ederek yıldırım kaynaklı kesintilerini büyük oranda azaltma potansiyeline sahiptir. Önerilen sistem, gerçek zamanlı meteorolojik veri akışı ile entegre edildiğinde potansiyel bir erken uyarı sistemi olarak işlev görebilir.

1.4. Tezin Yapısı

Bu tez çalışması toplam altı ana bölümden oluşmaktadır:

1. Giriş: Çalışmanın amacı, önemi ve EİH’de yıldırım elektromanyetik tahmini konusundaki literatürdeki boşluklar açıklanmıştır. Çalışmanın temel motivasyonu açıklanmış ve kullanılan yöntemlerin kısa bir özeti verilmiştir.

2. Kaynak Taraması: Yıldırım tahmini üzerine yapılan önceki çalışmalar değerlendirilmiş ve literatürde kullanılan geleneksel yöntemler ile MÖ tabanlı modeller karşılaştırılmıştır. MÖ algoritmalarının EİH’leri üzerindeki etkileri incelenmiş, özellikle ROA ve XGBoost’un yıldırım tahmininde nasıl kullanıldığı ele alınmıştır.

3. Materyal ve Metot: Bu bölümde Yıldırım elektromanyetik dalga ve darbeleri, yıldırım tipleri ve teorileri, kullanılan veri setleri ve özellikleri tanıtılmıştır. Hibrit modelin nasıl oluşturulduğu, kullanılan MÖ algoritmaları ve modelin eğitime süreçleri açıklanmıştır.

4. Bulgular: Modelin test sonuçları, doğruluk oranları, AİK eğrileri, karışıklık matrisi ve diğer performans değerlendirme metrikleri sunulmuştur. Ayrıca, modelin gerçek yıldırım olayları üzerindeki başarısı değerlendirilmiş ve geleneksel yöntemlerle karşılaştırılmıştır.

5. Tartışma: Modelin performansı üzerine detaylı bir analiz yapılmış, elde edilen sonuçlar değerlendirilmiştir. Modelin avantajları ve sınırlamaları ele alınarak EİH üzerindeki pratik etkileri tartışılmıştır. Enerji şirketlerinin bakım maliyetlerini optimize etmelerine yardımcı olacak kritik içgörüler sunulmuştur.

6. Sonuç ve Öneriler: Çalışmanın genel değerlendirmesi yapılmış, sonuçlar özetlenmiş ve ilerleyen çalışmalar için öneriler sunulmuştur. Ayrıca, tez kapsamında geliştirilen hibrit modelin EİH üzerindeki uzun vadeli etkileri de değerlendirilmiş ve modelin farklı bölgelerde, farklı gerilim seviyelerinde ve alternatif çevresel koşullarda uygulanabilirliğini test edecek çalışmalar önerilmiştir. EİH’de yıldırım tahmininin daha ileriye taşınması için MÖ algoritmalarının, gerçek zamanlı IoT tabanlı izleme sistemleriyle entegre edilerek, farklı iklim bölgelerinde validasyonu, modelin endüstriyel uygulanabilirliğini arttıracaktır.

2. KAYNAK TARAMASI

Yıldırım kaynaklı arıza tahmini literatürü, geleneksel meteorolojik modellere kıyasla daha yüksek doğruluk sağlayan MÖ tabanlı hibrit yaklaşımlara doğru evrilmektedir. MÖ tabanlı yıldırım tahmin modellerinde en önemli faktörlerden biri, modelin eğitildiği veri setinin temsiliyet gücüdür. Bu nedenle, eğitim verilerinin dengeli dağılıma sahip olması modelin başarısını doğrudan etkilemektedir. Ancak, EİH'leri üzerindeki yıldırım kaynaklı arızaların tahmini için sistematik hibrit model çalışmaları sınırlıdır (Zhou vd., 2024). Bu tez, ROA ve XGBoost algoritmalarını birleştirerek EİH'de yıldırım kaynaklı arızaları tahmin eden ilk hibrit modeli sunmaktadır. Literatürdeki boşluğu doldurmak amacıyla, bu bölümde geleneksel yıldırım tahmin yöntemlerinin sınırlamaları, MÖ tabanlı modellerin avantajları ve hibrit yaklaşımların önemi, EİH'de yıldırım-arıza ilişkisini inceleyen çalışmalar ayrıntılı bir perspektifle analiz edilmiştir.

2.1. Yıldırım Tahmini İçin Kullanılan Geleneksel Yöntemler

Geleneksel yıldırım tahmin yöntemleri YSA, MÖ gibi tahmin yöntemi ortaya konmadan önce kullanılmıştır. Bu yöntemler arızanın nedeninin tam olarak bilinmemesi sonucu ortaya çıkmıştır. Genel olarak tahmin öncesi çalışmalarda yıldırım aşırı gerilim üst değeri üzerine yapılmıştır. Bu yöntemler arıza sınıflandırması, yıldırım darbe aşırı gerilimlerinin hesaplanması, korona yarıçapı yöntemi, klasik geniş hava aralığı deşarj teorisi, yıldırımdan koruma yöntemleri için koruma teli teorileri, iletim hattı modeli, Kuasi- TEM, EAİD yöntemi ile Maxwell denklemlerine dayalı kapsamlı analizler olarak ortaya konabilir (Huang vd. 2024).


Kordi vd. (1999) ortaya koydukları çalışmada yıldırım kaynaklı yüksek gerilimlerin tahmininde yaygın olarak kullanılan iletim hattı kuplaj modeli ile EAİD yöntemi arasındaki karşılaştırmayı ele almaktadır. Çalışmada, iletim hattı yönteminin, güç sistemlerindeki yıldırım kaynaklı aşırı gerilimleri hesaplamak için geleneksel olarak kullanıldığı ancak karmaşık iletim hatlarında bazı sınırlamaları olduğu belirtilmektedir. Sonuç olarak ise karmaşık EİH sistemlerinde EAİD yaklaşımının daha güvenilir olduğu, ancak hesaplama süresinin uzun olduğu belirtilmiştir. İletim hattı modeli ise daha basit ve hızlıdır ancak karmaşık yapıların modellenmesinde zayıf kalabileceği öne sürülmüştür. Kordi vd. (1999) çalışmasında aşırı gerilim üst değerlerinin hesaplanmasını ortaya koymuşlardır ama EAİD yönteminin yüksek hesaplama maliyeti, pratik uygulamalarda sınırlayıcı bir unsur olarak değerlendirilmektedir.

He vd. (2010) çalışmasında çift devreli UHV havai iletim hatlarının yıldırım koruma performansını değerlendirmişlerdir. UHV EİH'de meydana gelen kesintilerin %90'ından fazlasının yıldırımdan korunma başarısızlığı nedeniyle olduğu, Çin ve Japonya'daki çift devreli UHV hatlarının yıldırım koruma performansları analiz edilmiştir. Geleneksel elektro geometrik model yönteminin tahminleri saha gözlemleriyle çelişmekte olduğu ortaya konmuş ve yeni bir 2 boyutlu analiz modeli önerilmiştir. Geleneksel modelin hatalı sonuçlar verdiği ve yenilenmesi gerektiği ortaya konulmuştur.

Atmosferik ve radar verilerine dayalı yıldırım tahmini mikro ölçekli değişimlere duyarsız kalabilmektedir. Yapılan çalışmalar, yıldırım tahmini için en belirleyici faktörlerin bulut hareketleri, nem oranı, sıcaklık değişimleri ve atmosferik basınç

olduğunu göstermektedir (Cummins ve Murphy 2010; Cecil vd. 2014; Poelman 2016). Ancak, bu yaklaşımlar gerçek zamanlı tahmin yapmada ve bölgesel farklılıkları hesaba katmada sınırlılıklara sahiptir. Geleneksel istatistiksel yöntemler, kısa vadeli tahminlerde başarılı olsa da yıldırımın coğrafi dağılımını öngörmekte yetersiz kalmaktadır (Cummins ve Murphy, 2010). Yıldırım tahmini üzerine yapılan önceki araştırmalar, fiziksel modelleme yöntemleri ve veri odaklı tahmin teknikleri olarak iki ana gruba ayrılmaktadır (Bonilla vd. 2023). Fiziksel modelleme yaklaşımlarında atmosferdeki elektriksel yük dengesizlikleri ve fırtına bulutlarının oluşumu analiz edilirken özellikle geçiş iklim bölgelerinde yeterli tahmin doğruluğunu sağlayamamaktadır.

Bedoui vd. (2010) çalışmasında 220 kV çift devreli iletim hatlarında yıldırım korumasının, metal oksitli parafudurlar kullanılarak değerlendirilmesini ele almaktadır. ATP/EMTP yazılımı kullanılarak gerçekleştirilen simülasyonlarla, yıldırım çarpmalarının neden olduğu aşırı gerilimlerin analizi yapılmış ve parafudurların yıldırım koruma performansı üzerindeki etkisi incelenmiştir. Parafudurlar, yıldırım darbe akımlarının neden olduğu aşırı gerilimlerin belirli seviyelerin altına çekilebileceği gösterilmiş ancak sadece EİH’de yapılan iyileştirmelerin tam bir koruma sağlamayacağı ortaya konulmuş, trafo merkezlerinde de ek koruma önlemleri gerekliliği vurgulanmıştır. Şekil 2.1 ile yıldırımın bir kuleye düşmesi bile yakın kulelerdeki parafudurların hedef kuledeki gerilim tepelerini bastırabildiğini göstermektedir.



Şekil 2.1. Parafudur konumlandırmasının etkisi (Bedoui vd. 2010).

Zhou vd. (2024) hazırladığı ve geleneksel modellerin eleştirildiği çalışmada, yıldırım tahmini için geleneksel meteorolojik modellerin eksikliklerini ele almak üzere geliştirilmiş bir model sunulmuştur. Model, derin öğrenme ve çok ölçekli uyarı


mekanizmaları kullanarak yıldırım tahminlerinde doğruluğu artırmayı amaçlamaktadır. Radar, uydu, hava durumu tahmini gibi çok kaynaklı verileri entegre edip, uzaysal ve zamansal veri özelliklerini iyileştirmek için çok ölçekli mekanizmaları kullanmıştır. Geleneksel modellerden daha yüksek CSI ve daha düşük hatalı pozitif sınıflandırma oranı ile daha güvenilir tahminler üretmiştir. Model, EİH'nin yıldırımdan korunması, havacılık ve acil durum yönetimi gibi alanlarda uygulanabilir noktaya gelmiştir. Ancak deney sonuçları, modelin hava olaylarının kısa vadeli tahminlerinde başarılı olmuş, orta ve uzun vadeli analizlerde ise başarı gösteremediği anlaşılmıştır.

Yıldırım tahmini için kullanılan geleneksel yöntemlerden bir diğeri atmosferik elektrik alanı ölçümlerine dayalı uyarı sistemleridir. Tao vd. (2016) tarafından geliştirilen modelde, atmosferik elektrik alan değişimleri ve yıldırım konumlandırma sistemleri birleştirilerek, EİH'de daha güvenilir yıldırım uyarıları sağlanmıştır. Bu çalışma, 15 dakika önceden sarı uyarı sinyali göndermiş ve sahadan gelen gözlemlerle doğruluğu teyit edilmiştir. Geleneksel yöntemlerin eksikliklerini gidermeye yönelik önemli bir katkı sunmaktadır.

2.2. MÖ Tabanlı Yıldırım Tahmin Modelleri

MÖ modelleri, yıldırım tahmininde giderek daha yaygın bir şekilde kullanılmaktadır. Shin vd. (2024) tarafından geliştirilen ROA tabanlı model, yıldırım tahmininde %84,25 doğruluk oranı sağlamıştır. Benzer şekilde, Zhou vd. (2024) tarafından önerilen derin öğrenme tabanlı model, yıldırım tahmini için %91,5 doğruluk oranına ulaşmıştır. Bu modelin, geleneksel yöntemlerden daha yüksek performans göstererek özellikle ani hava olaylarının tahmininde etkili olduğu belirtilmiştir. Ancak, Shin vd. (2024) tarafından önerilen ROA modeli, hatalı negatif oranlarının yüksek olması nedeniyle bazı yıldırım olaylarını kaçırmıştır. Modelin doğruluğu yüksek olmasına rağmen, yıldırım darbesinin olmadığı durumlarda yanlış tahminler ürettiği belirtilmiştir.


Nicora vd. (2024) çalışmalarında MÖ tabanlı bir model kullanılarak bulut-yer yıldırımlarının konumunun ve tepe akımının tahmin edilmesi ele alınmıştır. Çalışmada, havai EİH üzerindeki yıldırım kaynaklı gerilim ölçümleri kullanılarak bir regresyon modeli geliştirilmiş ve bu modelin geleneksel LLS'ye kıyasla daha yüksek doğruluk sağlama potansiyeline sahip olduğu gösterilmiştir. Model, ön işleme adımı olarak ana bileşen analizi uygulayarak giriş verilerinin boyutunu azaltmış ve ardından yüzeysel bir YSA ile eğitilmiştir. Elde edilen sonuçlar, modelin yıldırım konumlandırma hassasiyetinin mevcut LLS yöntemleriyle karşılaştırılabilir seviyede olduğunu ve tepe akımı tahmininin doğrudan kule ölçümlerinden daha geniş kapsamlı ve doğru olabileceğini ortaya koymuştur. Bu yaklaşım, yüksek maliyetli geleneksel yıldırım algılama sistemlerine kıyasla önemli bir maliyet avantajı sağlamıştır. Ayrıca EİH'de yıldırım kaynaklı riskleri azaltmak için alternatif bir çözüm sunmaktadır. Çalışmanın analiz sonuçlarının tatmin edici olmadığı Şekil 2.2'de görülmektedir. Şekil 2.2 (a) Sabit tepe akımı ve ideal zemin koşulları iken Şekil 2.2 (b) rastgele değişen tepe akımları ve iletken olmayan zemin koşulları verilmektedir. İdeal koşullarda 62 m olan hata miktarı değişen şartlarda 290 m'ye çıkmaktadır.



Şekil 2.2 a) İdeal şartlar için MAPE: %0, 62 m **b)** Değişen tepe akımı ve iletken olmayan zemin koşullarında MAPE: %12,5 290 m hassasiyet (Nicora vd. 2024).

Yang vd. (2019), hava koşullarına bağlı olarak EİH’de meydana gelen arıza olasılıklarını tahmin etmek için bir yöntem önermişlerdir. Çalışmalarında, Çin’in Guangxi Zhuang Özerk Bölgesi’ndeki 110 kV havai EİH’nin 2011-2014 yılları arasındaki kesinti ve hava durumu verilerini analiz etmişlerdir. Bulgular, kesinti olaylarının mekânsal ve zamansal olarak düzensiz dağıldığını ve özellikle yıldırım ve rüzgâr gibi şiddetli hava koşullarının iletim hatlarındaki ana arıza nedenleri olduğunu göstermektedir. Poisson modeli ile hava koşullarının arıza olasılığı üzerindeki etkisi incelenmiş ve gerçek kesinti verileriyle doğrulama yapılmıştır. Çalışma, hava durumu tahmin verilerine dayanarak iletim hatlarındaki arıza olasılığının öngörülebileceğini göstermiş ve şebeke operatörlerinin bakım planlarını optimize etmelerine yardımcı olabilecek bir yöntem sunmuştur.

Xie vd. (2019) çalışmasında EİH’de yıldırım kaynaklı kesintilerin tahmin edilmesi için genel regresyon sinir ağı tabanlı bir YZ modelini önermektedir. Araştırmada, iletim sistemlerinden elde edilen yıldırım ve yıldırım kaynaklı kesinti verileri kullanılarak, modelin yıldırım kaynaklı kesintileri önceden tahmin etme başarımı değerlendirilmiştir. Model, iletim hatlarına ait yıldırım düşme olasılığını belirleyen faktörleri analiz ederek eğitim verilmiş ve test edilmiştir. Simülasyon sonuçları, modelin, geri yayılım ve radyal baz fonksiyonlu sinir ağı gibi diğer MÖ modellerine kıyasla daha yüksek doğruluk sağladığını göstermektedir. Şekil 2.3 (a)’da 1,5 km’den başlayarak (b) 2 km, (c) 3 km ve (d) 5 km yıldırım koridoru için analizler sunulmuştur. Çalışmada ROA, XGBoost, LSTM gibi gelişmiş MÖ ve derin öğrenme modelleriyle kıyaslama yapılmamış, ayrıca gerçek zamanlı kullanım, daha geniş veri setleriyle genelleştirme, mühendislik değişkenlerinin entegrasyonu ve daha güçlü alternatif modellerle kıyaslama gibi eksiklikler bulunmaktadır.



Şekil 2.3. a) yıldırım koridoru 1,5km b) yıldırım koridoru 2 km c) yıldırım koridoru 3km d) yıldırım koridoru 5 km (Xie vd. 2019).

Huo vd. (2024) tarafından yapılan çalışmada, EİH'deki yıldırım kaynaklı arızaları önlemek için XGBoost tabanlı bir tahmin modeli geliştirilmiştir. Çalışmanın sonuçları, Kuzey Çin'de yapılan testlerde %80 doğruluk oranına sahip bir erken uyarı sistemi geliştirilerek hatalı pozitif sınıflandırmaların azaltıldığını göstermektedir. Ayrıca, yüksek riskli yıldırım bulutları ve EİH korunma seviyelerine dayalı erken uyarılar üreten bir model önerilmiştir.

Asadi vd. (2024) tarafından yapılan çalışmada, XGBoost, YSA ve ROA algoritmalarının yıldırım konumlandırma üzerindeki performansları karşılaştırılmıştır. Çalışmada, EİH boyunca yerleştirilen iki sensörden elde edilen yıldırım kaynaklı gerilim verileri kullanılmış ve bu veriler üzerinden yıldırım konumlarının tahmini gerçekleştirilmiştir. Yapılan simülasyonlarda, XGBoost algoritmasının, diğer MÖ yöntemlerine kıyasla hem konum doğruluğu hem de hesaplama süresi açısından daha verimli olduğu belirlenmiştir. Çalışmada, ana bileşen analizi uygulanarak veri boyutu 50 kat azaltılmış ve modelin tahmin performansı korunurken işlem süresi önemli ölçüde düşürülmüştür. Böylece, büyük veri setleriyle çalışırken bilgi kaybı en aza indirilerek daha hızlı ve verimli tahminler elde edilmiştir. Bu sayede büyük veri kümeleriyle çalışırken performans kaybı yaşanmadan yüksek doğrulukta tahminler elde edilmiştir. YSA ve ROA algoritmaları uygulanmış olmasına rağmen, sadece XGBoost sonuçlarına yer verilmiştir. Bu durum, yapılan karşılaştırmaların sınırlı kalmasına neden olmuştur.


Hebbagilu vd. (2024) çalışmasında önerilen model, geleneksel yöntemlerden farklı olarak çoklu veri kaynaklarını birleştiren bir derin öğrenme mimarisi sunmaktadır. CNN tabanlı yaklaşımlar, yıldırım tahmini konusunda istatistiksel modellere kıyasla daha yüksek doğruluk oranlarına sahiptir. Modelin sadece yıldırım görseli ile çalışması, çok

çeşitli meteorolojik verilerin entegre edilmediğini göstermektedir. Ayrıca model için kullanılan 90 eğitim ve 10 test örneği oldukça sınırlıdır.

Geng vd. (2019) yıldırım tahmini için geleneksel yöntemlerin zayıflıklarını gidermek amacıyla LightNet adlı bir model önermişlerdir. LightNet, YSA kullanarak hem geçmiş yıldırım gözlemlerini hem de simülasyon verilerini birleştiren çift yönlü bir kodlayıcı mimariye sahip olan model, geçmiş yıldırım olaylarından öğrenerek tahmin doğruluğunu arttırmıştır. Çalışmanın bulgularına göre, LightNet, üç saatlik tahminlerde geleneksel yöntemlere kıyasla üç kat daha iyi performans göstermektedir ancak çalışmanın başarılı olması hem sayısal hava tahmin simülasyonlarına hem de gerçek ve güncel zamanlı gözlem verilerine bağlıdır. Gözlem verisi güncel veya doğru olmazsa, tahminlerin de sapabileceği aşikârdır.

Cheng vd. (2024) tarafından yapılan çalışma, MÖ tabanlı yıldırım parametrelendirme modellerinin geliştirilmesini ele almaktadır. Çalışmada, dünya çapında yıldırım konumlandırma açısından alınan yıldırım gözlem verileri ile üç farklı MÖ algoritması eğitilerek yıldırım yoğunluğunun tahmini gerçekleştirilmiştir. Kullanılan modeller, yerel ve bölgesel atmosferik değişkenleri girdi olarak kullanarak yıldırım yoğunluğunu tahmin etmeye çalışmıştır. Sonuçlar, geleneksel yıldırım parametrelendirme yöntemlerine kıyasla MÖ tabanlı modellerin özellikle yıldırım yoğunluğunun yüksek olduğu bölgelerde daha başarılı tahminler sağladığını göstermiştir. Çalışma, EİH'deki yıldırım kaynaklı arızaların tahmini için MÖ yaklaşımlarının önemini vurgulamakta ve bu alandaki modellerin iyileştirilmesi için veri odaklı yöntemlerin gerekliliğini ortaya koymaktadır. Diğer taraftan modelin bazı girdileri arasında ise yüksek korelasyon bulunması, açıklanabilirliği azaltmaktadır.

Adiaksa vd. (2024) tarafından yapılan çalışmada, 150 kV Bukit Asam- Baturaja EİH'deki yıldırım düşmelerini tahmin etmek için modellerin karşılaştırmalı analizini gerçekleştirilmiştir. Çalışmada, 2018-2024 yılları arasındaki yıldırım verileri kullanılmış ve modellerin performansı çeşitli hata ölçütleri ile değerlendirilmiştir. Şekil 2.4'te paylaşılan sonuçlara göre, Transformer modeli en yüksek doğruluk oranına ulaşmış, diğer modellere kıyasla çok daha düşük hata oranları sergilemiştir. Transformer modelinin özellikle uzun vadeli bağımlılıkları daha iyi öğrenerek yıldırım tahmini süreçlerini önemli ölçüde iyileştirdiği belirlenmiştir. Model yalnızca tek EİH verisiyle eğitilmiştir. Bu durum modelin genelleme kabiliyetini sınırlamıştır. Farklı iklimsel, coğrafi veya altyapısal koşullarda bu modelin aynı başarıyı sağlayıp sağlayamayacağı ise belirsizdir. Ayrıca Transformer modeli genel olarak başarılı sonuçları vermesine rağmen, MAPE değerinin yüksek olması, özellikle sifıra yakın veri noktalarında oransal hata yüzdelерinin abartılı çıkmasına neden olmuştur.



Şekil 2.4. Transformer modelinin yıldırım tahmin performansı (Adiaksa vd. 2024).

Sulaiman vd. (2023) çalışmalarında, ileri beslemeli sinir ağı kullanılarak yıldırım oluşumlarının konumunun tahmin edilmesi ele alınmıştır. Çalışmada, Malezya Meteoroloji Departmanı'ndan elde edilen yıldırım gözlem verileri kullanılarak, yıldırım olaylarının meydana gelebileceği konumlar başarıyla tahmin edilmiştir. Modelin girdileri, yıldırım şiddeti, yönü, uzaklığı ve majör eksen ölçümleridir. Çıktı olarak ise yıldırımın enlem ve boylam bilgisi tahmin edilmiştir. Bu model, uzun kısa süreli bellek ağları ile karşılaştırılmış ve daha düşük hata oranları ile daha iyi performans sergilediği belirlenmiştir. Çalışma, derin öğrenme tekniklerinin geleneksel yöntemlere kıyasla yıldırım tahmininde daha yüksek doğruluk sağlayabileceğini göstermiştir. EİH'nin korunmasına yönelik geliştirilecek modeller için önemli bir temel oluşturabileceğini göstermektedir ancak verideki gürültü seviyesinin özellik mühendisliğini karmaşıktırabileceği, sadece 1 yıllık veri kullanılması da modelin genelleme kapasitesini sınırlayabileceği öngörülmektedir.

EİH'de yıldırım kaynaklı arızaların tahmini üzerine yapılan çalışmalar, özellikle farklı MÖ algoritmalarının başarımını karşılaştırarak en uygun yöntemleri belirlemeye odaklanmıştır (Wokoma vd. 2024; Anwar vd. 2025). Tanyıldızı (2022) tarafından yapılan çalışma, DVM, KNN, karar ağaçları, topluluk öğrenme ve doğrusal ayırım analizi algoritmalarını kullanarak EİH'deki arızaların sınıflandırılmasını ele almıştır. Çalışmada, faz-toprak, fazlar arası arızalar ve arıza olmayan durumlar analiz edilmiş ve MÖ algoritmalarının sınıflandırma doğrulukları karşılaştırılmıştır. Sonuçlara göre, DVM ve KNN algoritmalarının en yüksek doğruluk oranlarına ve en düşük hata oranlarına sahip olduğu belirlenmiştir. Karar ağaçları en hızlı tahmin süresini sağlarken, doğrusal ayırım analiz algoritması en kısa eğitim süresini sunmuştur. Bu bulgular, yıldırım kaynaklı EİH'deki arızaların tespitinde MÖ modellerinin önemli bir rol oynayabileceğini ve algoritma seçiminde doğruluk, hata oranı ve işlem süresi gibi faktörlerin dikkate alınması gerektiğini göstermektedir. Bu kapsamda, bu tez çalışmasında geliştirilmiş hibrit modelin

algoritma seçimi, eğitim süreci ve doğruluk değerlendirmesinde bu çalışmanın sunduğu karşılaştırmalı analizlerden faydalanılmıştır.

Shin vd. (2024) tarafından gerçekleştirilen çalışma, ROA tabanlı bir model olan LightningRF'nin kısa vadeli yıldırım tahmini için kullanımını incelemektedir. Çalışmada, Kore Meteoroloji İdaresi tarafından sağlanan yıldırım gözlem verileri ile Kore yerel analiz ve tahmin sistemi'nden alınan meteorolojik değişkenler kullanılmıştır. Model, SHO ile farklı atmosferik değişkenleri girdi olarak kullanarak 6 saatlik tahminler yapmaktadır. Ortalama %84,25 doğruluk oranı elde edilmiştir. Ancak, modelin uzun vadeli tahminlerde düşük performans gösterdiği ve hatalı pozitif tahminlerin fazla olduğu belirtilmiştir. Gelecek çalışmalarda, derin öğrenme modelleri ile karşılaştırmalar yapılması ve radar ile uydu verilerinin entegrasyonu önerilmektedir. Çalışma, MÖ tekniklerinin yıldırım tahmini süreçlerinde başarılı bir şekilde uygulanabileceğini göstererek, EİH'de kullanılabilecek modeller için önemli bir referans oluşturmaktadır.

Çizelge 2.1. Öne çıkan modellerin performans özeti

Çalışma	Algoritma	Doğruluk %	Veri Kaynağı
Hebbagilu vd. (2024)	LPAS+CNN	-	Video kaydı
Geng vd. (2019)	LightNet	77,7	China Meteorology Institute
Cheng vd. (2024)	ROA, CNN	Hata oranı %3	WWLLN
Adiaksa vd. (2024)	RNM+LSTM	95,43	Hat İşletme Verisi
Sulaiman vd. (2023)	FFNN	Hata oranı %5	MET Malaysia
Tanyıldızı (2022)	LDA	%100	Karşılaştırma
Shin vd. (2024)	ROA	84,25	KMA Radar verisi
Zhou vd. (2024)	SCE-RCNN	92,5	Çok kaynaklı meteorolojik veri
Nicora vd. (2024)	LLS	78,3	LLS ve direk ölçümü
Hibrit model	ROA+XGBoost	94,1	MGM ve Hat işletme verileri

DVM, yıldırım tahmininde kullanılan yöntemlerden biridir. Ancak, büyük veri kümelerinde işlem maliyetinin yüksek olması, bu yöntemin kullanımını sınırlamaktadır (Chang ve Lin 2011; Halloran ve Roche 2018). ROA modeli ise karar ağaçları topluluğu olarak çalışmakta olup, yıldırım tahmini için yüksek doğruluk sağlamaktadır (Mecikalski vd. 2021; Breiman, 2001). ROA ile özellikle sınıflandırma ve regresyon problemlerinde yüksek performans gösteren XGBoost, yıldırım tahmininde de başarılı sonuçlar vermektedir (Chen ve Guestrin 2016; Xin vd. 2021). En yüksek verimin elde edildiği hibrit modeller farklı algoritmaların birleşimiyle oluşturulan hibrit yaklaşımlar, yıldırım tahmininin doğruluğunu artırmak için kullanılmaktadır (Katuwal ve Suganthan 2019; Fawaz vd. 2019).

2.3. Hibrit Modellerin Kullanımı

Yıldırım kaynaklı EİH arızaları, enerji kesintileri ve altyapı zararlarının azaltılması için çeşitli yöntemler önerilmiştir (Heidler vd. 2008; Visacro vd. 2021). Yapılan çalışmalar, hibrit modellerin tekil algoritmalara göre %10 ila %25 daha yüksek doğruluk sağlayabildiğini göstermektedir (Zraibi vd. 2021; Raheem vd. 2023). Hibrit modellerin başarısı, farklı algoritmaların güçlü yönlerini birleştirerek tahmin doğruluğunu artırmalarından kaynaklanmaktadır. ROA ve XGBoost'un güçlü yönleri birleştirildiğinde, yıldırım tahmini doğruluk oranı belirgin şekilde artmaktadır. Breiman

(2001) ROA çalışmasını ortaya koyarken, aşırı öğrenmeyi engelleyerek genelleme yeteneği vurgulamıştır. Chen ve Guestrin (2016), çalışmasında XGBoost'un hata oranlarını minimize ederek daha hassas tahminler ürettiğini belirtmiştir. Literatürde hibrit modellerin EİH'de kullanımı üzerine yapılan çalışmalar oldukça sınırlıdır. Ayrıca tek başına kullanılan modeller performans, zaman kaybı gibi bazı durumlarda yetersiz kalabilir (Fatima vd. 2023). Hibrit model, bu iki algoritmanın avantajlarını birleştirerek doğruluk oranını artırmakta ve yıldırım kaynaklı arızaların daha güvenilir şekilde tahmin edilmesini sağlamaktadır (Zraibi vd. 2021).

EİH'de meydana gelen yıldırım kaynaklı arızaların tahmini için istatistiksel ve fiziksel modellerin yanı sıra, CBS ve YSA gibi teknikler de kullanılmıştır (Izadi vd. 2012; Mostajabi vd. 2019). Ancak, hibrit bir MÖ modeli kullanılarak yapılan tahminlerin doğruluğunu artıran çalışmalar kısıtlıdır.

Literatürde yıldırım tahmini için farklı MÖ modelleri önerilmiş olsa da tek bir algoritmanın belirli senaryolarda düşük doğruluk gösterebildiği bilinmektedir. Bu nedenle, farklı algoritmaların güçlü yönlerini birleştiren hibrit modeller geliştirilmiştir. Nicora vd. (2024) yıldırımın konum ve akım şiddetini tahmin etmek için ana bileşen analizi ve YSA'yı birleştiren bir model önermiştir. Bu çalışma tam olarak hibrit model olarak değerlendirilmese de ana bileşen analizi ile boyut azaltma sağlanarak hesaplama süresi düşürülmüş ve modelin doğruluğu artırılmıştır. Bu tür yaklaşımlar, hibrit modellerin yıldırım tahmini doğruluğunu iyileştirebileceğini göstermektedir.

Yıldırımın EİH etkisini değerlendirmek için farklı yöntemler geliştirilmiştir. Zheng vd. (2021) çalışmalarında EİH'nin yıldırım kaynaklı risklerini değerlendirmek amacıyla geliştirilmiş olan analitik hiyerarşi süreci tabanlı bir modeli tanıtmaktadır. Çalışmada, KNN ile EİH boyunca coğrafi özellikler sınıflandırılmış ve 10 farklı faktör belirlenmiştir. Bu faktörlerin yıldırım arızalarıyla olan ilişkisi analiz edilerek, güçlü korelasyon gösterenler belirlenmiş ve risk değerlendirme modeli oluşturulmuştur. Model, Çin'de 220 kV gerilim seviyesine sahip 28 EİH üzerinde test edilmiş ve tahminlerin doğruluk oranı %76 olarak belirlenmiştir. Sonuçlar modelin başarılı tahminler yaparak EİH'nin yıldırıma karşı korunmasında önemli bir katkı sunduğunu göstermektedir. Çalışmada EİH'nin yıldırımdan kaynaklanan arızalarını tahmin etmek ve koruyucu önlemler geliştirmek için veri madenciliği tekniklerinin ve analitik yöntemlerin birleştirilmesinin önemini vurgulamaktadır. Kullandıkları yöntem, ağırlık hesaplamalarında veri destekli ölçümleme yapmış olsa da bazı kriterlerin ağırlıkları hâlâ uzman deneyimlerine ve öznelliğe dayalı olarak belirlenmiştir. Bu durum da kişiye dayalı veri olduğu için hataya açık konuma gelmektedir. Çalışmada modelin performansı geleneksel yöntemlerle karşılaştırılmıştır; ancak ROA, XGBoost vb. MÖ algoritmaları ile doğrudan karşılaştırma yapılmamıştır.

Yıldırımın EİH'na zarar verme potansiyeli, hat kesintileri ve istenmeyen yüksek gerilim olayları nedeniyle ciddi bir mühendislik problemi oluşturmaktadır. Bu bağlamda, Huo vd. (2024) tarafından gerçekleştirilen çalışma, yıldırımdan korunma yöntemlerini ve EİH için erken uyarı sistemlerinin geliştirilmesini ele almaktadır. Çalışmada, geriye dönük yıldırım verileri analiz edilerek, fırtına bulutlarının hareket yönlerinin tahmini için bir model geliştirilmiştir. Model, EİH'de yüksek yıldırım riski oluşturan hava olaylarını

belirleyerek gerçek zamanlı yıldırım uyarıları sağlamaktadır. Çin'in kuzey bölgesinde yapılan vaka çalışması sonucunda, önerilen yöntemin belirli hatlar için %80 doğruluk oranına ulaştığı tespit edilmiştir. Çalışmanın sonuçları, Çizelge 2.2'den de görüleceği üzere, yıldırım verilerinin analiz edilerek erken uyarı sistemleri ile EİH'nin daha güvenli hale getirilebileceğini göstermektedir. Bu yaklaşım, MÖ tabanlı hava tahmin sistemlerinin enerji şebekelerinin korunmasında kritik bir rol oynayabileceğini ortaya koymaktadır. Model en az 20 dakikalık yıldırım aktivitesi sonrasında tahmin üretebilmiş bu da bazı erken yıldırım olaylarının kaçırılmasına neden olmuştur. Ayrıca bölgesel ve meteorolojik farklılıklar nedeniyle diğer coğrafyalarda da test edilmesi gerekmektedir.

Çizelge 2.2. (a) Erken uyarı yönteminin performansı (b) iletim hatları için yıldırım erken uyarı yönteminin performansı (Huo vd. 2024)

Yüksek Riskli Fırtınada Erken Uyarı Sistemi (a)			Yıldırım koruma değerlendirme modeli erken uyarı yönteminin performansı (b)		
Uyarı durumu	Gerçek kesinti oluşumu gerçekleşme	Gerçek kesinti oluşumu gerçekleşmeme	Uyarı durumu	Gerçek kesinti oluşumu gerçekleşme	Gerçek kesinti oluşumu gerçekleşmeme
Uyarı verildi	2	0	Uyarı verildi	6	7
Uyarı verilmedi	8	135	Uyarı verilmedi	4	128
Sınıflandırma doğruluğu: %94,48, Kaçırılan tespit oranı: %80, Uyarı doğruluğu: %20, Hatalı pozitif sınıflandırma oranı: %0			Sınıflandırma doğruluğu: %92,41, Kaçırılan tespit oranı: %60, Uyarı doğruluğu: %40, Hatalı pozitif sınıflandırma oranı: %53,85		

Hibrit MÖ modelleri, farklı arıza tiplerini daha iyi ayırt edebilme kapasitesine sahiptir. Rafi vd. (2024) tarafından önerilen YSA-DVM hibrit modeli, iletim hatlarındaki arızaların tespiti için geliştirilmiş ve kısa devre arızalarında %98 doğruluk oranı ile başarılı sonuçlar vermiştir. Makine öğrenimi tabanlı hibrit modeller, iletim hatlarındaki arıza tespitini önemli ölçüde iyileştirebileceğini, YSA-DVM modelinin güç sistemlerindeki hataların erken teşhisi için etkili bir çözüm sunabileceği bildirilmiştir. Çalışmanın eksik yönleri ise modelin eğitimi ve testleri, MATLAB kullanılarak üretilmiş gerçek olmayan verilerle yapılmıştır. Sahadan alınan ölçüm verileri kullanılmamış, bu da modelin normal koşullarda ne kadar güvenilir olduğu konusunda sınırlılık oluşturmaktadır. Ayrıca saha koşullarındaki verilerinde gürültü, eksiklik veya anormallikler, modelin performansını olumsuz etkileyeceğinden bahsedilmemiştir.

Çizelge 2.3. Çalışma performansı için değerlendirme metrikleri (Rafi vd. 2024)

Modeller	Ağırlıklı Hassasiyet	Ağırlıklı Duyarlılık	F1-Skor	Doğruluk
LR	86,00 %	81 %	82 %	82,43 %
YSA	92,00 %	90 %	90 %	90,21 %
DVM	92,00 %	92 %	92 %	92,57 %
ROA	91,00 %	93 %	91 %	92,78 %
Hibrit	98,00 %	99 %	98 %	98,43 %

Doostan ve Chowdhury (2020) tarafından yapılan çalışma, enerji dağıtım sistemlerinde yıldırım kaynaklı arızaların tahmin edilmesine yönelik istatistiksel ve MÖ


tabanlı bir model önermektedir. Çalışmada, büyük ölçekli bir enerji şirketinden alınan geçmiş kesinti verileri ile radar hava tahmin verileri birleştirilerek kısa vadeli yıldırım kaynaklı arıza tahmini yapılmıştır. Araştırmada, yıldırım nedeniyle arızaların meydana gelme olasılığının belirlenmesi ve tahminin zamansal ve mekânsal olarak optimize edilmesi hedeflenmiş, bu amaçla denetimsiz MÖ yöntemleriyle arıza kümeleri oluşturulmuş ve olasılık modelleri kullanılarak belirli bir gün için kesinti olasılığı hesaplanmıştır. Ayrıca belirli bir bölgede hangi kesinti türünün meydana geleceği tahmin edilmiştir. Model Çizelge 2.4'te de üç farklı vaka çalışmasıyla test edilmiş ve modelin kısa vadeli yıldırım tahminlerinde yüksek doğruluk sağladığı ortaya konulmuştur. Modelin tahmin doğruluğu %81,7 ile sınırlı kalmıştır. Hatalar, modelin bazı örnekleri doğru sınıflandıramamasından veya yıldırım olayının ilk zaman adımında tespit edilememesinden kaynaklanmaktadır.

Çizelge 2.4. Model performans çizelgesi (Doostan ve Chowdhury 2020)


Modeller	Doğruluk	Hatalı Pozitif Sınıflandırma Oranı	Hata Tespit Oranı
GRNN	81,7%	11,3%	76,7%
RBF	80,0%	16,7%	76,7%
BP	75,0%	16,7%	66,7%

Yıldırımın kesin konumunun belirlenmesi, EİH'lerini koruma ve arızaları önleme açısından büyük önem taşımaktadır. Bu bağlamda, Karami vd. (2020) tarafından yapılan çalışma, yıldırım kaynaklı gerilim dalgalanmalarını kullanarak MÖ tabanlı bir yıldırım konumlandırma algoritması geliştirmiştir. Çalışmada, EİH'de halihazırda mevcut olan gerilim ölçüm sistemleri kullanılarak yıldırım düşmelerinin konumu tahmin edilmiştir. Yöntem, herhangi bir ek sensör gerektirmeden önceden kurulu EİH gerilim sensörlerinden alınan verileri analiz etmiştir. Simülasyon sonuçlarına göre, iki sensör arasındaki mesafe 2 km olduğunda yıldırımın konumunun 90 m'den daha az bir hata ile tahmin edilebildiği ortaya konmuştur. Şekil 2.5 yıldırım darbeleri sonucu iletim hattında farklı konumlarda oluşan gerilim dalga formlarını ve gerçek yıldırım konumları ile modelin tahmin ettiği konumların karşılaştırmasını sunmuştur. Şekil 2.5 (b)'de X eksen gerçek yıldırım konumunu, Y eksen ise modelin tahmin ettiği yıldırım konumu göstermektedir. Noktalar ideal olarak $y = x$ köşegeni üzerine yakınsa, model yüksek doğrulukla tahmin yapmış demektir. Şekil 2.6 modelin genellenebilirliğini ve performansını farklı koşullarda değerlendirmek için modelin yıldırım konumunu ne kadar doğru tahmin ettiğini göstermektedir. Şekil 2.6'daki dağılım, modelin aynı veri ortamında eğitim ve test edildiği bir senaryoya işaret eder. Genellikle bu durumda daha yüksek doğruluğun gözlenmesi gerekmektedir. Noktaların köşegenden daha uzak dağılması, modelin genelleme yeteneğini sınıyor olabileceğini gösterir. Şekil 2.6 (a) modelin daha tanıdık veriler üzerinde yüksek doğrulukla çalıştığını; (b) ise modelin farklı koşullarda, genelleme kabiliyetinin ne kadar başarılı olduğunu test etmiştir. Modelin performansı düşmüş olsa da model anlamlı tahminler yapabilmektedir. Çalışma, özellikle XGBoost algoritmasının kullanılmasıyla yüksek doğruluk oranlarına ulaşıldığını ve yıldırım kaynaklı gerilim dalgalanmalarının tahmin modellerine entegre edilmesinin konum belirleme doğruluğunu artırabileceğini ortaya koymaktadır. Referans çalışma olmasına rağmen iletim hattı sonsuz uzunlukta kabul edilmiş, zemin tamamen iletken

olarak varsayılmıştır. Modellenen iletim hattı kayıpsızdır. Koruma teli dikkate alınmamış ve gerçek dünya topografyası hesaba katılmamıştır.



Şekil 2.5. (a) sinyallerin zaman-mekân karakteristiği, **(b)** MÖ modelinin lokalizasyon başarısı (Karami vd. 2020).



Şekil 2.6. (a) yıldırım konumunu ne kadar doğru tahmin ettiği **(b)** yıldırım konumu tahminleri (Karami vd. 2020).

2.4. Literatür Tarama Özeti

Literatürde yıldırım tahmini için çeşitli modeller önerilse de EİH'deki arızaların hibrit MÖ ile tahmini henüz sistematik olarak ele alınmamıştır (Sarmiento vd. 2024). Bu çalışmada XGBoost ve ROA algoritmaları birleştirilerek, EİH'de yıldırım kaynaklı arızaların tahmini için hibrit bir model önerilmektedir. Mevcut çalışmaların yıldırım tahmini konusundaki doğruluk oranları ve hata metrikleri Tablo 2.5'te özetlenmiştir.

Çizelge 2.5. Karşılaştırma Tablosu

Çalışma	Algoritma	Doğruluk %	Hata Oranı	Veri Kaynağı
Shin vd. (2024)	ROA	84,25	Yüksek hatalı negatif oranı	Radar verisi
Zhou vd. (2024)	SCE+RCNN (DL)	92,5	Düşük hatalı pozitif oranı	Çok kaynaklı meteorolojik veri
Nicora vd. (2024)	YSA+PCA	78,3	Orta seviye hata oranı	LLS ve direk ölçümleri
Huo vd. (2024)	XGBoost	80,0	Hatalı pozitif sınıflandırma oranı düşürülmüş	Kuzey Çin yıldırım verisi
Bu Çalışma	Hibrit	94,1	Hatalı pozitif/negatif oranları iyileştirilmiş	MGM ve hat işletme Verileri

Hibrit modellerin, tekil MÖ algoritmalarına kıyasla genellikle daha yüksek doğruluk sunduğu görülmektedir. Literatürdeki yıldırım tahmin çalışmalarının büyük bir kısmı yalnızca meteorolojik verileri analiz etmeye odaklanırken, bu çalışma EİH'deki yıldırım elektromanyetik darbeleri kaynaklı arızaları doğrudan ele alarak, daha özgün ve mühendislik açısından uygulanabilir bir yaklaşım sunmaktadır. Bu çalışmada önerilen hibrit model, EİH'de yıldırım kaynaklı arızaların erken tahmin edilmesine olanak sağlayarak önleyici bakım stratejilerini güçlendirmeyi amaçlamaktadır. Modelin uygulanması, bakım maliyetlerinin azaltılmasına, kesinti sürelerinin en aza indirilmesine ve enerji şebekesinin genel güvenilirliğinin artırılmasına katkı sağlayacaktır. Ayrıca, önerilen yaklaşımın gelecekte daha geniş çaplı enerji altyapı sistemlerine entegre edilerek uzun vadeli sürdürülebilir çözümler sunması beklenmektedir.

3. MATERYAL VE METOT

Bu bölümde, elektromanyetik alan kavramı, iletim hattı modeli, yıldırımın oluşmasına dair teoriler ve konuya ilişkin standartlardan bahsedilmiştir. Ayrıca hibrit modelin geliştirilme süreci ve kullanılan yöntemler açıklanmıştır. Çalışmanın güvenilirliğini artırmak amacıyla çeşitli MÖ yöntemleri karşılaştırılmış ve modelin en iyi sonucu hiperparametre optimizasyonu ile belirlenmiştir.

3.1. Araştırma Tasarımı ve Kapsamı

Çalışma kapsamında kullanılan veri kaynakları, modelleme sürecinin neden bu şekilde yapılandırıldığı ve alternatif yöntemlerle kıyaslamalar açıklanmıştır.

3.1.1. Çalışmanın hipotezi ve amacı

Bu tezin temel hedefi, EİH’de yıldırım kaynaklı elektromanyetik darbelerin oluşturduğu arızaların yüksek doğrulukla tahmin edilmesini sağlayan hibrit bir model geliştirmektir. Modelin temel dayanağı, yıldırımın oluşturduğu elektromanyetik darbelerin iletim hatlarında arızaya yol açma potansiyelidir. Bu yıldırım elektromanyetik darbeleri sonucu hatlarda oluşan arızaların tahlili için MÖ kullanılmıştır. ROA ve XGBoost algoritmalarının birleşimiyle oluşturulan modelin, geleneksel yöntemlere kıyasla daha yüksek tahmin performansı sunacağı hipotezi ortaya konulmuştur. Bu çalışmada şu sorulara yanıt aranacaktır:

- Yıldırım düşmesi ile EİH arızaları arasında nasıl bir ilişki vardır?
- MÖ tabanlı bir hibrit model, arızaları öngörmede ne kadar başarılıdır?
- Akım şiddeti, topraklama direnci gibi hangi değişkenler arızaları tahmin etmekte daha etkilidir?
- Hibrit model, diğer MÖ yöntemlerine kıyasla daha yüksek doğruluk sağlayabilir mi?

Bu çalışmada ortaya konan hipotez, ROA ve XGBoost’un hibrit modeli, tek başına kullanılan geleneksel ve MÖ tabanlı modellerden daha yüksek doğruluk sağlayarak EİH’de kesintileri minimize edecektir.

3.1.2. Hibrit modelin tercih gerekçesi

Bu çalışmada, EİH’de yıldırım kaynaklı arızaları tahmin etmek için ROA ve XGBoost algoritmalarının hibrit modeli kullanılmıştır. Model seçiminde Çizelge 3.1’deki kriterler göz önüne alınmıştır:

Çizelge 3.1. Kullanılan Algoritmaların Karşılaştırması

Algoritma	Avantajları	Dezavantajları
KNN	Kolay uygulanabilir, az veri gerektirir	Büyük veri setlerinde yavaş
GA	Küresel optimizasyon yeteneği yüksek	Karmaşık, hiperparametre ayarı zor
YSA	Karmaşık ilişkileri iyi öğrenir	Büyük veri gerektirir, açıklanabilirlik düşük
DVM	Küçük veri setlerinde etkili	Büyük veri setlerinde yavaş, hiperparametre seçimi kritik
LR	Yorumlama kolay, düşük hesaplama maliyeti	Doğrusal olmayan ilişkileri öğrenemez
ROA	Aşırı öğrenmeye dayanıklı, özellik önem sıralaması yapabilir	Büyük veri setlerinde yavaş çalışabilir
XGBoost	Hızlı, hata oranı düşük, optimizasyon yeteneği yüksek	Hiperparametre ayarı karmaşık

Seçilen modelin üstünlükleri ise şu şekilde sıralanabilir: ROA değişkenler arasındaki ilişkileri analiz etme ve önemli değişkenleri belirleme konusunda güçlüdür (Breiman 2001). XGBoost hata oranlarını minimize eden gradyan artırma mekanizmasına sahiptir ve daha hassas tahminler üretir (Chen ve Guestrin 2016). Literatürdeki çalışmalar, ROA ve XGBoost birleşiminin dengesiz veri setlerinde daha başarılı olduğunu göstermektedir (Imani vd. 2025).

3.1.3. Yıldırımın Antalya bölgesindeki enerji iletim hatlarına etkileri

Yıldırım olaylarının şebeke üzerindeki etkisini daha iyi analiz edebilmek için bölgesel hava durumu değişkenleri de modele entegre edilmiştir. Hat işletme operatörü verilerine göre 2015-2022 yılları arasında 713 yıldırım kaynaklı arıza kaydedilmiştir. Bölgesel analizler, yıldırım şiddeti, topraklama direnci, işletme gerilimi gibi değişkenlerin etkisini belirlemek için uygun bir örneklem sunmaktadır. Çalışmada kullanılan yıldırım verileri aşağıdaki parametreleri içermektedir:

Çizelge 3.2. Eğitim ve test için kullanılan girdiler

Değişken	Açıklama	Birim
Enlem	Yıldırım çarpma noktası	Derece
Boylam	Yıldırım çarpma noktası	Derece
Akım Şiddeti	Yıldırımın büyüklüğü	kA
Hava Sıcaklığı	Çarpma anındaki sıcaklık	°C
Nem	Çarpma anındaki nem oranı	%
Basınç	Çarpma anındaki atmosfer basıncı	hPa
Direnç	Direğin gövde direnci ve bulunduğu noktadaki topraklama direnci	Ω
İzolatör Boyu	Kullanılan izolatörün izole kısmının boyu	mm
Hat Gerilimi	Yıldırımın düştüğü hattın fazlar arası işletme gerilimi	kV
Kule Tipi	Tek veya çift kule ya da koruma	-

3.2. Elektromanyetik Alan Kavramı

1865 yılında James Maxwell'in elektrik ve manyetizmayı birleştirmesiyle Maxwell denklemleri olarak bilinen ve Heaviside ile tekrar yazılan denklemler karşımıza çıkmaktadır. Güncel Maxwell denklemlerinin diferansiyel hali altta verilmektedir.

$$\nabla \times \mathbf{E} = -\frac{\partial \mathbf{B}}{\partial t} = \mathbf{J}_m - \mu \frac{\partial \mathbf{H}}{\partial t} \quad (3.1)$$

$$\nabla \times \mathbf{H} = -\frac{\partial \mathbf{D}}{\partial t} = \mathbf{J}_e - \varepsilon \frac{\partial \mathbf{E}}{\partial t} \quad (3.2)$$

$$\nabla \cdot \varepsilon \mathbf{E} = \nabla \cdot \mathbf{D} = \rho_v \quad (3.3)$$

$$\nabla \cdot \mu \mathbf{H} = \nabla \cdot \mathbf{B} = 0 \quad (3.4)$$

Her biri birer uzay – zamanda tanımlı olmak üzere $\mathbf{E}, \mathbf{B}, \mathbf{H}, \mathbf{D}, \mathbf{J}_e, \mathbf{J}_m$ gerçek fonksiyon olmak üzere $\mathbf{E}(x, y, z: t) (V/m)$ elektrik alan vektörünü, $\mathbf{H} (A/m)$ manyetik alan vektörünü, $\mathbf{B} (wb/m^2)$ manyetik akı yoğunluğu vektörünü, $\mathbf{D} (C/m^2)$ elektrik akı yoğunluğu vektörü, $\mathbf{J}_m (V/m^2)$ manyetik gerilim yoğunluğu vektörünü, $\mathbf{J}_e (A/m^2)$ elektrik akımı yoğunluğu vektörünü temsil eder. Bunların yanı sıra $\varepsilon (F/m)$ elektriksel geçirgenlik, $\mu (H/m)$ Manyetik geçirgenlik, $v (C/m^3)$ birim hacim başına yük yoğunluğudur.

Ohm yasası olarak da bilinen elektrik akımının elektrik alanla doğru orantılı olması $\mathbf{J}_e = \sigma_e \cdot \mathbf{E}$ 'dir (Özen 2017). $\sigma_e (S/m)$ Elektrik iletkenliği olup manyetik alan için de aynı mantık geçerlidir. Manyetik gerilim yoğunluğu manyetik alanla doğru orantılıdır. $\mathbf{J}_m = \sigma_m \cdot \mathbf{H}$ olup, $\sigma_m (\Omega/m)$ manyetik dirençtir (Özen ve Helhel 2022). Yukarıda paylaşılan Maxwell denklemleri kullanılarak uzayda herhangi bir noktada istenen alan bulunabilir. Eşitlik 3.1 ve 3.2'nin elektrik manyetik alan vektörlerinin kartezyen koordinat açılımı sonucu altta verilen 2 denklem elde edilir.

$$-\frac{\partial E_y}{\partial z} = -\mu \frac{\partial H_x}{\partial t} \quad (3.5)$$

$$-\frac{\partial H_x}{\partial z} = J_{ey} + \varepsilon \frac{\partial E_y}{\partial t} \quad (3.6)$$

$$-\frac{\partial E_x}{\partial z} = -\mu \frac{\partial H_y}{\partial t} \quad (3.7)$$

$$-\frac{\partial H_y}{\partial z} = J_{ex} + \varepsilon \frac{\partial E_x}{\partial t} \quad (3.8)$$

$$-\frac{\partial J_y}{\partial z} = -\mu\sigma_e \frac{\partial H_x}{\partial t} \quad (3.9)$$

$$-\frac{\partial H_x}{\partial z} = J_{ey} + \frac{\varepsilon}{\sigma_e} \frac{\partial J_y}{\partial t} \quad (3.10)$$

$$-\frac{\partial J_x}{\partial z} = -\mu\sigma_e \frac{\partial H_y}{\partial t} \quad (3.11)$$

$$-\frac{\partial H_y}{\partial z} = J_{ex} + \frac{\varepsilon}{\sigma_e} \frac{\partial J_x}{\partial t} \quad (3.12)$$

Denklem 3.3 ile 3.4 ve denklem 3.5 ile de 3.6 birleştirildiğinde;

$$\frac{\partial^2 \mathbf{E}_{x,y}}{\partial z^2} = \mu\varepsilon \frac{\partial^2 \mathbf{J}_{x,y}}{\partial t^2} + \mu\sigma_e \frac{\partial \mathbf{J}_{x,y}}{\partial t} \quad (3.13)$$

$$\frac{\partial^2 \mathbf{E}_{x,y}}{\partial z^2} = \mu\varepsilon \frac{\partial^2 \mathbf{J}_{x,y}}{\partial t^2} + \mu\sigma_e \frac{\partial \mathbf{E}_{x,y}}{\partial t} \quad (3.14)$$


Burada denklemin sağındaki ilk kısım yayılım ikinci kısım difüzyondur.

$$\frac{\partial^2 \mathbf{J}}{\partial z^2} = \mu\varepsilon \frac{\partial^2 \mathbf{J}}{\partial t^2} \quad (3.15)$$

Elde edilen dalga denklemi ile kayıplı ve kayıpsız iletim hattı modelleri tanımlanacak olup bu modellerle tanımlanan iletim hattına düşen yıldıırımın matematik modeline geçiş yapılacaktır.

$$\Delta z \frac{\partial v}{\partial z} = -L \frac{\partial i}{\partial t} - iR \quad (3.16)$$

$$\Delta z \frac{\partial i}{\partial z} = -C \frac{\partial v}{\partial t} - Gv \quad (3.17)$$



Şekil 3.1. Kayıplı iletim hattı genel devre gösterimi.

$$\frac{\partial^2 v}{\partial z^2} = \frac{G \cdot R}{(\Delta z)^2} v + \frac{1}{(\Delta z)^2} (G \cdot L + R \cdot C) \frac{\partial v}{\partial t} + \frac{L \cdot C}{(\Delta z)^2} \cdot \frac{\partial^2 v}{\partial t^2} \quad (3.18)$$

$$\frac{\partial^2 i}{\partial z^2} = \frac{G \cdot R}{(\Delta z)^2} i + \frac{1}{(\Delta z)^2} (G \cdot L + R \cdot C) \frac{\partial i}{\partial t} + \frac{L \cdot C}{(\Delta z)^2} \cdot \frac{\partial^2 i}{\partial t^2} \quad (3.19)$$

Admitans 0 olduğunda denklem 3.20 elde edilir;

$$\frac{\partial^2 v}{\partial z^2} = \frac{1}{(\Delta z)^2} R \cdot C \frac{\partial v}{\partial t} + \frac{L \cdot C}{(\Delta z)^2} \cdot \frac{\partial^2 v}{\partial t^2} \quad (3.20)$$

Bu klasik özet kublaj modelinin temelini oluşturur. Dalganın yayılma hızı ise:

$$u = \frac{1}{\sqrt{\epsilon \mu}} \quad (3.21)$$

$$u = \frac{1}{\sqrt{\frac{C}{\Delta z} \cdot \frac{L}{\Delta z}}} = \sqrt{L \cdot C} \quad (3.22)$$

İletim hattı karakteristik empedansı ise:

$$Z_c = \sqrt{\frac{L}{C}} \quad (3.23)$$

3.3. Yıldırım Teorisi


Yıldırım darbesi boşalma yolu olarak bulut içi deşarj, buluttan buluta atlama ve buluttan yere üç ana tipe ayrılır. Bu çalışmada referans noktası ise buluttan yere olan yıldırım boşalmalarıdır (Thanasaksiri 2004; IEEE 2010). Yıldırımın oluşumuna dair pek çok teori bulunmaktadır. Ortaya konulan teorilerin ortak yanları atmosferde bulunan iyon veya yüklerin sıcaklık değişimiyle toplu halde hareketi olarak özetlenebilir.

3.3.1. Yıldırım oluşum süreci

Bulut içindeki negatif ve pozitif elektriksel yük merkezleri arasında yaklaşık 2–3 km'lik bir mesafe bulunmaktadır. Negatif yüklerin alt seviyelerde, pozitif yüklerin ise üst seviyelerde konumlandığı ifade edilmektedir (Wagner vd. 1942). Yıldırımın meydana gelmesinde temel rol oynayan negatif yük merkezleri ile yer yüzeyi arasındaki mesafe 500 metre ile 10 kilometre arasında değişkenlik gösterebilmektedir. Negatif yük merkezinin çevresindeki elektrik alan şiddeti yaklaşık 10 kV/cm düzeyine ulaştığında, iyonizasyon sonucu oluşan kanal, bulut ile yer arasında bir iletken yol teşkil edecek şekilde gelişmeye başlar. Bu iyonize kanalda elektronlar, ışık hızının yaklaşık %10'u oranında bir hızla hareket eder. (Wagner ve McCann, 1942).


Şekil 3.2’den de gözlemlenebileceği üzere, elektriksel boşalma dalgası her adımda ortalama 10 ila 200 metre arasında bir mesafe kat ederek aşağı yönlü bir hareket sergilemektedir. Yaklaşık 2–3 μs ’lık bir süre boyunca ilerleyen dalga, kısa bir duraklamanın ardından yeniden harekete geçer. Bu kesintili ve kademeli ilerleme biçimi nedeniyle söz konusu oluşum *adım lider* olarak adlandırılmaktadır. Adım lider ile yer yüzeyi arasındaki mesafe yaklaşık 15 ila 50 metreye kadar azaldığında, bu elektriksel alan etkisine karşılık olarak yerden yukarıya, bulut yönüne doğru pozitif yüklü bir kanal oluşmaya başlar (Yoldaş, 2019).

Jiang vd. (2015) yaptıkları çalışmada Şekil 3.2’den de görüleceği üzere oluşan yıldırım adım liderlerinin ilerleyişi gösterilmektedir. Kırmızı çizgiler yer seviyesini, sarı çizgiler lider uçlarını ve mavi çizgi ise adım liderin ilk olarak yeterli parlaklıkla görüntülediği ve geri dönüş darbesinden 2.1 ms önce ulaştığı irtifayı göstermektedir.



Şekil 3.2. (a-c) Adım lidere ait ilk geri dönüş darbesi, **(d-f)** 2.liderin 4.geri dönüş darbesi, **(g-i)** ardıl liderin 5.geri dönüş darbesi (Jiang vd. 2015).

Adım lider ile yeryüzünden yukarıya doğru pozitif kanal birleşir. Bu durum Şekil 3.3'te sunulmaktadır. Rakov ve Uman (2007) çalışmasına göre ortalama 20 kA civarındaki akım, adım liderin meydana getirdiği iyonize yıldırım kanalı boyunca yer yüzeyinden bulut istikametinde hareket eder. Adım liderin ana kanal ve dalları boyunca biriken negatif elektron yükü, yerden yukarı doğru ilerleyen pozitif kanal ile karşılaştığında, bu yük akışı bir akım ile nötralize edilir. Bu hızlı ve yoğun elektriksel akım geri dönüş darbesi veya geri dönüş darbe akımı olarak adlandırılmaktadır. İlk deşarjdan takribi olarak 40 μ s sonra, bulut içerisinde yer alan ikinci bir yük merkezi, daha önce oluşmuş olan iletken kanalı takip ederek boşalım gerçekleştirir. Bu ikincil deşarj, adım adım ilerleyen ilk deşarjın aksine, ışık hızına yakın bir hızda ve yaklaşık onun on katı daha kısa sürede meydana gelir. Bu süreçte de yine geri dönüş darbe akımı oluşur. (Wagner ve McCain 1942).



Şekil 3.3. Adım lider ile yıldırımın oluşumu (Yoldaş, 2019).

3.3.2. Yıldırım matematik modelleri

Yıldırımın oluşturduğu elektromanyetik alanlar, geri dönüş darbe akım modellerinde bir fonksiyonel bağıntı aracılığıyla tanımlanır. Bu bağlamda, kanal boyunca rastgele z yüksekliğinde ve t anındaki akımı temsil eden $I(z, t)$ kanal başındaki akım ile matematiksel olarak ilişkilendirilir. Bu fonksiyon, kanal üzerindeki akım dağılımını

zamana ve yüksekliğe bağlı olarak tanımlayan temel bir ifadedir. Bu bağlamda kullanılan temel denklem 3.24'te verilmiş olup:

$$I(z, t) = I_0(t - z/v) \quad (3.24)$$

Burada $I_0(t)$ başlangıç akımını, v ise kanal boyunca akımın yayılma hızını tanımlar. IEC62305'e göre ise yıldırım akımı:

$$i(t) = I_p \cdot \left(\frac{t}{T_1}\right)^k \cdot e^{-k \cdot \frac{t}{T_2}} \quad (3.25)$$

Burada:

$i(t)$: zamanla değişen akımı (kA)

I_p : Tepe akımı (kA)

T_1 : Yükselme süresi (s)

T_2 : Bozulma süresi (s)


k : Dalga şekli parametresi ($k = \frac{T_2}{T_1} \cdot \ln \left(\frac{T_2}{T_1}\right)$)

Literatürde 2 tip dalga mevcuttur. Bunlar 8/20µs ve 10/350µs'dir. Bunlar için kullanılan referans IEC 62305'tir. IEC 62305'te yıldırıma karşı koruma için kullanılan standartlar paylaşılmaktadır. IEC 62305-4 özellikle yıldırım akımı dalgalarının sistemlere etkilerini inceler. Genellikle 8/20 µs şebeke kökenli darbelere karşı koruma için kullanılırken 10/350µs yıldırım darbe korumasına karşı kullanılmaktadır. Genellikle SPD olarak geçen parafudur vb. cihazların standartlarında değerlendirilir.

Yıldırım akımının daha doğru modellenmesi için literatürde sıklıkla Heidler Fonksiyonu kullanılır. Heidler fonksiyonu:

$$i(t) = \frac{I_p \left(\frac{t}{T_1}\right)^n}{1 + \left(\frac{t}{T_1}\right)^n} \cdot e^{-t/T_2} \quad (3.26)$$

Burada IEC62305'ten farklı olarak " n " Biçimlendirici sabit (dalga formunun sivriliğini belirler). Heidler fonksiyonu özellikle elektromanyetik alan simülasyonlarında tercih edilir, çünkü hem yükselme hem de düşüş bölgesini daha esnek biçimde kontrol etmeye olanak tanır. Bu duruma örnek Şekil 3.4'te paylaşılmıştır.



Şekil 3.4. 10/350µs Yıldırım darbesinin Heidler fonksiyonu ile gerçekçi modellemesi.

Yukarıda paylaşılan formüller Denklem 3.27’de verilmektedir.

$$i(z', t) = u\left(t - \frac{z'}{v_f}\right) \cdot P(z') \cdot I\left(0, t - \frac{z'}{v}\right) \quad (3.27)$$

Burada u : heaviside fonksiyonu olup,

$$t \geq \frac{z'}{v_f} \text{ için } u = 1 \text{ ve } t < z'/v_f \text{ için } u = 0 \quad (3.28)$$

Rakov ve Dulzon (1991) tarafından tanımlanan $P(z')$ fonksiyonu yıldırım kanalında akımın yükseklikle birlikte zayıflamasını ifade eden ve kanal yüksekliği H ile ilişkili bir bağıntıdır. Bu fonksiyon, geri dönüş darbe akımı modellerinde, akımın kanalda yukarıya doğru ilerlerken maruz kaldığı zayıflamayı matematiksel olarak temsil eder. Burada z' kanal üzerindeki herhangi bir noktada tanımlanan yerel yükseklik değişkenidir.

Rakov ve Dulzon’un ortaya koyduğu $P(z')$ zayıflama fonksiyonu ise:


$$P(z') = e^{-\lambda z'} \quad (3.29)$$

Burada $P(z')$ zayıflama fonksiyonu, λ akımın zayıflama sabitini (m^{-1}), z' ise kanal üzerindeki lokal yüksekliktir. Akımın yukarıya doğru yayılım hızı, V_f aynı zamanda geri dönüş darbe akımının iletim hızını temsil eder. İlk deşarj sırasında bu hız ışık hızının yaklaşık %10’u kadarken, daha sonraki darbelerde bu hız yaklaşık ışık hızına eşittir. Akım dalga yayılım hızı V ise, toprakla kanal arasında meydana gelen elektriksel iletimin hızıdır. Toprak, yıldırım kanalına akım sağlayan sabit bir jeneratör gibi davrandığı için bu hız sabit kabul edilir (Rakov ve Dulzon, 1991).

Rakov ve Dulzon (1991) tarafından tanımlanan modele göre, akımın iletim hattı boyunca azalması belirli bir bağıntı ile ifade edilmektedir. Yukarıya doğru ilerleyen ön darbe hızı V_f aynı zamanda geri dönüş akımının yayılma hızını da temsil eder. Bu hız, ilk darbe için ışık hızının yaklaşık onda biri iken, ardışık darbelerde ışık hızına eşit kabul edilir. Buradaki V akım dalgasının yayılma hızını gösterirken; toprak, sabit akım sağlayan bir jeneratör gibi davranır ve dolayısıyla bu kaynak hız açısından sabit kabul edilir. H Yıldırım kanalının toplam yüksekliğini, c ışık hızını, λ ise akımın zayıflama sabitini temsil eder. z' , z konumundaki kanal segmentinde tanımlanan yerel bir yükseklik parametresidir.


$$i(z', t) = \begin{cases} i(0, t) & z' \leq vt \\ 0 & z' > vt \end{cases} \quad (3.30)$$

Bu model Şekil 3.5'te gösterilmektedir. Yıldırım darbe akımı için Bruce-Golde modeli fiziki olarak önerilmez. Bu olgu, Bruce-Golde modelinde yıldırım darbe akımının öncül bileşeninde ortaya çıkan süreksizlikten kaynaklanmaktadır. Buradaki “öncül süreksizlik”, Şekil 3.6'da gösterilen dalga yapısının başlangıç anının net biçimde tanımlanamamasıyla ilgilidir. İncelenen darbe akımının belirgin bir başlangıç noktasına sahip olmaması, modelin bu bölgesinde zamanla ilgili bir belirsizlik doğurur. Bu nedenle, Şekil 3.5 ile Şekil 3.6 arasındaki temel fark da bu süreksizlikten kaynaklanan yapısal farklılığa dayanmaktadır. Şekil 3.5'te akımın yükselmeye başladığı an net iken, Şekil 3.6'da bu başlangıç noktası kesindir denilemez.



Şekil 3.5. Bruce-Golde modeline göre geri dönüş darbe akım modeli (Djalel vd. 2007).

Şekil 3.6'da, öncül akım bileşeni nedeniyle ani değişimlere bağlı süreksizlikler yer alırken, Şekil 3.5'te dalga formu süreklidir. Şekil 3.5, analitik modellemeye daha elverişli bir yapı sunarken, Şekil 3.6'daki yapı gerçek yıldırım olaylarında karşılaşılan karmaşık davranışı daha gerçekçi şekilde temsil eder.



Şekil 3.6. Bruce- Golde modelinde süreksiz geri dönüş darbe akımı (Djalel vd. 2007).

3.3.3. İletim hattı yıldırım modeli

Bu modele göre, toprakta oluşan darbe akımının dalga formu, yıldırım kanalının tabanından zirvesine kadar herhangi bir bozulma ya da enerji kaybı olmaksızın sabit bir hızla iletilir. Modelde, yükün kanal boyunca alt uçtan üst uca taşınırken hiçbir net yük kaybı yaşanmadığı varsayılmaktadır. Şekil 3.5'te bu modele ilişkin şematik gösterim sunulmuştur.

$$i(z', t) = \begin{cases} i\left(0, t - \frac{z'}{v}\right) & z' \leq vt \\ 0 & z' > vt \end{cases} \quad (3.31)$$

3.3.4. Master, Uman Lin ve Standler modeli

Master, Uman, Lin ve Standler tarafından geliştirilen model, ilk olarak Lin vd. (1980) tarafından önerilmiş; ardından Master vd. (1981) tarafından yenilenmiştir. Bu modele göre, yıldırımın geri dönüş darbe akımı süreci üç farklı akım bileşeniyle karakterize edilir. Bu bileşenlerden ilki, sabit bir akım kaynağı tarafından yıldırım bulutundan sürekli olarak beslendiği varsayılan, tekdüze (uniform) bir akım bileşeni olan (I_u) Bu bileşen, belirli bir H yüksekliğinde kapalı ve sabit bir elektrik alan oluşturur. Modelde, söz konusu elektrik alan ve akım dağılımı, yer yüzeyinden itibaren $r = 1\text{ km}$ ile 10 km arasında uzanan bir yarıçap boyunca denklem 3.22'de tanımlanmıştır (Lin vd. 1980).

$$I_u = \frac{2\pi\epsilon_0(H^2 + R^2)^{\frac{3}{2}} dE_{\text{kapalı}}(r, t)}{H} \quad (3.32)$$

Modelin ikinci bileşeni, arıza darbesi akımının yıldırım kanalı boyunca yukarı yayılan dalga ile öncü geri dönüş darbesi sırasında oluşan elektriksel süreksizlik arasındaki etkileşimi temsil eder. Bu bileşen, yukarı yönlü yayılım sırasında ortaya çıkan elektromanyetik etkilerle, geri dönüş darbesinin başlangıcında gözlenen elektriksel kesilmenin birleşimini dikkate alır. Rusck (1997) çalışmasında, bu etkileşimin yıldırım darbesinin dalga formunu ve yayılma dinamiklerini önemli ölçüde etkilediğini belirtmiştir.

$$i_p(z', t) = \begin{cases} i_p\left(0, t - \frac{z'}{v}\right) \exp\left(-\frac{z'}{\lambda_p}\right) & z' \leq vt \\ 0 & z' > vt \end{cases} \quad (3.33)$$

Burada λ_p arıza darbesi akımının bozulma sabitidir.

Üçüncüsü ise ($\dot{I}_c$) korona akımıdır. Kanal etrafındaki korona kılıfında yer alan yüklerin radyal karşıt yönlü hareketleri temel alınarak, yıldırım kanalındaki akım bileşeni modellenir. Bu bağlamda, korona etkisiyle oluşan akım, kanal boyunca belirli bir z' yüksekliğinde ortaya çıkmakta ve hesaplamaya dahil edilmektedir. Burada:

$$di_{cs}(z'', t) = \begin{cases} 0, & t \leq t' \\ I_0 \exp\left(\frac{z''}{\lambda_c}\right) \times \{\exp[-\alpha(t - t')] - \exp[-\beta(t - t')]\} dz, & t > t' \end{cases} \quad (3.34)$$

Burada (i_0), α , β (i_0) varsayılan tekil korona kaynağının çift üstel şeklini belirleyen değişkenlerdir. λ_c Zayıflama sabiti, $t' = z''/v + t_{on}$ ve t_{on} arıza akımı 0'dan en yüksek değerine kadar geçen zamandır. Bu modelin eksikliği kanal baz akımının bulunmayışı ve matematiksel karmaşıdır.

3.3.5. Gezen akım kaynağı modeli

Gezgin akım kaynağı modelinde, akım kaynağının topraktan bulut yönüne doğru v hızıyla ve z' yüksekliğinden itibaren yayıldığı kabul edilmektedir. Bu modelde akımın yukarıya doğru yayılım hızı, ışık hızı c olarak varsayılır. Heidler (1985) tarafından tanımlanan bu modele göre, gezgin akım kaynağının oluşturduğu darbe akımı aşağıdaki şekilde ifade edilmektedir:

$$i(t) = \frac{I_m \left(\frac{t}{\tau_1}\right)^n}{1 + \left(\frac{t}{\tau_1}\right)^n} \cdot e^{-\frac{t}{\tau_2}} \quad (3.35)$$

$$i(z', t) = \begin{cases} i(0, t + z'/c, & z' \leq vt \\ 0, & z' > vt \end{cases} \quad (3.36)$$

Toprağa akan akım sonsuz kabul edilerek, hareket eden akım kaynağı modelinden Bruce-Golde modeli çıkarılabilir.

3.3.6. Geliştirilmiş iletim hattı modeli

Geliştirilmiş iletim hattı modelinde yıldırım akımı (Nucci vd. 1988);

$$\frac{\partial V(z, t)}{\partial z} = -L \frac{\partial I(z, t)}{\partial t} - RI(z, t) \quad (3.37)$$

$$\frac{\partial I(z, t)}{\partial z} = -C \frac{\partial V(z, t)}{\partial t} - GV(z, t) \quad (3.38)$$

Burada:

$V(z, t)$: zaman ve konuma bağlı gerilim

$I(z, t)$: zaman ve konuma bağlı akım

L, C : hattın birim uzunluktaki endüktans ve kapasitansı

R : Direnç

G : İletkenlik (Toprak sızıntı etkisi)

$$i(z', t) = \begin{cases} i\left(0, t - \frac{z'}{v}\right) \exp\left(-\frac{z'}{\lambda}\right), & z' \leq vt \\ 0, & z' > vt \end{cases} \quad (3.39)$$

Burada v geri dönüş darbe hızı ve λ bozulma sabitidir.

3.3.7. Üssel olarak zayıflayan iletim hattı modeli

Bu model, korona akımının üssel zayıflamasıyla yukarı yönlü hareket eden akımın geliştirilmiş iletim hattı modeli gibi ifade edilirse (Rachidi ve Nucci, 1990):

$$i_c(z', t) = \begin{cases} i_c\left(t - \frac{z'}{v}\right) \exp(-z'/\lambda_c), & z' \leq vt \\ 0, & z' > vt \end{cases} \quad (3.40)$$

Burada λ_c bozulma sabitidir.

3.3.8. Doğrusal akım zayıflaması ile geliştirilmiş iletim hattı

Bu model, iletim hattı yaklaşımının bir varyasyonu olarak geliştirilmiş olup, akımın yıldırım kanalı boyunca doğrusal şekilde zayıfladığı varsayımına dayanmaktadır (Rakov ve Dulzon, 1987). Bu bağlamda, akım yoğunluğu kanal boyunca denklem 3.41'de gösterildiği gibi belirli bir doğrusal oranda azalmaktadır.

$$J(z) = J_0 \left(1 - \frac{z}{H}\right) \quad (3.41)$$

Burada:

$J(z)$: z yüksekliğindeki akım yoğunluğu

J_0 : Kanalın alt ucundaki ($z = 0$) maksimum akım yoğunluğu,

H : Yıldırım kanalının toplam yüksekliği,

z : Kanal boyunca yukarı yönlü mesafe.

Bu ifadeye göre, akım yoğunluğu yıldırım kanalının başlangıcında maksimum değere sahipken, kanalın üst ucunda sıfıra yaklaşmaktadır. Bu doğrusal zayıflama modeli, yıldırım kanalında yük ve enerji dağılımının daha gerçekçi biçimde temsil edilmesine olanak tanır.

3.3.9. Diendorfer – Uman modeli

Diendorfer ve Uman modeli, ana yıldırım deşarjının iki bağımsız fiziksel süreçten oluştuğunu varsaymaktadır (Diendorfer ve Uman, 1990). Bu süreçlerden ilki, oldukça kısa bir zaman aralığında—yaklaşık 1 μ s veya daha kısa sürede—yoğun şekilde iyonize olmuş ana kanal çekirdeğinin ani deşarjını ifade eder. İkinci süreç ise, korona sabiti ile ilişkili olarak ms mertebesinde daha büyük bir zaman sabitiyle gerçekleşen daha yavaş bir deşarj mekanizmasıdır. Bu nedenle, yer yüzeyinde ölçülen toplam akım; yüksek hızlı çekirdek deşarjı (kesilme akımı) ile daha yavaş gelişen korona akımının süperpozisyonu yani toplamı olarak değerlendirilmektedir.

$$i(z', t) = i_{bd}(0, t_m) - i_{bd}(0, z'/v^*) \exp(-t_e/\pi_{bd}) + i_c(0, t_m) - i_c(0, t + z'/v^*) \exp(-t_e/\tau_c) \quad (3.42)$$

Burada:

$$t_m = t + z'/c, v^* = 1/(1/v + 1/c)$$

$$t_e = (t - z'/v)$$

$$i(0, t) = i_{bd}(0, t) + i_c(0, t)$$

3.3.10. Mühendislik modellerinin genellenmesi

Rakov tarafından önerilen genelleştirilmiş akım denklemi, yıldırım darbe akımının hem zamana hem de yüksekliğe bağlı olarak modellenmesine olanak tanır (Nucci, 2000; Djalel et al., 2007). Bu denklem 3.43'te şu şekilde ifade edilmektedir:

$$i(z', t) = g\left(\frac{t - z'}{v^*}\right) \cdot P(z') \cdot i\left(0, \frac{t - z'}{v^*}\right) \quad (3.43)$$


Burada $i(z', t)$ z' yüksekliğinde ve t anındaki akımı, $i(0, \cdot)$ kanalın başlangıcında $z=0$ tanımlanan akım bileşeni, v^* akım dalgasının yayılma hızını, $P(z')$ Yükseklikle değişen akım zayıflama faktörünü, g Heaviside birim adım fonksiyonu; yalnızca $t \geq z'/v$ koşulu sağlandığında etkindir. Bu model hem fiziksel hem de matematiksel olarak daha uygun bir yaklaşım sunar ve özellikle elektromanyetik alan hesaplamalarında birim adım fonksiyonunun kullanımı sayesinde doğruluk oranı artırılabilir. Ancak, yıldırımın oluşumunun çok erken evrelerinde meydana gelen hızlı fiziksel süreçler bu model tarafından yeterli düzeyde temsil edilememektedir. Çünkü bu ve benzeri modeller, yıldırım deşarjının ilk fazını (öncü kanal oluşumu, iyonizasyon başlangıcı vb.) doğrudan dikkate almaz.

Bu sınırlılıklar nedeniyle, yıldırımın yüksek enerjili darbe evresine ilişkin kanal davranışlarını daha doğru tanımlamak adına daha fazla deneysel veriye ihtiyaç duyulmaktadır (Djalel vd. 2007).

3.4. Kublaj Modeli

Yıldırım darbe akımı, çevresinde güçlü elektromanyetik alanlar oluşturarak, özellikle elektrik iletim ve dağıtım sistemlerinde ciddi arızalara ve ekipman hasarlarına yol açabilir (Montano 2005). Bu elektromanyetik etkilerin iletim hatları üzerindeki sonuçlarını değerlendirebilmek için, yıldırım darbesi ile iletim hattı arasındaki etkileşim çeşitli modeller aracılığıyla incelenmektedir. Bu kapsamda, iletkenlerin mükemmel iletkenlik özelliği taşıdığı ve doğrudan toprağa bağlı olduğu varsayımı altında oluşturulan ideal devre modeli Şekil 3.7'de gösterilmektedir. Bu devre yapısı, dolaylı yıldırım darbesinin havai hatlar üzerinde indüklediği aşırı gerilimleri hesaplamak amacıyla geliştirilmiştir.

Bu modelde, kayıpsız bir tek iletkenli havai hat; x eksenine paralel, xy -düzleminde konumlanan ve her iki ucu R_0 ve R_L ile sonlanan bir yapı olarak tanımlanır (Nucci, 1995). Bu yapı, yıldırım kaynaklı elektromanyetik girişimlerin havai hatlarda neden olduğu gerilim yükselmelerini incelemek için oldukça uygun bir temsildir. İlgili bağlantı modeli, genellikle kublaj (coupling) modeli olarak adlandırılmakta olup, bu modele dayalı çeşitli varyasyonlar ve iyileştirme çalışmaları sonraki bölümlerde ayrıntılı olarak ele alınmıştır.



Şekil 3.7. İdeal devre modeli.

3.4.1. Rusck modeli

Rusck modeli ile ilişkili olarak iletim hatlarına uygulanan teorik çerçevede, iletim hattı iletkeninin yüzeyinde oluşan toplam elektrik alan, skaler ve vektörel potansiyellerin türevleri cinsinden ifade edilir. Bu yaklaşıma göre, iletken yüzeyindeki elektrik alan; elektrostatik yani skaler potansiyel ve elektromanyetik yani vektörel potansiyel bileşenlerin zaman ve konumsal türevlerinin süperpozisyonu ile tanımlanır. Böylece, yıldırım kaynaklı darbe akımı nedeniyle oluşan elektromanyetik alanların, iletim hattı üzerindeki etkileri teorik olarak modellenebilir. Rusck modelinde:

$$\mathbf{E} = -\nabla\phi - \frac{\partial \mathbf{A}}{\partial t} \quad (3.44)$$

Burada:

$\vec{E}$: Toplam elektrik alan(V/m)

ϕ : Skaler potansiyel (V)

$\vec{A}$: Vektör potansiyel (Wb/m)

∇ : Konumsal gradyan operatör

$$\frac{\partial \phi(x, t)}{\partial x} + L' \frac{\partial i(x, t)}{\partial t} = 0 \quad (3.45)$$

$$\frac{\partial i(x, t)}{\partial x} + C' \frac{\partial \phi(x, t)}{\partial t} = C' \cdot \frac{\partial \phi^i(x, t)}{\partial t} \quad (3.46)$$

ϕ Hattta indüklenen toplam skaler potansiyeldir. (ϕ^i) Yük alanı, $i(x, t)$ hat toplam akımı ve L', C' birim uzunluk başına karşılık gelen hat endüktansı ve hat kapasitansıdır. Hat üzerindeki tahrik edilen gerilim toplamı $u(x, t)$;

$$u(x, t) = \phi(x, t) + \int_0^h \frac{\partial A_z^i(x, z, t)}{\partial t} \cdot dz \quad (3.47)$$

Burada iletkenin yerden yüksekliği h , yük vektör potansiyelinin dikey bileşeni A_z^i 'dir. Denklemler için sınır şartları:

$$\phi(0, t) = -R_0 \cdot i(0, t) - \int_0^h \frac{\partial A_z^i(0, z, t)}{\partial t} \cdot dz \quad (3.48)$$

$$\phi(L, t) = -R_L \cdot i(L, t) - \int_0^L \frac{\partial A_z^i(l, z, t)}{\partial t} \cdot dz \quad (3.49)$$


Yukarıda belirtilen kublaj modeli kapsamında elde edilen iletim hattı denklemleri, zorlamalı yani kaynak uyartımlı fonksiyonlarının türetilmesine fırsat verir. Bu bağlamda, yük alanına karşılık gelen skaler potansiyel fonksiyonlar, vektör potansiyelin özellikle dikey bileşeniyle doğrudan ilişkilidir. Başka bir ifadeyle, iletim hattında meydana gelen gerilim; yük alanının oluşturduğu skaler potansiyelin, elektrik alan üzerindeki dikey bileşeni tarafından belirlenir (Cooray 1994).

Özellikle yıldırım darbesinin iletim hattına yakın bir noktaya düşmesi durumunda, hat üzerinde indüklenen tepe aşırı gerilimi, darbenin yeri ve genliğine bağlı olarak değişkenlik göstermektedir. Bu olasılıklı ve konuma bağlı ilişki, Rusck tarafından ilk kez teorik olarak ele alınmış; ardından Golde (1997) tarafından daha kapsamlı biçimde değerlendirilmiştir. Rusck'un yaptığı sadeleştirilmiş yaklaşım, darbenin hattın geometrisine göre konumuna ve akım genliğine bağlı olarak aşırı gerilimleri yaklaşık olarak tahmin etmeye yönelik olup denklem 3.50'de sunulmaktadır.

$$U_{max} = \frac{Z_0 I_0 h}{d} \left(1 + \frac{1}{\sqrt{2}} \frac{v}{c} \frac{1}{\sqrt{1 - \frac{1}{2} \left(\frac{v}{c} \right)^2}} \right) \quad (3.50)$$

Burada Z_0 karakteristik empedanstır. I_0 Yıldırım tepe akım değeri $(1/4\pi\sqrt{\mu_0\epsilon_0})$ ile hesaplanır. Yıldırım darbe noktası ile iletim hattı arasındaki en yakın mesafe d 'dir. Denklem 3.51 yıldırım aşırı gerilimin tepe değerini verir.

Rusck iletim hattı kublaj modeli Şekil 3.8'de gösterilmektedir.



Şekil 3.8. Rusck iletim hattı kublaj modeli.

Denklem 3.51'de Z_0 değerinin 30Ω ile değiştirilmesi ve Idone ve Orville (1982) çalışmasında belirttiği üzere doğal yıldırım hızı için ölçülen yıldırım dönüşü darbesinin de 0.29×10^8 m/s ile 2.4×10^8 m/s arasında değiştiği göz önüne alınırsa, dönüş darbe hızının ortalama 1.2×10^8 m/s olduğu varsayımıyla:

$$U_{\max} = 38.8 \frac{I_0 h}{d} [\text{kV}] \quad (3.51)$$

Bu modelin yıldırım geriliminin çıkış ve bozunma süreleri ile ilgili herhangi bir bilgi içermemesi büyük bir dezavantajdır (Montano, 2005).

3.4.2. Taylor modeli

Dağıtılmış akım ve gerilim kaynakları açısından Taylor vd. (1965) tarafından ortaya koyulan modeldir. Hat gerilim ve akımları EİH denklemleri açısından incelendiğinde:

$$\frac{\partial u(x, t)}{\partial x} + L' \frac{\partial i(x, t)}{\partial t} = - \frac{\partial}{\partial t} \int_0^h \mathbf{B}_y^i(x, z, t) dz \quad (3.52)$$


$$\frac{\partial i(x, t)}{\partial x} + C' \frac{\partial u(x, t)}{\partial t} = - C' \frac{\partial}{\partial t} \int_0^h E_z^i(x, z, t) dz \quad (3.53)$$

Sınır şartlar ise;

$$u(0, t) = -R_0 I(0) \quad (3.54)$$

$$u(L, t) = -R_L I(L) \quad (3.55)$$

Taylor modeli, yıldırım darbesini tek bir nokta etkisi yerine, hat boyunca yayılan bir etki olarak ele alması bakımından Rusck modeli gibi tek nokta modellerine göre daha gerçekçidir (Taylor 1965). Taylor modeline Paralel akım ve seri gerilim kaynağı bulunan eş iletim hattı modeli Şekil 3.9'da sunulmuştur.



Şekil 3.9. Eş iletim hattı modeli.

3.4.3. Agrawal modeli

Tam adıyla Agrawal, Price ve Gurbaxani Modeli olan bu modelde, iletim hattı üzerindeki elektromanyetik etkileşimleri tanımlamak amacıyla dağınık gerilim kavramı kullanılmıştır. Bu yaklaşımda, iletim hattı boyunca indüklenen gerilim, yalnızca tek bir

noktadaki potansiyel farkı ile değil; hat boyunca zamana ve konuma bağlı olarak değişen, sürekli bir dağılım şeklinde ifade edilir. Bu bağlamda, Maxwell denklemleri, Şekil 3.8'de gösterilen kapalı kontur yolu boyunca bütünleşme işlemine tabi tutulmuş ve sonuçta elde edilen ifadeler, doğrudan dağılık gerilim cinsinden formüle edilmiştir (Agrawal vd. 1980; Nucci 1995; Nucci vd. 1995). Bu yöntem, yıldırım kaynaklı elektromanyetik alanların iletim hatları üzerindeki etkilerinin daha hassas ve fiziksel olarak tutarlı biçimde modellenmesine olanak tanır.

$$\frac{\partial u^s(x, t)}{\partial x} + L' \frac{\partial i(x, t)}{\partial t} = \mathbf{E}_x^i(x, h, t) \quad (3.56)$$

$$\frac{\partial i(x, t)}{\partial x} + C' \frac{\partial u^s(x, t)}{\partial t} = 0 \quad (3.57)$$

$\mathbf{E}_x^i(x, h, t)$ x eksenini boyunca gelen elektrik alanının yatay bileşenidir. $u^s(x, t)$ Denklem 3.59'un tanımladığı dağılık gerilimdir.

$$u^s(x, t) = - \int_0^h \mathbf{E}_z^s(x, z, t) dz \quad (3.58)$$

$\mathbf{E}_z^s(x, z, t)$ Dağılmış elektrik alanının yatay bileşenidir. Toplam hat gerilimi $u(x, t)$ dağılmış gerilim olarak Denklem 3.59'da verilmiştir.

$$u(x, t) = u^s(x, t) + u^i(x, t) \quad (3.59)$$

Bu sebeple dağılık gerilimlerin toplamı, hat boyunca belirli bir noktada toplam gerilimdir. Denklem 3.57 ve Denklem 3.58'den gerilim ve tanımlanan gerilim Denklem 3.60'ta verilmiştir:

$$u^i(x, t) = - \int_0^h \mathbf{E}_i^z(x, z, t) dz \quad (3.60)$$


Burada h iletkenin yüksekliğidir. $\mathbf{E}_i^z(x, z, t)$ Yük dikey elektrik alanıdır. Dağılık gerilim sınır şartları:

$$u^s(0, t) = -R_o i(0, t) - u^i(0, t) \quad (3.61)$$

$$u^s(L, t) = -R_L i(L, t) - u^i(L, t) \quad (3.62)$$

Hat boyunca oluşan yatay yöndeki yük kaynaklı elektrik alanı $\mathbf{E}_x^i$ ile dikey yöndeki yük elektrik alanı $\mathbf{E}_z^i$, iletim hattı boyunca ve uç noktalarında dağılık gerilim kaynaklarının oluşmasına neden olur. Bu etkileşim, iletim hattının elektromanyetik alanlara karşı gösterdiği tepkilerin temelini oluşturur. Şekil 3.10'da sunulan Agrawal kuplaj modeli eşdeğer devre temsili çerçevesinde, bu gerilim etkileri dağıtılmış gerilim kaynakları olarak modellenmiştir. Hat boyunca sürekli şekilde dağılmış bu kaynaklara ek

olarak, iletim hattının uç noktalarında da iki adet ayrı gerilim kaynağı tanımlanmıştır. Söz konusu uç gerilim kaynakları, modelde yükseltici işlevi gören bileşenler olarak adlandırılmakta ve yıldırım kaynaklı elektromanyetik alanların uçlarda oluşturduğu aşırı gerilimlerin temsiline kullanılmaktadır.



Şekil 3.10. Agrawal kuplaj devresi modeli.

3.4.4. Rachidi modeli

Bu modelde, elektrik alanın matematiksel ifadesi, iletim hattı-kuplaj denklemleri ile doğrudan ilişkilendirilmiştir. Söz konusu alan denklemi, Rachidi tarafından türetilmiş olup, modelin temelinde manyetik uyarılma alanı yer almaktadır. Yani, modelde hat üzerindeki gerilim ve akım değişimleri esas olarak manyetik alan kaynaklı uyarılmalara dayandırılarak açıklanır.

Rachidi kuplaj modeli, daha önce Agrawal vd. ve Taylor vd. tarafından ortaya konulan iletim hattı modelleme yaklaşımlarının geliştirilmiş bir versiyonudur. Bu modelde, yıldırım darbesi sonucu oluşan elektromanyetik alanların, iletim hattında oluşturduğu etkiler fiziksel olarak tutarlı diferansiyel denklemler aracılığıyla temsil edilir. Rachidi'nin katkısıyla bu kuplaj modeli, özellikle hem doğrudan hem de dolaylı yıldırım etkilerinin iletim hatlarındaki gerilim ve akım dağılımı üzerindeki etkilerini daha hassas biçimde tahmin etmeye olanak sağlamaktadır. Bu konudaki ilgili ilgili iletim hattı denklemleri (Rachidi F., 1993):

$$\frac{\partial u(x,t)}{\partial x} + L' \frac{\partial i^s(x,t)}{\partial t} = 0 \quad (3.63)$$

$$\frac{\partial i^s(x,t)}{\partial x} + C' \frac{\partial u(x,t)}{\partial t} = \frac{1}{L'} \int_0^h \frac{\partial \mathbf{B}_x^i(x,z,t)}{\partial y} \cdot dz \quad (3.64)$$

t Zamanındaki ve x noktasındaki toplam dağılık akım:

$$i(x, t) = i^s(x, t) - \frac{1}{L'} \int_0^h \mathbf{B}_y^i(x, z, t) dz \quad (3.65)$$


Hat sonu sınır şartları:

$$i^s(0, t) = -\frac{u(0, t)}{R_0} + \frac{1}{L'} \int_0^h \mathbf{B}_y^i(0, z, t) dz \quad (3.66)$$

$$i^s(L, t) = -\frac{u(L, t)}{R_L} + \frac{1}{L'} \int_0^h \mathbf{B}_y^i(l, z, t) dz \quad (3.67)$$


İletim hattı ile yıldırım kaynaklı kublaj, özellikle manyetik alan bileşenleri temel alınarak değerlendirilebilir. Rachidi (1993) tarafından önerilen model, kublaj analizinde manyetik alanın etkisini esas alan bir yaklaşım sunar. Literatürde genel kabul gören bir gerçek, manyetik alan ölçümlerinin, elektrik alan ölçümlerine kıyasla daha kolay ve daha kararlı koşullarda gerçekleştirilebildiğidir. Bu bağlamda, Rachidi modeli özellikle dikkat çekicidir; çünkü bu model, yıldırım etkilerinin iletim hattına olan etkisini yalnızca manyetik alan bileşenleri üzerinden değerlendirir ve bu alanlar üzerinden hesaplamalarını gerçekleştirir. Bu özellik, modeli hem teorik çalışmalarda hem de deneysel uygulamalarda tercih edilebilir kılmaktadır.

Şekil 3.11’de, Rachidi’nin iletim hattı kublaj modeline ilişkin eşdeğer devre temsili sunulmakta ve manyetik uyarılmanın iletim hattı üzerindeki etkileri ayrıntılı biçimde gösterilmektedir.



Şekil 3.11. Rachidi modeli iletim hattı.

Chowdhuri - Gross iletim hattı kublaj modeli Şekil 3.12’de sunulmaktadır.



Şekil 3.12. Chowdhuri-Gross iletim hattı kublaj modeli.

Chowdhuri ve Gross (1967) tarafından Şekil 3.12'deki iletim hattı modeli, yapısal olarak Rusck (1958) modelinin temel denklemleriyle benzerlik göstermektedir. Ancak bu modelde, Rusck modelinde kullanılan toplam hat gerilimi ve yük skaler potansiyelleri yerine, toplam hat gerilimi ile yük uyarım gerilimleri esas alınmaktadır. Bu yaklaşım, iletim hattı üzerindeki yıldırım kaynaklı indüklenmiş gerilimlerin, doğrudan gözlemlenebilen gerilimler cinsinden ifade edilmesini sağlamaktadır ve uygulamalı mühendislik hesaplamaları açısından avantaj sunmaktadır. Chowdhuri modeli, yıldırımın iletim hatları üzerindeki etkilerini daha sade bir matematiksel çerçevede tanımlayarak, sistematik analizlerde kullanılabilecek pratik bir modelleme yöntemi sunmaktadır. Bu modele ait iletim hattı denklemleri Denklem 3.68 ve Denklem 3.69'da verilmiştir:

$$\frac{\partial u(x,t)}{\partial x} + L' \frac{\partial i(x,t)}{\partial t} = 0 \quad (3.68)$$

$$\frac{\partial i(x,t)}{\partial t} + C' \frac{\partial u(x,t)}{\partial t} = -C' \cdot \frac{\partial}{\partial t} \int_0^h \mathbf{E}_z^i(x,z,t) dz \quad (3.69)$$

$\mathbf{E}_z^i$ Elektrik alan yükünün yatay bileşenidir. Sınır şartları ise:

$$u(0,t) = -R_0 i(0,t) \quad (3.70)$$


$$u(L,t) = -R_L i(L,t) \quad (3.71)$$

Şekil 3.12, Chowdhuri kuplaj modeline dayalı eşdeğer iletim hattı gösterimini sunmaktadır. Literatürde önerilen çeşitli kuplaj modelleri arasında, özellikle Rusck modeli ile Agrawal ve arkadaşları tarafından geliştirilen model öne çıkmaktadır. Bu iki model, EİH üzerinde yıldırım kaynaklı aşırı gerilimlerin tahmini amacıyla en yaygın şekilde kullanılan yöntemler arasında yer almaktadır.

Cooray (1994) tarafından yapılan karşılaştırmalı analiz, Rusck modelinin önemli bir kısıtına dikkat çekmiştir: model, vektör potansiyelin etkisini ihmal etmektedir. Bu nedenle, sadece yatay elektrik alan bileşeninin, yıldırım akımı kaynağına olan bağımlılığı esas alınır. Bu eksikliğe rağmen, Rusck modeli yıldırım parametreleri tam olarak bilinmese dahi çoğu durumda doğruya yakın sonuçlar verebilmektedir. Söz konusu


doğruluk, modelin sadeliği ve vektör potansiyel katkısının ihmal edilmesinden kaynaklanan basitleştirilmiş yaklaşımı sayesinde elde edilmektedir.

Barker vd. (1996), Araujo vd. (2001) yaptıkları deneysel ölçümler tek devre bir iletim hattı üzerinde olup, Agrawal kuplaj modelini kullanarak maksimum aşırı gerilimleri hesaplamışlardır. Benzer şekilde, Jankov (1997), Rusck modeline dayalı hesaplamalarla yıldırım kaynaklı aşırı gerilimlerin nicel analizini gerçekleştirmiştir. Ayrıca, Şekil 3.13'te sunulan grafik, yıldırım akımı modellemesinde yaygın olarak kullanılan ve standart kabul edilen bir akım-zaman profiline sahiptir. Bu grafik, aşırı gerilim tahminlerinde temel giriş olarak kullanılan yıldırım akım formunu temsil etmektedir.



Şekil 3.13. IEEE 1410 standardına göre yıldırım akım grafiği.

Aynı yıldırım akımı etkisi altında Rusck ve Agrawal modellerine göre iletim hattında oluşan indüklenmiş gerilim tepkilerini göstermektedir. Agrawal modeli, vektör potansiyel ve alan türevlerini hesaba kattığı için daha keskin ve yüksek tepe gerilimleri üretirken, Rusck modeli daha sönümlü bir yanıt verir. Bu fark, Agrawal modelinin daha fiziksel olarak doğru sonuçlar üretmesinden kaynaklanmaktadır.



Şekil 3.14. Rusck ve Agrawal modellerine göre iletim hattı tepkisi.


3.5. Yıldırım Aşırı Gerilimleri Etkileyen Unsurlar

Yıldırım kaynaklı aşırı gerilimlerin büyüklüğünü etkileyen birçok faktör bulunmaktadır. Bu faktörler, iletken tasarımından hat yüksekliğine, korona kayıplarından topraklama teline kadar geniş bir yelpazeyi kapsamaktadır. İlgili tüm başlıklar aşağıda sistematik olarak değerlendirilmiştir.

3.5.1. Çoklu iletken

Darbe noktasına yakın konumlanan iletim hatlarında oluşan aşırı gerilimler, hattın fiziksel yapısından, özellikle de çok iletkenli kule konfigürasyonundan önemli ölçüde etkilenmektedir. Bu etki, özellikle hatların dikey yerleşim düzenine bağlı olarak belirginleşmektedir. Chowdhuri (1990)'ya göre, yatay yerleşim düzenine sahip hatlarda ise, iletkenler arasındaki mesafe ile yıldırım darbe noktasının bu iletkenlere olan uzaklığı indüklenen aşırı gerilimin büyüklüğünü doğrudan etkilemektedir. Çok iletkenli bir hat yapısında, tek bir iletken üzerinde indüklenen aşırı gerilim, komşu iletkenlerin elektromanyetik etkisiyle önemli ölçüde azaltılmaktadır. Literatürdeki çalışmalara göre, bu azalma oranı tek bir iletkenli yapı ile karşılaştırıldığında %15 ila %40 arasında değişebilmektedir. Bazı çalışmalarda bu oran %15 ila %25 aralığında ölçülmüştür (Idone 1982; Rachidi 1997; Kannu ve Thomas 2005). Bu durum, çok iletkenli yapılarda elektromanyetik alanların karşılıklı etkileşimi sonucu bir gölgeleme etkisinin oluştuğunu göstermektedir. Bu bağlamda, iletim hattındaki iletken sayısının artırılması, darbe kaynaklı indüklenen aşırı gerilimlerin hem hat boyunca hem de uç noktalarda daha düşük seviyelerde gerçekleşmesini sağlar. Başka bir ifadeyle, iletken sayısı arttıkça, sistemin yıldırım etkilerine karşı elektromanyetik bağışıklığı artmakta, dolayısıyla gerilim tepkileri daha kontrollü hale gelmektedir.

Şekil 3.15'te sunulan grafikte yıldırım darbesine bağlı olarak iletim hattında indüklenen aşırı gerilimin, iletken sayısına bağlı olarak nasıl azaldığını göstermektedir. Görüldüğü üzere, iletken sayısı arttıkça her bir iletken üzerindeki indüklenen gerilim önemli ölçüde düşmekte ve elektromanyetik bağışıklık artmaktadır. Bu da çok iletkenli hat konfigürasyonlarının yıldırıma karşı daha avantajlı olduğunu ortaya koymaktadır




Şekil 3.15. İletken sayısına göre indüklenen aşırı gerilimler.

3.5.2. Koruma iletkeni

Koruma iletkenlerinin (topraklama telleri) kullanımı, yıldırım darbesi etkisiyle iletim hattında indüklenen aşırı gerilimlerin azaltılmasında etkili bir yöntem olarak kabul edilmektedir. Bu gerilim azalımı, koruma iletkeninin faz iletkenlerine olan konumuna ve özellikle de iletkenin topraklı ya da topraklanmamış oluşuna bağlı olarak değişiklik göstermektedir (Chowdhuri 1990). Literatürde yapılan deneysel ve teorik çalışmalara göre, koruma iletkenlerinin kullanımı; indüklenen aşırı gerilimlerin genliğini yaklaşık %20 ila %40 oranında azaltabilmektedir (Rusck 1958; Yoldaş 2019). Bu azalma, yıldırım kaynaklı elektromanyetik alanların iletim hattı faz iletkenleri üzerindeki etkilerinin elektromanyetik kalkanlama prensibiyle sınırlandırılmasından kaynaklanmaktadır. Ancak bu etkinlik, yalnızca koruma iletkeninin varlığına değil, aynı zamanda iki ardışık topraklama noktası arasındaki mesafeye de duyarlıdır. Paolone vd. (2004) tarafından yapılan çalışmalarda, bu aralığın azaltılmasının, koruma iletkeninin yıldırıma karşı etkinliğini önemli ölçüde artırdığı gösterilmiştir. Dolayısıyla, koruma tellerinin tasarımı yapılırken yalnızca konumları değil, aynı zamanda topraklama frekansı ve mesafesi de dikkate alınmalıdır.

Şekil 3.16'da koruma iletkeninin yıldırım kaynaklı indüklenen aşırı gerilimleri azaltmadaki etkinliğinin, iki ardışık topraklama noktası arasındaki mesafeye bağlı olarak

nasıl değiştiğini göstermektedir. Görüldüğü üzere, topraklama aralığı azaldıkça koruma iletkeninin etkinliği artmakta ve aşırı gerilimlerde %40'a kadar azalma sağlanabilmektedir. Bu grafik, tasarım sürecinde koruyucu iletkenlerin uygun aralıklarla topraklanmasının önemini açıkça ortaya koymaktadır.




Şekil 3.16. Topraklama aralığına göre koruma iletkeninin etkinliği.

3.5.3. Toprak direnci

Sonlu zemin iletkenliği durumunda, yıldırım etkisiyle iletim hattında indüklenen aşırı gerilimin büyüklüğü, hattın geometrisi ve seçilen gözlem (hesaplama) noktasına bağlı olarak değişkenlik göstermektedir. Kannu ve Thomas (2005)'e göre, bu gerilimin büyüklüğü hattın orta noktasında maksimuma ulaşmakta, buna karşın hat uçlarında belirgin şekilde azalmaktadır. Özellikle iletken yüksekliğinin düşük olduğu durumlarda (örneğin 10 metre veya daha az), toprak iletkenliğinin hem dalga şekli hem de indüklenen gerilim genliği üzerinde önemli bir etkisi bulunmaktadır. Bu kapsamda, Perez vd. (2003) ve Razzak (2004) tarafından yapılan çalışmalar, toprak iletkenliğinin artırılmasının yıldırım kaynaklı indüklenen aşırı gerilimi azaltmaya katkı sağladığını göstermektedir. Bunun nedeni, daha iletken bir zeminin yıldırım darbesiyle oluşan elektromanyetik alanları daha etkili bir şekilde dağıtarak, hat üzerinde daha düşük gerilim tepkileri oluşturmasıdır. Ancak iletken yüksekliği arttıkça, özellikle yüksek gerilim hatlarında (>10 m), sonlu zemin iletkenliğinin indüklenen aşırı gerilim üzerindeki etkisi göz ardı edilebilir hâle gelir (Perez vd. 2003). Bu, elektromanyetik alanın büyük oranda havada yayıldığı ve zemin etkisinin zayıfladığı durumlarla ilişkilidir. Sonlu zemin iletkenliği varsayımı altında yapılan modellemeler, hattın ortasında gerilim yükselmesi, ancak uç noktalarında sönümlenme ile sonuçlanan bir gerilim dağılımı profili ortaya koymaktadır.

(Kannu ve Thomas, 2003). Bu durum, yıldırım darbesine maruz kalan iletim hattı boyunca konum bazlı koruma stratejilerinin önemini vurgulamaktadır.

Şekil 3.17’de sonlu toprak iletkenliği durumunda iletim hattı boyunca indüklenen aşırı gerilimin konuma bağlı dağılımını göstermektedir. Görüldüğü gibi, gerilim hattın ortasında maksimum seviyeye ulaşırken, hat uçlarında belirgin şekilde azalmaktadır. Bu durum, yıldırıma karşı koruma stratejilerinin tasarımında konum bazlı farklılaştırmalar yapılması gerektiğini ortaya koymaktadır.




Şekil 3.17. Sonlu toprak iletkenliğinde indüklenen aşırı gerilim profili.

3.5.4. Yıldırımın darbesinin konumu

Yıldırımın darbe noktası ile iletim hattı arasındaki konum ilişkisi, indüklenen aşırı gerilimlerin büyüklüğünü doğrudan etkilemektedir. Perez (2003) tarafından yapılan çalışmada, yük açısının artırılmasıyla iletim hattında indüklenen aşırı gerilimin azaldığı gösterilmiştir. Benzer şekilde, yıldırım darbesinin iletim hattına olan mesafesi arttıkça, hat üzerinde oluşan indüklenmiş gerilimlerin genliği azalma eğilimi göstermektedir. Koga vd. (1979) tarafından önerilen modelde, geri dönüş darbesi parametreleri ve mükemmel iletken bir toprak varsayımı altında, indüklenen aşırı gerilim; yıldırım darbesi ile iletim hattı arasındaki mesafeyle ters orantılı olacak şekilde modellenmiştir. Yani, darbe noktası hattın daha yakın bir konumunda gerçekleştiğinde, hattaki gerilim daha yüksek; daha uzak noktalarda ise daha düşüktür. Öte yandan, gecikme süresi de yıldırımın iletim hattına olan mesafesine bağlı olarak değişmektedir. Razzak vd. (2024) tarafından yapılan güncel çalışmalarda, yıldırım darbesinin hattaki belirli bir noktada oluşturduğu gerilim tepkisinin zamansal gecikmesi, darbe mesafesi arttıkça artış göstermektedir. Bu durum, elektromanyetik alanların yayılma süresi ile doğrudan ilişkilidir ve özellikle zaman-domainde yapılan analizlerde dikkate alınması gereken önemli bir parametredir.

Şekil 3.18'deki çift eksenli grafik, yıldırım darbe noktasının iletim hattına olan mesafesi arttıkça indüklenen, ters orantı sergileyen ve kırmızı eğri ile gösterilen aşırı gerilimin azaldığını, mavi ile gösterilen eğri gerilim tepkisinin gecikme süresinin ise arttığını göstermektedir.




Şekil 3.18. Darbe mesafesine göre indüklenen gerilim ve gecikme süresi.

3.5.5. Hat uzunluğu ve direk yüksekliği

İletim hattı yüksekliği, yıldırım kaynaklı indüklenen aşırı gerilimlerin hem genliği hem de ön dikliği (ön kenar yükselme süresi) üzerinde önemli bir etkiye sahiptir. Razzak (2004) çalışmasında, iletim hattı yüksekliğinin artmasının, indüklenen gerilimlerin büyüklüğünü artırdığı ve bu etkinin özellikle ön dikliği yüksek olan darbe türlerinde daha belirgin hale geldiği ortaya konmuştur. Mükemmel toprak iletkenliği varsayımı altında, hat yüksekliği ile indüklenen aşırı gerilim arasında yaklaşık doğrusal bir ilişki söz konusudur. Bu durum, elektromanyetik alanların daha yüksek iletken seviyelerinde hat boyunca daha fazla kuplaj oluşturmamasından kaynaklanmaktadır. Bu ilişki, Rachidi (1997), Borghetti vd. (2000), Borgetti (2000) ve Cooray (2003) gibi araştırmacıların çalışmalarında teorik ve deneysel olarak doğrulanmıştır. Öte yandan, sonlu toprak iletkenliği durumunda bu ilişki daha karmaşık hale gelir. Bu durumda indüklenen aşırı gerilim büyüklüğü; yalnızca hat yüksekliğine değil, aynı zamanda toprak iletkenliğine, yıldırım darbe noktasının hattaki konumuna ve gözlem yapılan hattın konumuna bağlı olarak değişkenlik gösterir. Bu etkileşimler nedeniyle sonlu toprak modelleri, daha karmaşık ancak gerçekçi analizler sunar. Ayrıca, yıldırımın oluşturduğu elektromanyetik darbe ile iletim hattı arasındaki kuplaj etkisi, hattın uzunluğu 2 km'yi geçtiğinde ihmal edilebilir düzeye iner. Bu, elektromanyetik alanın uzayda yayılımı sırasında enerji dağılımının zayıflamasıyla ilişkilidir. Guerrieri vd. (1997) ve Cooray (2003) tarafından yapılan analizlerde, kayıpsız bir hat varsayımı altında hat uzunluğunun gerilim genliği

üzerindeki etkisinin sınırlı olduğu, yani gerilim genliğinin hat uzunluğu arttıkça sabit kaldığı gösterilmiştir. Ancak düşük toprak iletkenliği koşullarında, bu maksimum gerilim genliği zamanla azalma eğilimi göstermektedir.



Şekil 3.19. Hat yüksekliğine göre indüklenen aşırı gerilim.

Şekil 3.19'da sunulan grafik, iletim hattı yüksekliğinin artmasıyla birlikte indüklenen aşırı gerilimdeki değişimi, iki farklı toprak iletkenliği durumuna göre göstermektedir. Bunlardan mavi çizgi mükemmel toprak iletkenliği durumuna göre oluşan gerilim, hat yüksekliğiyle doğrusal olarak artmaktadır. Kırmızı kesik çizgi sonlu toprak iletkenliği halinde artış daha sönümlü ve logaritmik eğilimlidir, yani yüksekliğin etkisi sınırlanır. Bu grafik, yıldırım etkisine karşı sistem tasarımında toprak özelliklerinin ve hat yüksekliğinin birlikte değerlendirilmesi gerektiğini göstermektedir.

3.5.6. Korona etkisi

Korona etkisi, yıldırım darbesi sonucu iletim hattında indüklenen aşırı gerilimlerin büyüklüğü ve karakteristikleri üzerinde önemli bir rol oynamaktadır. Bu etki, darbenin türüne bağlı olarak farklı şekillerde ortaya çıkar. Silva (2002) çalışmasına göre, yıldırımın dolaylı etkisi yani yakın çevrede oluşan elektromanyetik alan nedeniyle indüklenme durumunda, korona etkisi nedeniyle indüklenen aşırı gerilim genliği artış göstermektedir. Buna karşılık, yıldırımın doğrudan darbesi durumunda ise, korona etkisi indüklenen aşırı gerilimin azalmasına neden olmaktadır. Bu farklılık, korona oluşumunun hat üzerindeki kapasitansı artırmasıyla açıklanabilir. Kapasitansın artması, hattın elektromanyetik darbelerle karşı tepkisini yavaşlatır ve enerjinin daha geniş zamana yayılmasına yol açar. Bu durum, aşırı gerilim yayılma hızının azalmasıyla, toplam indüklenen aşırı gerilimin artmasına neden olur. Korona etkisi, özellikle sonlu toprak iletkenliği koşullarında oluşan yüksek gerilimde oldukça belirgindir. Ancak yapılan analizler, doğrudan darbe senaryosunda, koronanın etkisinin sonlu toprak iletkenliğinden bile daha baskın olduğunu

ortaya koymaktadır. Bu durum, doğrudan yıldırım darbesine maruz kalan iletim sistemlerinin tasarımında koronanın ayrı bir hassasiyetle ele alınmasını gerektirmektedir. Ayrıca, korona oluşumu indüklenen aşırı gerilimin yükselme süresini artırmakta, buna karşılık ön dikliğini yani gerilim darbesinin çıkış eğimini azaltmaktadır. Bu değişim, yıldırım darbesinin iletim hattı üzerinde oluşturduğu elektromanyetik etkilerin zaman profiline doğrudan etki eder ve hat içi ekipmanların maruz kalacağı gerilim karakteristiğini önemli ölçüde değiştirir.

3.5.7. Yıldırım parametrelerinin etkileri

Yıldırımın iletim hatları üzerindeki etkilerini doğru şekilde analiz edebilmek için, yıldırım darbesinin şekli, şiddeti, yapısı ve zamansal karakteristikleri gibi parametrelerin dikkatle değerlendirilmesi gerekmektedir. Bu bağlamda yıldırım darbesinin öncül zamanı, bozunma süresi, akım genliği ve geri dönüş darbe hızı gibi fiziksel büyüklükler, indüklenen aşırı gerilimin hem genliğini hem de zaman profiline ilişkin karakteristiklerini belirlemektedir.

Yıldırım darbesinin en önemli zamansal parametrelerinden biri olan öncül zaman, akımın tepe noktasına ulaşma süresini tanımlar. Öncül zamanın artması, hat boyunca özellikle orta bölgelerde indüklenen aşırı gerilimlerin genliğinde belirgin bir azalmaya yol açmaktadır. Bu ilişki genellikle ters orantılıdır. Yıldırımın öncül zamanı ile oluşan gerilimin kendi öncül zamanı arasında doğrusal bir orantı bulunur. Bu da yıldırımın zaman karakteristiğinin iletim hattına doğrudan yansıdığını gösterir (Silva 2002; Perez vd. 2003).

Bozunma süresi, yıldırım darbesinin tepe değerinden sonra ne kadar sürede sönümlendiğini belirler. Ancak yapılan çalışmalar göstermiştir ki, öncül zaman 1 μ s'nin altındaysa, bozunma süresinin indüklenen aşırı gerilim üzerindeki etkisi oldukça sınırlıdır. Gerilim genliği üzerinde etkisi ihmal edilebilir düzeyde olup, sadece darbe akımının değişkenliği üzerinde zayıf bir etkiye sahiptir (Silva vd. 2002).

Akım genliği, yıldırımın taşıdığı toplam enerjiyle ilişkilidir ve iletim hattı boyunca indüklenen aşırı gerilimle doğrudan orantılıdır. Bu orantı tüm hat boyunca korunur. Ancak, akım genliğinin indüklenen gerilimin zaman profiline özellikle de öncül zaman üzerine etkisi bulunmamaktadır (Silva vd. 2002; Yoldaş 2003).

En dinamik etkilerden biri ise geri dönüş darbe hızı ile ilgilidir. Geri dönüş darbesi yıldırım kanalında yukarı doğru hareket ederken elektromanyetik alanları oluşturan başlıca kaynaktır. Bu hız arttıkça, indüklenen aşırı gerilim genliği azalma eğilimindedir. Ancak bu azalma, dalga formunun dikliğini artırmakta, yani darbe daha keskin hale gelmektedir. Bu ilişki yukarıdaki grafikte açıkça gösterilmiştir: geri dönüş darbe hızı arttıkça, indüklenen aşırı gerilimin ön dikliği de artmaktadır (Silva vd. 2002). Böylece iletim hattında daha kısa sürede daha yüksek eğimli gerilim darbeleri oluşmaktadır. Bu

etkinin büyüklüğü, hattın konumuna ve yıldırımın çarpma yerine olan mesafeye göre değişiklik gösterir. Özellikle düşük toprak iletkenliği durumlarında, bu etki hat sonlarında daha belirgin hale gelir. Uzak darbe noktalarında, geri dönüş darbe hızı ile indüklenen gerilim tepe değeri arasında yaklaşık bir orantı varken, bu bölgelerde gerilim düzeyi genel olarak düşüktür. Buna karşılık, yakın darbe noktalarında geri dönüş hızının etkisi minimaldir ve indüklenen gerilim genliği, hızdan ziyade diğer parametrelere bağlı olarak şekillenir (Nucci vd. 1993; Cooray 2003).

3.6. Veri Setleri ve Kaynakları

Bu bölümde, yıldırım kaynaklı arızaların tahmini için kullanılan veri setleri ve bu verilerin kaynakları detaylandırılmış olup iki kısma ayrılmıştır. Bunlar yıldırım ve EİH arıza verileridir. Yıldırım verileri MGM'den elde edilmiştir. 2015-2022 yılları arasında Antalya bölgesinde 360.000 yıldırım verisi koordinat (enlem, boylam), akım şiddeti (kA), tarih, saat, bulut-toprak yıldırımı, sıcaklık, nem oranı ve atmosfer basıncı bilgilerini içermektedir.

EİH arıza verileri ise YG EİH işletme operatörü olan TEİAŞ'tan alınmıştır. Alınan veriler ile MGM'den alınan veriler filtrelenerek 2015-2022 yılları arasında meydana gelen 713 yıldırım kaynaklı arıza bilgisi elde edilmiştir. Topraklama direnci, direk tipi, izolatör boyu, işletme gerilimi, hava durumu değişkenleri barındırmaktadır. Direklere ait direnç hesaplanırken PSCAD programı kütüphanesi kullanılmıştır. İzolatör boyu bilgisi de imalatçı firmaların katalog bilgilerinden elde edilmiştir. Filtreleme işlemi için EİH güzergâhları ile yıldırım verileri NETCAD programı kullanılarak birleştirilmiştir. Tek devre hatlar için ve 50m, çift devre hatlar için 80 m'lik koridor içinde kalan yıldırım verisi filtrelenmiştir. Bu veriler ile EİH arıza verilerinin tarih ve saatleri eşleştirilerek hangi yıldırımın hatta düştüğü tespit edilmiştir. Bu sayede 713 adet yıldırım kaynaklı arıza elde edilmiştir. 5 kA ve altındaki yıldırımlar düşük etki gücü nedeniyle analiz dışı bırakılmıştır.

3.7. Veri Ön İşleme ve Özellik Mühendisliği

MÖ modellerinin başarılı bir şekilde eğitilebilmesi için veri ön işleme ve özellik mühendisliği kritik bir adımdır. Bu işlem için eksik veri yönetimi, aykırı değer analizi, özellik seçimi ve dönüşümü ile veri bölünmesi incelenmiştir.

3.7.1. Eksik veri yönetimi

Bu çalışma kapsamında EİH arıza verileri ve yıldırım verileri farklı kaynaklardan toplandığından, bazı eksik değerler içermektedir. Bu eksik verilerin yönetimi için belirli veri temizleme ve işleme adımları uygulanmıştır. Öncelikle, eksik konum koordinat bilgisine sahip yıldırım olayları veri setinden çıkarılmış, benzer şekilde akım şiddeti eksik olan yıldırım verileri de analiz dışı bırakılmıştır. EİH verilerinde direk tipi, izolatör boyu, koruma teli sayısı vb. eksik olan mühendislik parametreleri ise en yakın benzer verilerin

ortalaması alınarak tamamlanmıştır. Ayrıca, arızaların tam konum doğruluğunu artırmak için mesafe koruma rölesinden alınan kilometre kayıt bilgisi ile veriler doğrulanmıştır. Son olarak elde edilen toplu veri setinde %5'ten fazla eksik veri içeren satırlar tamamen çıkarılarak veri kalitesinin artırılması sağlanmıştır. Bu adımlar, modelin güvenilirliğini artırmak ve eksik veri kaynaklı hataları en aza indirmek için uygulanmıştır.

3.7.2. Aykırı değer analizi

Aykırı değerler, modelin doğruluğunu olumsuz etkileyebileceğinden, bunların tespit edilmesi ve temizlenmesi için istatistiksel ve MÖ tabanlı çeşitli yöntemler kullanılmıştır. İlk olarak, istatistiksel yöntemler kapsamında, akım şiddeti değerleri için Z-skor yöntemi uygulanmış ve ± 3 standart sapma dışındaki veriler aykırı olarak işaretlenerek veri setinden çıkarılmıştır. Grafiksel yöntemler kullanılarak, özellikle yükseklik ve topraklama direnci gibi mühendislik değişkenlerindeki uç değerler kutu grafiği analizleri ile görselleştirilmiş ve belirlenen Aykırı gözlemler çıkarılarak analiz dışı bırakılmıştır. Son olarak, MÖ tabanlı yöntemler arasında izole orman algoritması kullanılarak normal dağılımın dışında kalan anormal veriler tespit edilmiştir. Bu yöntemler sayesinde, modelin doğruluğunu etkileyebilecek olağan dışı veriler ayıklanarak, analiz edilen veri setinin güvenilirliği artırılmıştır.

3.7.3. Özellik Seçimi ve Dönüşümü


Modelin tahmin doğruluğunu artırmak amacıyla çeşitli özellik mühendisliği teknikleri uygulanmış ve en etkili değişkenler SHAP analizi ile belirlenmiştir. MÖ modelinin başarısını en üst seviyeye çıkarmak için önemli değişkenler belirlenmiş ve uygun dönüşümler uygulanmıştır.

Değişken seçimi sürecinde, model için en kritik değişkenleri belirlemek amacıyla SHAP analizi ve karşılıklı bilgi ölçütü yöntemi birlikte kullanılarak değişkenler arasındaki ilişkiler değerlendirilmiştir. Bu sayede, modelin karar mekanizmasını en çok etkileyen değişkenler seçilerek gereksiz veya düşük etkili özellikler çıkarılmıştır. En etkili değişkenler yıldırım akım şiddeti, topraklama direnci, izolatör boyu ve hat gerilimi bulunmuştur. Ayrıca, veri seti min-maks normalizasyon yöntemiyle $[0,1]$ aralığına dönüştürülerek modelin daha dengeli ve kararlı çalışması sağlanmıştır. Bunun yanı sıra, direk tipi gibi kategorik değişkenler tekil kodlama yöntemiyle sayısal forma dönüştürülerek MÖ algoritmalarının bu değişkenleri daha verimli kullanabilmesi sağlanmıştır. Yapılan bu işlemler, modelin performansını artırarak yıldırım kaynaklı EİH arızalarının daha hassas bir şekilde tahmin edilmesine katkı sağlamıştır.

3.7.4. Veri bölünmesi

Verilerin eğitim ve test süreçlerini yönetmek için tabakalı örnekleme yöntemi kullanılarak veri seti dengeli bir şekilde bölünmüştür. %80 eğitim seti, %20 test seti olarak kullanılmıştır. Bu oran, literatürde yaygın bir şekilde kullanılan ve eğitim ile test

verileri arasında denge sağlayan bir yaklaşımdır (Kohavi 1995; Géron 2022). Bu sayede sınıf dengesizliği önlenmiş ve tüm sınıfların eğitim sürecinde yeterince temsil edilmesi sağlanmıştır. Ancak, yıldırım verileri ile arıza verileri arasında dengesizlik olduğu tespit edilmiştir. Modelin bu dengesizlikten etkilenmemesi için veri dengeleme yöntemleri uygulanmıştır. Veri setinde azınlık sınıfının daha iyi temsil edilmesini sağlamak amacıyla SMOTE yöntemi kullanılmıştır. Ayrıca, modelin öğrenme sürecinde yanlılığı önlemek için ağırlıklandırılmış kayıp fonksiyonu uygulanmış ve alt örnekleme yöntemiyle çoğunluk sınıfının etkisi dengelenmiştir. Azınlık sınıfın çoğaltılmasına ek olarak, çoğunluk sınıfa ait örnekler de alt örnekleme yöntemiyle seyreltilmiştir. Veri setindeki baskın sınıf örneklerinin kontrollü biçimde azaltılması, modelin eğitiminde sınıflar arası dengenin sağlanmasına yardımcı olmuştur. Bu yaklaşım, modelin çoğunluk sınıfa aşırı uyum sağlamasını engelleyerek hatalı negatifleri azaltmaya katkı sunarken, aynı zamanda aşırı sayıda gereksiz hatalı pozitif tahmin yapılmasının da önüne geçmeyi hedeflemiştir. Bu yöntemler sayesinde modelin dengesiz veriler karşısında daha adil ve doğru tahmin yapması sağlanmıştır. Öncelikle, dengesiz sınıf dağılımının model üzerindeki etkisini azaltmak için SMOTE uygulanmıştır. SMOTE yöntemi, azınlık sınıfa ait sentetik örnekler üretip veri setine ekleyerek sınıflar arası dengesizliği giderir. Bu sayede model, nadir görülen yıldırım olaylarını daha fazla örnek üzerinden öğrenme imkânı bulmuş ve bu durum hatalı negatif sayısının azalmasına katkı sağlamıştır. Bu durum şekil 3.20’te paylaşılmıştır.



Şekil 3.20. SMOTE ile azınlık sınıfını dengeme.

Matematiksel olarak ise:

$$\tilde{x} = x_i + \delta \cdot (x_{zi} - x_i) \quad (3.72)$$

Burada x_i azınlık sınıfına ait orijinal örnek, x_{zi}, x_i' nin k-en yakın komşularından biri, $\delta \in [0,1]$ Rastgele seçilen her bir sentetik örnek için farklı skaler.

3.8. Hibrit Modelin Oluşturulması

Hibrit model, yıldırım kaynaklı elektromanyetik darbelerin EİH’de oluşturduğu arızalarını tahmin etmek için ROA ve XGBoost'un birleşimiyle oluşturulmuştur. Modelin daha yüksek doğruluk oranı sunması için topluluk öğrenme teknikleri kullanılmış ve hiperparametre optimizasyonu gerçekleştirilmiştir.

3.8.1. Algoritma seçimi ve gerekçesi

ROA karar ağaçları topluluğuna dayalı bir topluluk öğrenme yöntemidir. Model, her bir karar ağacının farklı bir alt küme ile eğitildiği ve ağaçların çoğunluk oyu veya ortalaması ile son tahminin belirlendiği bir yapıya sahiptir (Breiman 2001).

Matematiksel model:

$$\hat{f}(x) = \frac{1}{B} \sum_{b=1}^B h_b(x) \quad (3.73)$$

B toplam ağaç sayısı,

$h_b(x)$ b . karar ağacının tahmin ettiği sonuç,

x giriş değişkeni,

$\hat{f}(x)$ nihai tahmin sonucudur.

Sınıflandırma için:

$$\hat{y} = \text{çoğunluk oyu}(h_1(x), h_2(x), \dots, h_B(x))$$

Regresyon için Denklem 3.74’te ortaya konulmuştur:

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B h_b(x) \quad (3.74)$$

ROA aşırı öğrenmeye dayanıklı bir algoritma olup, modelin genelleme kapasitesini artırarak daha dengeli tahminler üretmesini sağlar (Imani vd. 2025). Ayrıca, öznitelik önem sıralaması yapabilme yeteneği sayesinde modelin açıklanabilirliğini artırarak hangi değişkenlerin tahminlerde daha etkili olduğunu belirleyebilir. Büyük veri setlerinde başarılı sonuçlar veren ROA, özellikle karmaşık ilişkilerin bulunduğu veri kümelerinde güçlü performans sergiler. Ancak, büyük veri setlerinde eğitim sürecinin

uzun sürmesi ve karmaşık modellerde fazla bellek tüketmesi gibi dezavantajları bulunmaktadır.

XGBoost, gradyan artırma yöntemi temelinde çalışan güçlü bir MÖ algoritmasıdır. Karar ağaçları, birbirini takip eden iterasyonlarla oluşturulur ve her yeni ağaç, önceki ağaçların hatalarını minimize edecek şekilde eğitilir (Chen ve Guestrin, 2016). Matematiksel model Denklem 3.75 ile bulunur:

$$y_i^{(t)} = y_i^{(t-1)} + f_t(x_i) \quad (3.75)$$

Burada:

$y_i^{(t)}$: i . Gözlem için t . iterasyondaki tahmin değeridir.

$f_t(x_i)$: t . iterasyondaki yeni karar ağacıdır.

XGBoost'un amaç fonksiyonu şu şekilde ifade edilir:

$$\mathcal{L}(\theta) = \sum_{i=1}^n l(y_i, y_i) + \sum_{t=1}^T \Omega(f_t) \quad (3.76)$$

Burada:

$\mathcal{L}(\theta)$: Modelin optimizasyon fonksiyonudur.

$l(y_i, y_i)$: Logaritmik kayıp ve kare hata gibi kayıp fonksiyonudur.

$\Omega(f_t)$: Ağaç derinliği, yaprak sayısı vb. modelin karmaşıklık ölçüsü ya da düzenleme terimi olup Denklem 3.77 ile bulunmuştur.

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (3.77)$$

Burada:

T : Ağacın yaprak sayısı

ω_j : Yaprak skorları

λ, γ : Hiperparametreler

Bir yapraktaki örnekler kümesi I_j ise o yaprağın değeri Denklem 3.78 ile hesaplanır:

$$\omega_j = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (3.78)$$

Ağacın toplam skoru Denklem 3.79'da sunulmuştur:

$$\mathcal{L}_{\text{ağaç}} = -\frac{1}{2} \sum_{j=1}^T \frac{\left(\sum_{i \in I_j} g_i\right)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (3.79)$$

XGBoost, hata oranlarını minimize eden gelişmiş optimizasyon mekanizmasına sahip olup, daha doğru ve güvenilir tahminler üretir. Büyük veri setlerinde hızlı ve verimli çalışabilen bu algoritma, ölçeklenebilir yapısıyla büyük çaplı makine öğrenimi problemlerinde etkili bir şekilde uygulanabilir. Ayrıca, L1 en küçük mutlak daraltma ve seçim operatörü ve L2 sırt düzenleme mekanizmaları sayesinde aşırı öğrenme riski azaltılarak modelin daha iyi genelleme yapması sağlanır. Ancak, XGBoost'un hiperparametre ayarları oldukça karmaşıktır ve aşırı optimize edilmesi durumunda modelin genelleme performansı düşebilmektedir (Hakkal ve Lahcen 2024).

3.8.2. Model entegrasyonu

Hibrit model, topluluk öğrenme teknikleri kullanılarak oluşturulmuştur. ROA ve XGBoost modellerinin güçlü yönleri birleştirilerek daha yüksek doğruluk oranı hedeflenmiştir. Ağırlık katsayıları, çapraz doğrulama sonuçlarına dayalı olarak iyileştirilmiştir. Hibrit model tahmini denklem 3.80 ile hesaplanmıştır:

$$y = \alpha \cdot \text{ROA}(x) + (1 - \alpha) \cdot \text{XGBoost}(x) \quad (3.80)$$

Burada:

$\text{ROA}(x)$: Rastgele orman tahmini,

$\text{XGBoost}(x)$: XGBoost'un tahmini,

$(1 - \alpha)$: XGBoost'un ağırlık katsayısıdır.

α : Rastgele orman algoritmasının ağırlık katsayısı, yani model kombinasyonundaki en yüksek başarıyı sağlayan optimum ağırlıktır. Denklem 3.81 ile hesaplanır.

$$\alpha = \frac{\text{ROA}_{\text{skoru}}}{\text{ROA}_{\text{skoru}} + \text{XGBoost}_{\text{skoru}}} \quad (3.81)$$

Burada α hesaplanırken performansa dayalı ağırlık hesaplama yöntemi kullanılabilir. Bu durumda ROA iyiye α 1'e yaklaşırken XGBoost iyiye α 0'a yaklaşır. Sistem dengeliye $\alpha \approx 0,5$ olur. Bayesian veya GA ile de belirlenebilse de bu çalışmada

ızgara arama kullanılmış ve α için optimizasyon yapılmıştır. Bu yapılırken kullanılan yaklaşım:

$$\alpha^* = \arg \max_{\alpha \in [0,1]} \text{Metrik}(\alpha \cdot \text{ROA}(x) + (1 - \alpha) \text{XGBoost}(x)) \quad (3.82)$$

Burada $[0,1]$ aralığındaki tüm olası α değerleri denenir. Her bir α için hibrit model tahminleri hesaplanır ve hangi α değeri modelin başarımını maksimum yapıyorsa o değer α^* olarak seçilir.

3.8.3. Hiperparametre optimizasyonu

Hibrit modelin performansını artırmak ve aşırı öğrenmeyi önlemek amacıyla hiperparametre optimizasyonu gerçekleştirilmiştir. Izgara arama ve Bayesian optimizasyon yöntemleri kullanılarak en iyi hiperparametre kombinasyonu belirlenmiştir. Izgara arama, önceden belirlenen hiperparametre kombinasyonlarını test ederken, Bayesian optimizasyonu, olasılıksal modeller kullanarak en uygun parametreleri belirlemektedir. Çizelge 3.3 ROA için optimize edilen hiperparametreleri, Çizelge 3.4 XGBoost için optimize edilen hiperparametreleri göstermektedir.

Çizelge 3.3. ROA için optimize edilen hiperparametreler

Parametre	Açıklama	Optimum Değer
n	Ağaç sayısı	150
Maks. derinlik	Maksimum ağaç derinliği	12
n. tahminci	Düğüm ayrımı için gerekli asgari gözlem sayısı	4
Min. örnek	Yaprak başına düğümde bulunması gereken minimum örnek	2
Maks.özellik	Bir bölünme için değerlendirilen maksimum özellik sayısı	karekök

Çizelge 3.4. XGBoost için optimize edilen parametreler

Parametre	Açıklama	Optimum Değer
n	Ağaç sayısı	300
Maks. derinlik	Maksimum ağaç derinliği	10
Öğrenme oranı	Öğrenme oranı	0,05
Min. ağırlık	Yaprak düğüm başına minimum ağırlık	1
Gamma	Ağaç budama için düzenleme parametresi	0
Alt örneklem	Rastgele veri oranı	0,8
Özellik sütun oranı	Her ağaç için girilen rastgele özellik oranı	0,7

Çizelge 3.5'te öncesi ve sonrası model performans kıyaslaması aşağıda verilmiştir.

Çizelge 3.5. Optimizasyon öncesi ve sonrası model karşılaştırması

Model	Doğruluk%	F1-Skor	AİK-EAA
ROA (Optimizasyon öncesi)	85,2	0,81	0,88
ROA (Optimizasyon sonrası)	86,6	0,85	0,91
XGBoost (Optimizasyon öncesi)	87,3	0,83	0,89
XGBoost (Optimizasyon sonrası)	90,1	0,87	0,93

3.9. Model Eğitimi ve Test Süreci

Bu bölümde, hibrit modelin eğitim, test ve doğrulama süreçleri detaylandırılmaktadır. Modelin performansını güvenilir şekilde değerlendirebilmek için veri bölünmesi, çapraz doğrulama, model eğitimi ve test süreci açıklanmıştır.

3.9.1. Çapraz doğrulama

MÖ modellerinin genellenebilirliğini değerlendirmek için k-katlı çapraz doğrulama yöntemi değerlendirilmiştir. Bu değerlendirme yoluyla k eşit parçaya veri setini böler. Her iterasyonda bir kısmını test, geri kalanını eğitim verisi olarak kullanır. Bu tez kapsamında $k = 5$ olarak seçilmiştir. Düşük varyans ve makul seviyede yanlılık arasında iyi bir denge sağlamıştır. k değerinin 5'ten büyük seçilmesi halinde hesaplama süresi artmakta ve verimlilik düşmektedir. Çapraz doğrulama modelin farklı veri bölümleriyle test edilmesini sağlayarak daha güvenilir bir değerlendirme sunar. Aşırı öğrenme riskini azaltır. Her örneğin eğitim ve test süreçlerinde en az bir kez kullanılması sağlanır. Her ne kadar hesaplama maliyetini artırsa da, modelin güvenilirliğini artırdığı için tercih edilmektedir (Herrmann ve Kollmannsberger 2024). Matematiksel olarak tanımlanırsa:

Veri kümesi "D":

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (3.83)$$

Bu küme k eşit parçaya bölünürse,

$$D = D_1 \cup D_2 \cup \dots \cup D_k \quad (3.84)$$

Her D_i çapraz doğrulamanın bir katı olur. Model değerlendirilmesi yapılırken her bir iterasyonda bir katman D_i doğrulama için ayrılır. Geri kalan katmanlar yani eğitim için $D_{-i} = D \setminus D_i$ kullanılır. Model D_{-i} üzerinde eğitilir ve D_i üzerinden test edilir.

$$\hat{f}_i = \text{eğit}(D \setminus D_i) \quad (3.85)$$

$$\text{Doğruluk}_i = \text{Değerlendir}(\hat{f}_i, D_i) \quad (3.86)$$

Genel performans skoru ise tüm katmanlardaki başarımların ortalamasıdır.

$$\text{Ortalama Performans} = \frac{1}{k} \sum_{i=1}^k \text{Skor}_i \quad (3.87)$$

3.9.2. Eğitim süreci

Hibrit modelin eğitim süreci Python programlama dili ve MÖ kütüphaneleri kullanılarak gerçekleştirilmiştir. Model eğitimi sürecinde aşağıdaki cihaz ve programlar kullanılmıştır.

Kullanılan yazılım Python 3.9+, Scikit-Learn ROA için, XGBoost Gradient Boosting için, Pandas veri işleme için, Numpy matematiksel işlemler için, Matplotlib ve Seaborn görselleştirme için kullanılmıştır. Donanım ise Intel i7-13700H, 2.40 GHz işlemci, 16 GB RAM, GPU hızlandırma NVIDIA RTX 3060'tır.

3.9.3. Model eğitimi

Model eğitimi, veri normalizasyonu, hiperparametre optimizasyonu, özellik seçimi ve çapraz doğrulama adımlarını içermektedir. Buna ek olarak, modelin eğitim aşamasında ağırlıklandırılmış bir kayıp fonksiyonu kullanılmıştır. Bu sayede, yıldırım olayının gerçekleştiği halde tahmin edilememesi gibi azınlık sınıfındaki hatalar daha yüksek bir maliyetle cezalandırılarak modelin bu tür hatalara karşı daha duyarlı olması sağlanmıştır.

XGBoost için Min-Max normalizasyonu uygulanmıştır. ROA modeli, ham verilerle çalıştırılmıştır. En iyi model yapılandırması için ızgara arama ve Bayesçi optimizasyon yöntemleri kullanılmıştır. 5-katlı çapraz doğrulama ile model test edilmiştir. Eğitim süreci GPU hızlandırması kullanılarak optimize edilmiştir. XGBoost için kullanılan Min-Max normalizasyon formülü denklem 3.88'de paylaşılmıştır.

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3.88)$$

Burada x normalizasyon uygulanacak değer, x' 0-1 arasındaki normalleştirilmiş değerler, $x_{\max}$ ilgili sütundaki maksimum değer, $x_{\min}$ ise ilgili sütundaki minimum değerdir. Izgara arama için kullanılan formül ise denklem 3.89'da paylaşılmıştır.

$$\theta^* = \arg \max_{\theta \in \Theta} \text{Skor}(M(x; \theta)) \quad (3.89)$$

Burada θ modelin n_{tahm} $\text{maks}_{\text{derinlik}}$ gibi hiperparametre vektörü, Θ denenecek tüm hiperparametre kombinasyonlarının kümesi diğer adıyla ızgara, $M(x; \theta)$ θ parametreleriyle eğitilmiş model, Skor ($\cdot$) F1-Skor, Doğruluk, AİK gibi performans metriği, $\arg \max$ ise en iyi sonucu sağlayan parametre setinin seçimidir.

Hiperparametre optimizasyonu sürecinde, geleneksel ızgara aramaya kıyasla daha az deneme ile daha iyi sonuçlar verebilen Bayesian optimizasyon yaklaşımı kullanılmıştır. Bu yöntem, daha önce denenmiş parametreler üzerinden bir olasılık modeli öğrenir ve bu modelden türetilen kazanç fonksiyonu aracılığıyla en verimli yeni deneme noktasını seçer. Denklem 3.90'da Bayesian optimizasyonun genel formülasyonu verilmiştir.

$$\theta^* = \arg \max_{\theta \in \Theta} \mathbb{E}_{p(f|\mathcal{D})}[\text{Kazanç}(\theta)] \quad (3.90)$$

Burada θ hiperparametre kombinasyonu, Θ aranacak hiperparametre uzayını, $\mathcal{D}$ şimdiye kadar denenmiş parametre ve sonuç çiftlerini, $Kazanç(\theta)$ yeni denenecek noktanın seçilmesini sağlayan kriterini, $\mathbb{E}$ beklenen değeri yani olasılıksal tahmini, $p(f | \mathcal{D})$ verilen gözlem parametrelerine göre ($\mathcal{D}$) modelin başarımlı fonksiyonel f hakkında sahip olunan olasılıksal tahmini simgeler.

3.9.4. Test süreci

Model eğitiminin tamamlanmasının ardından, genellenebilirlik ve güvenilirlik analizleri yapmak amacıyla test süreci uygulanmıştır. Test sürecinde kullanılan yöntemler ise eğitimde kullanılmayan %20'lik test verisi ile modelin doğruluk oranı ölçülmüştür. Ayrıca bağımsız veri setleri ile test edilmiştir. Bunun için 2023 yılına ait model eğitiminde kullanılmayan yeni yıldırım verileri kullanılarak model tekrar test edilmiştir. Sahadan tedarik edilen arıza verileriyle karşılaştırma yapılmıştır. YG hatları işletme operatörünce raporlanan gerçek arıza verileriyle model tahminleri kıyaslanmıştır. Bu süreçler sonucunda, modelin sahada başarılı tahminler yapabildiği gözlemlenmiştir.

3.10. Performans değerlendirme ve hata analizi

Elde edilen sonuçlar, modelin yalnızca arıza tahmininde değil, şebekeye yönelik bakım planlamalarında da kullanılabileceğini göstermektedir. Geliştirilen hibrit modelin başarısını değerlendirmek için kullanılan metrikler, modelin hata analizini ve farklı MÖ yöntemleriyle yapılan karşılaştırmaları da değerlendirmiştir. Bunun sonucunda doğru pozitif sınıfların ne kadarının doğru tahmin edildiğini göstermiştir.

3.10.1. Kullanılan metrikler

MÖ modellerinin performansını ölçmek için farklı metrikler kullanılmaktadır. Bu çalışmada, modelin tahmin doğruluğunu belirlemek için aşağıdaki metrikler tercih edilmiştir:

Çizelge 3.6. Kullanılan metriklere ait tablo

Metrik	Açıklama
Doğruluk	Modelin doğru tahmin oranını gösterir.
Kesinlik	Modelin pozitif tahminlerinin ne kadar doğru olduğunu gösterir.
Duyarlılık	Gerçek pozitif sınıfların ne kadarının doğru tahmin edildiğini gösterir.
F1-Skor	Kesinlik ve Doğruluk değerlerinin dengeli bir ortalamasıdır.
AİK-EAA	Tüm sınıflandırma eşiklerinde ne kadar başarılı olduğunu gösterir.

Metriklerin hesaplama formülleri Denklem 3.91-3.94'teki gibidir.

$$Doğruluk = \frac{DP + DN}{DP + DN + HP + HN} \quad (3.91)$$

$$Kesinlik = \frac{DP}{DP + HP} \quad (3.92)$$

$$Duyarlılık = \frac{DP}{DP + HN} \quad (3.93)$$

$$F1 - Skor = \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (3.94)$$

Burada:

- Doğru Pozitif (DP): Modelin doğru şekilde pozitif tahmin ettiği örnekler
- Doğru Negatif (DN): Modelin doğru şekilde negatif tahmin ettiği örnekler
- Hatalı Pozitif (HP): Modelin yanlışlıkla pozitif tahmin ettiği örnekler
- Hatalı Negatif (HN): Modelin yanlışlıkla negatif tahmin ettiği örneklerdir.

Modelin hata oranlarını anlamak ve iyileştirme alanlarını belirlemek amacıyla detaylı bir hata analizi gerçekleştirilmiştir.

3.10.2. Hatalı pozitif ve hatalı negatif oranlarının azaltılması

Modelin hatalı pozitif ve hatalı negatif yanlışlarını azaltmak amacıyla çeşitli iyileştirme stratejileri uygulanmıştır. Başlıca stratejiler arasında, veri dengesizliğini gidermeye yönelik örnekleme teknikleri, eğitimde ağırlıklandırılmış bir kayıp fonksiyonu kullanılması, sınıflandırma eşik değerinin optimize edilmesi ve 5 kA altındaki düşük şiddetli yıldırım olaylarının analiz dışında tutulması sayılabilir.

Öncelikle, dengesiz sınıf dağılımının model üzerindeki etkisini azaltmak için SMOTE uygulanmıştır. SMOTE yöntemi, azınlık sınıfa ait sentetik örnekler üretip veri setine ekleyerek sınıflar arası dengesizliği giderir. Bu sayede model, nadir görülen yıldırım olaylarını daha fazla örnek üzerinden öğrenme imkânı bulmuş ve bu durum hatalı negatif sayısının azalmasına katkı sağlamıştır.

Azınlık sınıfın çoğaltılmasına ek olarak, çoğunluk sınıfa ait örnekler de alt örnekleme yöntemiyle seyreltilmiştir. Veri setindeki baskın sınıf örneklerinin kontrollü biçimde azaltılması, modelin eğitiminde sınıflar arası dengenin sağlanmasına yardımcı olmuştur. Bu yaklaşım, modelin çoğunluk sınıfa aşırı uyum sağlamasını engelleyerek hatalı negatifleri azaltmaya katkı sunarken, aynı zamanda aşırı sayıda gereksiz pozitif tahmin yapılmasının da önüne geçmeyi hedeflemiştir.

Buna ek olarak, modelin eğitim aşamasında ağırlıklandırılmış bir kayıp fonksiyonu kullanılmıştır. Bu sayede, azınlık sınıfındaki yıldırım olayının gerçekleştiği halde tahmin edilememesi durumu eğitim sırasında daha yüksek bir maliyetle

cezalandırılarak modelin bu tür hatalara karşı daha duyarlı olması sağlanmıştır. Kullanılan ağırlıklı ikili çapraz entropi fonksiyonu Denklem 3.95'teki gibidir:

$$L = -\frac{1}{N} \sum_{i=1}^N [w_+ \cdot y_i \cdot \log(\hat{y}_i) + w_{-(1-y_i)} \cdot \log(1 - \hat{y}_i)] \quad (3.95)$$

Burada y_i gerçek etiket; $\hat{y}_i$ modelin tahmin ettiği olasılık, w_+ pozitif sınıf ağırlığı, w_- negatif sınıf ağırlığıdır. Bu sayede yıldırım arızalarında pozitif sınıfa daha fazla önem atfedilerek HN oranı düşürülmüştür.

Tahmin sonuçlarının yorumlanmasında sınıflandırma eşiği de optimize edilmiştir. Varsayılan olarak 0,5 olan olasılık eşik değeri, hatalı negatifleri azaltmak amacıyla daha düşük bir değere ayarlanmıştır. Böylece model, sınır vakalarda pozitif sınıfı işaretlemeye daha yatkın hale getirilmiş, bu da gerçek yıldırım olaylarının kaçırılma olasılığını azaltmıştır. Bunun sonucu olarak hatalı negatif sayısı azalırken, kaçınılmaz bir şekilde belli ölçüde artan hatalı pozitif sayısı da kabul edilebilir bir düzeyde tutulmuştur.

5 kA'nın altındaki yıldırım darbeleri analiz kapsamı dışında bırakılmıştır. Düşük akım şiddetli yıldırım olaylarının iletim hattı üzerinde kayda değer bir etki oluşturmadığı ve model açısından gürültüye sebep olabileceği öngörülmüştür (Hamel vd. 2025). Bu nedenle veri setine yalnızca 5 kA ve üzeri yıldırım vakaları dâhil edilmiş, daha zayıf sinyallerin neden olabileceği hatalı pozitif sınıflandırma ve kaçırma sorunlarının önüne geçilmeye çalışılmıştır. Bu seçici veri kullanımı, modelin önemli olaylara odaklanarak daha tutarlı tahminler yapmasına yardımcı olmuştur. Hatalı pozitif ve hatalı negatif adetlerini ve oranlarını açıkça gösteren bir performans tablosu Çizelge 3.7'de sunulmuştur:

Çizelge 3.7. Hibrit Modelin Karışıklık Matrisi ve Temel Metrikleri

	Tahmin: Arıza var	Arıza yok
Gerçek: Arıza	DP: 645	HN:68
Gerçek: Arıza yok	HP:52	DN:894

Çizelge 3.7'den görüldüğü üzere, model toplamda 645 doğru pozitif tahminde bulunmuş, sadece 68 vakada yıldırım kaynaklı arızaları atlamıştır (HN). Ayrıca 52 durumda gereksiz alarm verilmiş (HP), ancak modelin genel başarımı oldukça yüksektir.

Yapılan incelemeler sonucunda modelin yanlış tahmin yaptığı örnekler analiz edilmiş ve hata oranlarını artıran başlıca faktörler belirlenmiştir. Öncelikle, modelin belirli bir eşik değerinin altındaki yıldırımları riskli olarak görmemesi, bazı hatalı negatif sonuçlara yol açmıştır. Bu hatayı minimize etmek için 5 kA altı yıldırımlar modele dahil edilmemiştir. Ayrıca, yıldırım düşmesi ile arıza oluşumu arasında gecikmeli bir ilişki olabilmektedir. Modelin bu ilişkiyi doğru şekilde yakalayabilmesi için veri seti zaman

farkı analizine tabi tutulmuş ve veriler senkronize edilerek olası yanlış tahminlerin önüne geçilmiştir. Bunun yanı sıra, direk tipi, izolatör özellikleri ve topraklama direnci gibi mühendislik değişkenlerinin model tahminlerindeki etkisi daha iyi analiz edilmelidir. Bu değişkenlerin önemini ölçmek için SHAP analizi ile modelin hangi değişkenlere daha duyarlı olduğu belirlenmiştir. Modelin yaptığı hatalı pozitif ve hatalı negatif analizleri sonucu, bazı yıldırım olaylarının arıza olarak tahmin edildiği ancak sahada herhangi bir arıza meydana gelmediği tespit edilmiştir. Bu hatanın başlıca nedenleri arasında yıldırım sonrası bakım çalışmaları, topraklama iyileştirmesi veya izolatör ilavesi gibi bölgesel koruma önlemleri bulunmaktadır. Bu nedenle, bu tür veriler modelin eğitim setinden çıkarılarak tahmin doğruluğunun artırılması sağlanmıştır. Ayrıca, modelin bazı gerçek arızaları tespit edemediği belirlenmiştir. Yapılan incelemeler sonucunda, bu hatanın temel nedeninin eksik veya temizlenmemiş veriler olduğu belirlenmiştir. Bu tür verilerin modelin eğitim sürecine dahil edilerek tahmin başarısını olumsuz etkilediği tespit edildiğinden, eksik ve düzensiz veriler setten temizlenmiştir. Son olarak, tespit edilen bu hata kaynaklarını azaltmak için, özellik mühendisliği ve hiperparametre optimizasyonu süreçlerinde çeşitli iyileştirmeler yapılmıştır. Böylece, modelin hatalı pozitif ve hatalı negatif tahmin oranları düşürülmüş, genel tahmin doğruluğu artırılmıştır.

3.10.3. Diğer algoritmalarla karşılaştırma

Geliştirilen hibrit modelinin başarısını test etmek için farklı MÖ algoritmaları ile kıyaslama yapılmıştır. Karşılaştırılan yöntemler ise KNN, DVM, YSA, GA, LR, ROA, XGBoost'tur. Model performanslarının karşılaştırılması için Doğruluk, Kesinlik, Duyarlılık, F1-Skor ve AİK-EAA metrikleri hesaplanmıştır.

Çizelge 3.8'de sunulan değerlendirmede Hibrit model, tüm algoritmalarla kıyasla en yüksek doğruluk oranına sahiptir (%94,3). Tek başına kullanılan ROA ve XGBoost modelleri başarılı olsa da hibrit modelin kombinasyonu daha iyi sonuçlar vermiştir. YSA ve DVM gibi yöntemler de iyi sonuçlar üretmiştir, ancak hibrit model kadar yüksek doğruluk elde edememiştir. GA ve LR, özellikle doğrusal olmayan ilişkileri öğrenmede yetersiz kalmıştır (Özdemir 2017). Bu sonuçlar, farklı algoritmaların güçlü yönlerini birleştiren hibrit modellerin daha başarılı olabileceğini göstermektedir.

Çizelge 3.8. Farklı Algoritmaların Karşılaştırılması

Model	Doğruluk%	Kesinlik%	Duyarlılık%	F1-Skor%	AİK-EAA%
KNN	82,3	79,5	80,1	79,8	83,2
DVM	85,1	82,6	83,9	83,2	86,5
YSA	87,4	85,2	86,7	85,9	88,3
GA	81,2	78,8	79,4	79,1	82,1
LR	78,6	75,5	76,9	76,2	80,5
ROA	89,2	87,8	88,5	88,1	90,4
XGB	91,0	89,6	90,2	89,9	92,1
Hibrit Model	94,3	92,5	93,8	93,1	95,4

3.11. Etik ve Çalışma Sınırlılıkları

Bu bölümde, çalışmanın etik boyutları, veri gizliliği konuları ve modelin sınırlılıkları ele alınmıştır.

3.11.1. Etik konular ve veri gizliliği

Veri toplama ve analiz sürecinde, yetkili kurumların onayı alınmış; kişisel veri içermeyen, anonimleştirilmiş veri kullanılmıştır. Kişisel veri içermeme ilkesi kapsamında, çalışmada EİH adı, koordinat bilgisi bulunmamaktadır. Bu tez çalışmasında önerilen modelin kullanım amacı, yalnızca EİH’de yıldırım kaynaklı arızaları tahmin etmek ile sınırlıdır.

3.11.2. Modelin coğrafi ve teknik sınırlılıkları

Hibrit modelin performansı yüksek olmasına rağmen, bazı kısıtlamalar bulunmaktadır. Bunların başında bölgesel sınırlamalar gelmektedir. Model, Antalya bölgesindeki EİH’leri için eğitilmiş ve test edilmiştir. Çok yüksek rakımlı veya sanayi bölgelerinde kirlilik vb. gibi farklı iklim koşullarına ve çevresel şartlara sahip bölgelerde modelin doğrudan uygulanabilirliği test edilmemiştir. Modelin Türkiye’nin diğer bölgelerinde de test edilmesi gerekmektedir.

Veri kapsamı ve kalitesi açısından bakıldığında, kullanılan veri seti 2015-2022 yılları arasındaki yıldırım ve arıza verilerini içermektedir. Eksik veya yanlış raporlanmış arıza verileri, modelin hata oranını artırabilir. Daha geniş veri setleri kullanılarak modelin doğruluğu artırılabilir.

Gerçek zamanlı uygulama konusunda, mevcut model geriye dönük verilerle eğitildiği için gerçek zamanlı tahmin yeteneği henüz test edilmemiştir. Gerçek zamanlı veri akışı entegrasyonu yapılarak anlık tahminlerin yapılması mümkündür. Bu noktada Meteoroloji istasyonları ve EİH’leriyle veri entegrasyonu sağlanarak modelin gerçek zamanlı tahmin yapabilmesi planlanabilir.


4. BULGULAR

4.1. Veri Setinin Görselleştirilmesi ve Ön Analiz

Veri setinin daha iyi anlaşılması ve model performansının iyileştirilmesi amacıyla çeşitli görselleştirme teknikleri kullanılmıştır. Kullanılan yöntemler alt başlıklarda paylaşılmıştır.

4.1.1. Korelasyon matrisi ve analizi

Korelasyon analizi sonucunda, yıldırım akımı ve topraklama direnci arasındaki ilişkinin doğrusal olmadığı, bu nedenle modelin yalnızca korelasyon katsayılarına dayalı olarak değerlendirilmemesi gerektiği tespit edilmiştir. Veri setindeki değişkenlerin birbirleriyle olan ilişkisini analiz etmek için bir korelasyon matrisi oluşturulmuştur. Cihan ve Coşkun (2021), doğrusal ilişkilerin ötesine geçebilmek için karşılıklı bilgi ölçütü analizinin kullanılmasını önermektedir.




Şekil 4.1. Korelasyon matrisi ile değişkenler arasındaki bağıntı analizi.

4.1.2. Yoğunluk grafikleri ile değişken dağılımı

Yıldırım akımının arıza durumu üzerindeki etkisini daha iyi analiz edebilmek için farklı akım aralıklarında gruplama yapılarak yoğunluk analizi gerçekleştirilmiştir. Sonuçlar, 30 kA ve üzeri yıldırım akım seviyelerinde arıza oranlarının belirgin şekilde arttığını göstermektedir. Yıldırım akımının açma durumu ile olan ilişkisini incelemek için


Kernel yoğunluk tahmini grafikleri kullanılmıştır. Şekil 4.2’de Kernel yoğunluk grafiği sunulmuştur.



Şekil 4.2. Yıldırım akımı ve arızadan açma durumu yoğunluk grafiği.

4.1.3. 3 boyutlu saçılım değerlendirmesi


Yıldırım akımı, topraklama direnci ve izolatör boyu değişkenleri arasındaki ilişki 3 boyutlu saçılım grafiği ile Şekil 4.3’te incelenmiştir. Kırmızı noktalar *arıza var* durumunu, mavi noktalar ise *arıza yok* durumunu temsil etmektedir. Saçılım değerlendirmesine ilişkin bulgular Şekil 4.3’te verilmiştir.



Şekil 4.3. Yıldırım, direnç ve izolatör boyu arasındaki ilişki.

4.1.4. Histogramlar ile değişkenlerin dağılımı

Veri setindeki yıldırım akımı ve topraklama direnci değişkenleri sağa çarpık bir dağılım göstermekte olup, medyan değerleri ortalamalarından daha küçüktür. Aşırı uç değerlerin etkisini azaltmak için logaritmik dönüşüm uygulanmıştır. Histogram analizi, modelin hangi değişkenlere daha hassas tepki verdiğini ortaya koymuştur. Model, yüksek yıldırım şiddetli verileri uç değer olarak algılayarak tahmin sürecinde dikkatli değerlendirmektedir.



Şekil 4.4. Histogram değerlendirme grafikleri.

4.2. Modelin Eğitilmesi ve Test Edilmesi

Bu bölümde geliştirilen hibrit model eğitilmiş ve test edilmiştir. Modelin başarısını artırmak için veri bölünmesi, dengeli veri seti oluşturma, çapraz doğrulama, hiperparametre optimizasyonu ve performans değerlendirme süreçlerine ilişkin bulgular paylaşılmıştır.

4.2.1. Veri bölünmesi


Veri seti, modelin aşırı öğrenmesini önlemek ve genelleştirme performansını artırmak amacıyla %80 eğitim- %20 test olarak ikiye ayrılmıştır. Eğitim setinde 568 arıza kaydı, test setinde 142 arıza kaydı bulunmaktadır. Ancak, sınıf dengesizliği problemi nedeniyle modelin hatalı negatif oranının yüksek olabileceği göz önüne alınmıştır. Bu dengesizliği gidermek amacıyla, azınlık sınıfa ait örneklerin sentetik olarak çoğaltıldığı SMOTE yöntemi uygulanmıştır. SMOTE yönteminde azınlık sınıfındaki örnekleri sentetik olarak artırarak modelin daha dengeli öğrenmesini sağlamıştır. Arıza kaydı sayısını artırarak modelin hatalı negatif oranını düşürmüştür.

4.2.2. Model performans değerlendirme metrikleri

Model performansı; doğruluk, kesinlik, duyarlılık, F1 skoru ve AİK eğrisi gibi temel metriklerle değerlendirilmiştir. Karışıklık matrisi kullanılarak modelin hatalı pozitif ve hatalı negatif oranları analiz edilmiştir. AİK-EAA Eğrisi, modelin sınıflandırma performansını ölçmek amacıyla çizilmiştir. Sonuçlar altta verilmektedir:

- ROA doğruluk oranı: %90,85
- XGBoost doğruluk oranı: %87,32
- Hibrit model doğruluk oranı: %92,96

Oluşturulan modelin performans değerlendirme metrikleri Doğruluk, Kesinlik, Hassasiyet, Duyarlılık ve F1-Skor'dur. Şekil 4.5'te ROA ve XGBoost'a ait karışıklık matrisi bulunmaktadır.



Şekil 4.5. ROA ve XGBoost Karışıklık matrisi.


ROA doğruluk oranı %90,85 iken XGBoost doğruluk oranı %87,32'de kalmıştır. Bu farkın temel nedeni, ROA algoritmasının aşırı öğrenmeyi daha iyi önleyebilmesi ve özellikle gürültülü verilerde daha genelleştirilebilir tahminler yapabilmesidir (Breiman 2001). XGBoost ise daha hızlı bir hata azaltma yöntemi kullandığından, belirli senaryolarda daha düşük genelleme performansı gösterebilir. Karışıklık matrisi, tahmin hatalarının türlerini ve dağılımını görselleştirerek karşılaştırma yapılmasına olanak sağlar.

ROA ve XGBoost için doğruluk, kesinlik, duyarlılık ve F1-Skor çizelge 4.1'de verilmektedir. Bu karşılaştırmaya göre yıldırım tahmininde çok az farkla ROA, XGBoost'a göre üstünlük sağlamaktadır. Breiman (2001) çalışmasında vurguladığı gürültülü verilerde daha iyi genelleştirme yapıyor olması bu noktada ortaya çıkmaktadır.


Çizelge 4.1. ROA ve XGBoost karşılaştırması

	Doğruluk	Kesinlik	Duyarlılık	F1-Skor
ROA	0,9014	0,91	0,9479	0,9286
XGBoost	0,8873	0,9082	0,9271	0,9175

EAA-AİK ve doğruluk analizine ilişkin veriler Şekil 4.6’da paylaşılmıştır. Buna göre ROA %94,54 iken XGBoost %93,73’e ulaşmış ve aralarında neredeyse hiç fark bulunmamaktadır.

**Şekil 4.6.** AİK-EAA eğrisi ve doğruluk analizi.

ROA ve XGBoost’un özellik karşılaştırması Şekil 4.7’de verilmektedir. EAA değeri %94’ün üzerine çıkmıştır. Tabloda verilmeyen diğer özelliklerin etkisi önemsizlenecek kadar düşük olduğu için eklenmemiştir.




Şekil 4.7. ROA ve XGBoost önem özellik karşılaştırması.

4.2.3. Aşırı öğrenme analizi

Modelin genel doğruluğunu artırmak amacıyla, belirli aralıklar için ağırlıklı kayıp fonksiyonları kullanılmış ve düşük akım seviyelerindeki hatalı negatif oranları azaltılmaya çalışılmıştır. MÖ modellerinde aşırı öğrenme problemi, modelin eğitim verisinde çok iyi sonuç verirken test verisinde düşük performans göstermesine neden olabilir. Öğrenme eğrisi analizi sonucunda eğitim doğruluğu, test doğruluğundan büyük olduğu gözlenmiş ve farkı incelenmiştir. Aşırı öğrenmenin önüne geçmek için L1 ve L2 düzenlemeleri uygulanmıştır. L1, L2 parametreleri optimize edilerek modelin genelleştirme kapasitesi artırılmıştır. Sonuç olarak, modelin test doğruluğu %91,55 seviyesine çekilerek daha genelleştirilebilir bir yapı elde edilmiştir.

Eğer model aşırı uyumluluk yapıyorsa, eğitim seti doğruluk oranı yüksek ancak test seti doğruluk oranı düşük olur (Merkulov ve Oseledets 2019). Eğitim ve test doğruluk oranlarını farklı eğitim veri büyüklükleri için çizerek aşırı uyum olup olmadığını anlamak için öğrenme eğrisi kullanılmıştır. Şekil 4.8 (a)'da bu durum az olsa da (%6) gözlenmektedir. Bunun için L1/L2 düzenlemesine gidilmiştir. Bunu sonucu Şekil 4.8(b)'de %1,8'e kadar fark düşmüştür.




Şekil 4.8. (a) Aşırı öğrenme kontrolü, (b) L1/L2 düzenlemesi sonrası.

4.3. Hibrit Model ile Karşılaştırmalar

Bu bölümde geliştirilen hibrit model diğer MÖ algoritmaları ile karşılaştırılmıştır. Amaç, hibrit modelin tek başına kullanılan yöntemlere kıyasla ne kadar başarılı olduğunu ölçmektir.


4.3.1. ROA ve XGBoost birleşiminin etkisi

Hibrit model, ROA ve XGBoost'un avantajlarını birleştirerek arıza tahmininde daha yüksek doğruluk sağlamaktadır. Optimizasyon sonrası sonuçlara göre ROA doğruluk oranı %90,85, XGBoost doğruluk oranı %87,32 iken Hibrit Model doğruluk oranı %92,96'dır. En iyi ağırlık kombinasyonu (ROA: %60, XGBoost: %40) bu doğrulukla elde edilmiştir. Bu sonuçlara göre Hibrit model, tek başına ROA veya XGBoost modellerinden daha yüksek doğruluk oranı sağlamıştır.



Şekil 4.9. Hibrit model karışıklık matrisi.

Şekil 4.10’da görülen hibrit modelin hatalı pozitif oranı ile doğru pozitif oranları arasında oluşturulan AİK eğrisi paylaşılmış olup 0,95 gibi oldukça yüksek bir sonuç elde edilmiştir.



Şekil 4.10. Hibrit model AİK-EAA görseli.

Hiperparametre optimizasyonu ve model entegrasyonu kapsamında yapılan çalışmalar doğrultusunda, Bayessian optimizasyonu, ızgara arama, min-maks normalizasyonu ve performansa dayalı çalışmalar yapılmıştır. Bunların sonucunda en yüksek doğruluk değerini, AİK oranını veren 0,65 ağırlık katsayısı seçilmiş ve hibrit modelde kullanılmıştır. Bu duruma ilişkin sonuçlar Çizelge 4.2’de paylaşılmıştır.

Çizelge 4.2. Eşik değere göre duyarlılık tablosu

Eşik değeri	FP Sayısı	FN Sayısı	Doğruluk	Kesinlik	Duyarlılık	F1-Skor
0,50	73	91	0,895	0,88	0,88	0,88
0,60	58	77	0,910	0,90	0,91	0,905
0,65	52	68	0,9296	0,92	0,91	0,915
0,70	41	86	0,920	0,94	0,89	0,915


4.3.2. Diğer makine öğrenimi algoritmaları ile karşılaştırmalar

Bu tez kapsamında Çizelge 4.3’te de verilen MÖ algoritmaları eğitilmiş ve test edilmiştir. Elde edilen sonuçlara göre, Hibrit Model diğer tüm algoritmalarından daha yüksek performans göstermiştir.


Çizelge 4.3. Seçilen modellerin karşılaştırmalı tablosu

Model	Doğruluk	EAA	Kesinlik	Duyarlılık	F1-Skor
ROA	0,9085	0,93	0,91	0,89	0,90
XGBoost	0,8732	0,91	0,88	0,86	0,87
KNN	0,8250	0,87	0,83	0,80	0,81
ANN	0,8450	0,88	0,85	0,83	0,84
DVM	0,8325	0,86	0,82	0,81	0,81
LR	0,8100	0,84	0,81	0,79	0,80
GA	0,8500	0,89	0,86	0,84	0,85
Hibrit Model	0,9296	0,95	0,92	0,91	0,915

Şekil 4.11’de sunulan AİK eğrileri, modellerin sınıflandırma performansını doğrudan görsel olarak karşılaştırmaktadır. Hibrit Model, Şekil 4.10’dan da görüleceği üzere AİK eğrisi altında kalan alan bakımından 0,95 AİK ile diğer tüm algoritmalarından daha yüksek performans göstermiştir.

**Şekil 4.11.** Tüm modeller için AİK Eğrisi.


Tüm modellerin doğruluk oranları şekil 4.12’de görselleştirilmiştir. Hibrit Model %92,96 doğruluk oranı ile en yüksek performansı göstermektedir. ROA ve XGBoost modelleri de yüksek başarı sağlamıştır. KNN, DVM ve LR modelleri, bu veri setinde daha düşük performans göstermiştir. GA optimizasyonu ile doğruluk artışı sağlanabilir, ancak bu veri setinde hibrit model daha başarılıdır.



Şekil 4.12. Tüm modellerin doğruluk oranı karşılaştırma tablosu.


4.4. Modelin Baskın ve Çekinik Yönleri

Bu kısımda, geliştirilen hibrit modelin avantajları ve sınırlılıkları ele alınarak, modelin performansını etkileyen faktörler değerlendirilmiştir. Şekil 4.13'ten görüleceği üzere model büyük oranda hatasız çalışmaktadır. Eğitim setinde mavi olarak gösterilen modelin çoğu tahmini doğru yapılmış, model eğitim setinde çok iyi performans göstermiş ancak test verilerinde eğitim setine göre daha yüksek hata oranı gözlenmiştir. Bu durumun çözümü için L1/L2 düzenleme gerekmektedir. Bu durum değerlendirildiğinde hibrit modelin doğruluk oranı %91,55 e düşmektedir. Bu da tekrar düzenlemenin modeli daha genelleştirici hale getirdiğini ve aşırı öğrenmeyi önlediğini göstermiştir.



Şekil 4.13. Modelin hata dağılımı

Şekil 4.14'te yer alan SHAP önem grafiğinde görüldüğü üzere, model özellikle yüksek Yıldırım akımı değerlerine duyarlıdır. Bu, modelin yıldırım çarpmasının açma durumuna etkisini iyi öğrendiğini göstermektedir. Ancak gerilim değişkeni, modelin tahminlerine daha az etki eden bir değişken olarak belirlenmiştir. Diğer değişkenlerin mevcut verilere göre etkisi çok düşük olduğu için dahil edilmemiştir.



Şekil 4.14. SHAP özellik önem grafiği.

Modelin hangi değişkenlere dayalı karar verdiği açıkça analiz edilmiştir. Yüksek doğruluğun yanında modelin olmazsa olmazı düşük hata oranıdır. Hatalı pozitif ve hatalı negatif oranları diğer yöntemlere göre daha düşük seviyede kalmıştır. Özellikle 40-100 kA yıldırım akımı seviyelerinde modelin tahmin başarısı yüksektir.

4.4.1. Model gelişimi için atılan adımlar

Özellik mühendisliği ve yeni değişkenler ile yeni türev değişkenler oluşturulmuştur. Örneğin yıldırım akımı $\times$ topraklama direnci çarpımı, bu noktada eklenmiştir. İlave olarak yıldırımın çarpma açısı, yoğunluğu ve tekrarlanma süresi gibi ek değişkenler kullanılabilir. Ayrıca öznitelik dönüşümü ve seçimi iyileştirilmiştir. Bunun için kategoriye dönüştürme, etiket kodlama ve tekil kodlama gibi teknikler ile değişkenlerin temsili güçlendirilmiştir. Şekil 4.15'te güçlendirilmiş modele ilişkin yeni doğruluk oranı ve karışıklık matrisi verilmiştir.

Karışıklık Matrisi - Güçlendirilmiş Model	
Gerçek Sınıf	Negatif
	Pozitif
Tahmin Edilen Sınıf	Negatif
	Pozitif

Şekil 4.15. Güçlendirilmiş modele ilişkin karışıklık matrisi.

4.5. Hata Analizi ve İyileştirme Önerileri


Bu bölümde, modelin hata yapma eğilimleri, yanlış tahminlerin etkisi ve iyileştirme stratejileri ele alınmıştır.

4.5.1. Modelin en yüksek doğruluk sağladığı senaryolar

Modelin en yüksek isabetle çalıştığı koşullar aşağıda sıralanmıştır:

- Yıldırım Akımı (40-100 kA) aralığında modelin doğruluk oranı oldukça yüksektir.
- Topraklama Direnci (50-100 Ω) seviyelerinde modelin tahminleri daha güvenilirlerdir.
- İzolatör uzunluğu 1250-1500 mm olduğunda model en iyi sonuçları vermektedir.


Bu durumların tamamında arızadan hattın açması çok yüksek oranda doğru tahmin edilmiştir. Gerilim değişkeninin model performansına etkisi düşüktür; model, bu değişken olmadan da güçlü tahminler yapabilmektedir. Modelin güncellenmiş doğruluk performansı şekil 4.16'da görülmekte olup, en yakın algoritma ROA 0,9085'lik skora sahiptir. Bu durumu sırasıyla YSA ve XGBoost takip etmektedir.



Şekil 4.16. Model doğruluk oranı karşılaştırması.


4.5.2. Modelin hatalı tahmin yaptığı durumların analizi

Modelin hata analizi sonucunda, en çok hatalı negatif tahminlerin düşük akım seviyelerinde gerçekleştiği tespit edilmiştir. Bu durum, yıldırım çarpmasının şebeke üzerindeki etkisinin yalnızca akım büyüklüğüne bağlı olmadığını göstermektedir. Hatalı Pozitif modelin arıza tahmini yapıp aslında arıza olmaması durumudur. Topraklama direnci 150Ω 'un üzerine çıktığında bu hatalar artmaktadır. 5-10kA hatalı negatif gerçek bir arızanın model tarafından gözden kaçırılması durumu bulunmaktadır. Düşük akım seviyelerinde modelin hatalı negatif tahmin oranı yüksektir. 400 kV hatlarında hatalı negatif tahmin oranı nispeten artmıştır. Topraklama direnci 150Ω 'un üzerine çıktığında, model normal durumları da hatalı şekilde arıza olarak tahmin edebilmektedir. İzolatör uzunluğu 3000 mm gibi değerlere ulaştığında, modelin doğruluk oranı düşmektedir. Bu durumun temel sebebi 400 kV hatlarda yeterli sayıda arıza kaydı bulunmamasıdır. Arıza olmayan ancak yüksek yıldırım akımına sahip noktalar model tarafından yanlış tahmin edilebilmektedir. Bu durumlara ilişkin duyarlılık – kesinlik eğrisi Şekil 4.17'de yer almaktadır.



Şekil 4.17. Hibrit modele ilişkin duyarlılık – kesinlik eğrisi.

Şekil 4.18'de sunulan SHAP etki analizi incelendiğinde, modelin tahminlerinin değişkenlere göre nasıl farklılık gösterdiği belirlenmiştir. Yıldırım akım değeri arttıkça modelin arıza tahmini yapma olasılığı artmaktadır. Özellikle 40 kA ve üzerindeki değerler, modelin yüksek olasılıkla *açma* tahmini yapmasına neden olmaktadır. Direnç değişkeni, modelin tahminlerinde kritik bir rol oynamaktadır. Direnç değerinin 200 Ω 'un üzerine çıkması, modelin *arıza* tahminine yönelmesini sağlamaktadır. İzolatör boyu ve gerilim değişkenleri, modelin tahminlerine daha sınırlı bir etki yapmaktadır. Ancak, bazı istisnai durumlarda gerilim değişiminin model çıktısını etkilediği gözlemlenmiştir.




Şekil 4.18. SHAP etki analizi (Arı sürüsü grafiği).

4.5.3. Alternatif özellik mühendisliği yaklaşımı


Bu bölümde, modelin doğruluk oranını artırmak için yeni özellikler oluşturma, dönüşüm teknikleri ve farklı öznitelik mühendisliği yöntemleri ele alınmıştır. Şekil 4.19'da Yıldırım akımı $\times$ topraklama direnci çarpımı gibi türetilmiş değişkenler oluşturularak modelin tahmin gücü artırılmıştır. Mevsimsel ve coğrafi faktörler

eklenerek, yıldırım olaylarının zaman içindeki etkileri daha iyi modellenerek alternatif çalışmalara ulaşılabilir.



Şekil 4.19. Seçili değişkenler için korelasyon matrisi.

Yeni üretilen özelliklerin model performansı üzerindeki etkisini belirlemek için özellik önem sıralamaları çıkarılmıştır. Şekil 4.20’de ROA ve XGBoost algoritmaları için yeni özelliklerin önem düzeyi gösterilmektedir. Özellikle yıldırım akım şiddeti, topraklama ve izolatör boyu değişkenlerinin modelin tahmin gücünü artırdığı tespit edilmiştir. Hibrit modelin genel performansı, yeni özelliklerin eklenmesiyle birlikte iyileşmiştir. Şekil 4.15’teki korelasyon analizi değerlendirildiğinde yıldırım şiddeti ile direnç arasında pozitif korelasyon bulunmaktadır. Özellikle modelin eğitim sürecinde, yıldırım şiddeti ve direnç arasındaki bu ilişki, modelin hatalı negatif tahmin oranlarını düşürmeye yardımcı olmuştur. Bu bulgu, modelin yıldırım kaynaklı arızaları daha hassas bir şekilde tahmin edebilmesini sağlamaktadır.



Şekil 4.20. Yeni özelliklerin model performansına etkisi grafiği.

4.6. Güncel Verilerle Arıza Analizi

Bu bölümde, geliştirilen hibrit modelin 2023 yılına ait 20 yıldırım verisi ile test edilerek nasıl çalıştığı, modelin anlık gelen verilerle test edilmesi ve uygulama senaryoları ele alınmaktadır. Modelin, EİH'lerine düşen yıldırımların anlık tahminini yapmak üzere nasıl optimize edildiği açıklanarak saha kullanımı için öneriler sunulmuştur. Bunun için model uygulama haline getirilip hangi modda kullanılacağı seçilebilir.

4.6.1. Modelin güncel zamanlı kullanımı

Hibrit modelin güncel zamanlı tahmin yapabilmesi için belirli veri girişlerinin sağlanması gerekmektedir. Model, yıldırım darbesi ile EİH'deki arızalar arasındaki ilişkiyi değerlendirerek olasılıksal bir tahmin üretmektedir. Arıza sürecine ilişkin tahmin model giriş değişkenlerinin manuel ya da otomatik olarak girilmesiyle çalışmaktadır. Veri ister noktasal bazda istenirse de tüm verilerin toplu halde *.csv dosyasından okunmasıyla çalışmaktadır. Örnek çalışmada girilen veriler yıldırım akımı, topraklama direnci, izolatör boyu ve hat gerilimidir. Modelin anlık tahmin üretmesi *Arıza Olur (1)* veya *Arıza Olmaz (0)* şeklindedir. *Arıza olur* sonucu, EİH'ye yıldırım düşmesi sonucu hattın enerjisiz kalması diğer sonuç ise yıldırım düşmesi sonucu EİH'de arıza olmayacağı anlamına gelmektedir.

Güncel zamanlı tahmin için yazılım eklentisiyle önceden eğitilmiş hibrit model kullanmaktadır. Modelin karar eşiği, Youden İndeksi kriterine göre optimize edilen 0,65 değeri olarak sabitlenmiştir. Bu eşik değeri, AİK eğrisi üzerinde en iyi duyarlılık ve özgüllük dengesini sağlayan Youden İndeksi $J = \text{Duyarlılık} + \text{Özgüllük} - 1$ kriterine göre optimize edilmiştir. Yapılan analizlerde J değeri en yüksek olan noktanın 0,65 eşiğine karşılık geldiği Çizelge 4.2'den de görüleceği üzere tespit edilmiştir. Bu nedenle, karar eşiği bu değerde sabitlenmiş ve özellikle kritik arıza durumlarının gözden kaçırılmasının (FN) önüne geçilmiştir.

⚡ Yıldırım Akımı (kA): 45	⚡ Yıldırım Akımı (kA): 100	⚡ Yıldırım Akımı (kA): 1
● Topraklama Direnci (ohm): 45	● Topraklama Direnci (ohm): 70	● Topraklama Direnci (ohm): 1
📏 İzolatör Boyu (mm): 45	📏 İzolatör Boyu (mm): 1250	📏 İzolatör Boyu (mm): 10
🔌 İşletme Gerilimi (kV): 154	🔌 İşletme Gerilimi (kV): 154	🔌 İşletme Gerilimi (kV): 1
Tahmin Sonucu: ⚠️ ARIZA	Tahmin Sonucu: ⚠️ ARIZA	Tahmin Sonucu: ✅ NORMAL
Olasılık: 0.8443	Olasılık: 0.8743	Olasılık: 0.3010

Şekil 4.21. Manuel veri girişi ile model sonuç örnekleri

Güncel tahmin süreci Python tabanlı uygulama ile test edilmiştir. Kullanıcıdan aşağıdaki değişkenler girildiğinde model anlık arıza tahmini yapmaktadır. Bunun için rastgele seçilen örnek görsel Şekil 4.23'te verilmiştir. Örnek kullanım senaryosunda yıldırım akımı, topraklama direnci, izolatör boyu ve hat geriliminin manuel olarak girilmesi halinde model, 'ARIZA' ya da 'NORMAL' şeklinde sınıflandırma yapmakta ve her bir sonuç için olasılık değeri sunmaktadır. Şekil 4.23 incelendiğinde 45kA yıldırım,

45Ω topraklama direnci ve 45cm izolatör boyunda 154kV EİH bilgileri girildiğinde sunucun %84,43 olasılıkla arıza vereceği görülmektedir.

4.6.2. Güncel zamanlı test senaryoları ve sonuçları

Model, 2024 yılına ait yıldırım ve arıza verileri ile doğrulanmıştır. Eğitim ve test verisi dışında kalan 20 farklı yıldırım düşme olayında modelin tahminleri test edilmiş ve aşağıdaki sonuçlar elde edilmiştir:

Çizelge 4.4. Güncel zamanlı veri ile modelin test sonuçları

No	Yıldırım Şiddeti (kA)	Toprak Direnci (Ω)	İzolatör Boyu (mm)	İşletme Gerilimi (kV)	Model Tahmini %	Model Sonucu (1/0)	Gerçek Durum (1/0)
1	65	46,3	1560	170	92,5	1	1
2	12	71,7	3000	400	94,9	1	0
3	24	64,9	1560	170	86,1	1	1
4	90	4,0	3000	400	76,1	1	0
5	56	25,7	1560	170	95,4	1	1
6	71	17,8	1560	170	92,0	1	1
7	35	51,2	1560	170	90,9	1	1
8	32	162,5	1560	170	81,3	0	1
9	17	87,1	1560	170	87,7	0	0
10	69	24,7	1560	170	92,8	1	1
11	44	81,2	1560	170	96,4	1	1
12	67	25,3	1560	170	90,1	1	1
13	39	49,2	1560	170	89,5	1	1
14	21	10,0	1560	170	91,7	0	0
15	14	36,8	3000	400	94,0	0	0
16	121	11,3	1560	170	92,8	1	1
17	19	29,0	1560	170	88,7	0	0
18	83	19,1	1560	170	92,9	1	1
19	27	150,5	1560	170	94,7	1	1
20	39	45,3	1560	170	90,4	1	1

Model 20 arıza verisi üzerinden yapılan 2024 yılına ait değerlendirmede 3 arıza için doğru sonuç vermemiştir. Bu sonuçlar incelendiğinde arıza olmayan 2 durum için arıza olur ve arıza olmayan durum için de arıza olur mesajı vermiştir. Model tahmin yüzdesi incelendiğinde bu 3 hatadan 2 tanesinde tahmin yüzdesi oldukça düşüktür. 2 no'lu arızadaki tahmini tamamen hatalı tahmin olup, diğer 2 durumda da bu değerler oldukça düşüktür. 4 no'lu arızada tahmin %76,1 iken 8 no'lu arızada bu durum 81,3'tür. %85 ve üzerindeki tahminleri için güvenilir tahmin referans değeridir.

Hatalı tahmin verileri incelendiğinde daha önce bahsedilen düşük yıldırım şiddeti ve yüksek topraklama direnç değerlerinde modelin yüksek başarı sergileyemediği bu

evrelerde de görülmüştür. 4 no'lu arızada yıldırım şiddeti 90kA iken 8 no'lu arızada toprak direnci 162,5 Ω 'dur. Bu durumun sebebi kullanılan test datalarının içinde yüksek yıldırım şiddetine ve yüksek topraklama direncine sahip arıza sayısı düşüktür. Başarı değeri ortalaması bu 20 arıza verisi için %91,68 çıkmıştır.



5. TARTIŞMA

Bu bölümde, geliştirilen hibrit modelin performansı, elde edilen bulgular ve literatürdeki benzer çalışmalar ile karşılaştırılarak değerlendirilmiştir. Modelin sağladığı avantajlar, karşılaştığı limit ve iyileştirme alanları tartışılmış, aynı zamanda EİH uygulamalarına ilişkin öneriler sunulmuştur.

5.1. Model Performansının Değerlendirilmesi

Hibrit model, ROA ve XGBoost algoritmalarının güçlü yönlerini birleştirerek, EİH'deki yıldırım kaynaklı arızaların tahmininde %92,96 doğruluk oranı elde etmiştir. Bu doğruluk oranı, benzer literatür çalışmalarıyla karşılaştırıldığında, modelin oldukça yüksek performans sergilediğini göstermektedir. Özellikle AİK-EAA skorunun 0,95 olması, modelin ayırt edici gücünün yüksek olduğunu göstermektedir. Bununla birlikte, hibrit modelin tek başına ROA (%90,85) veya XGBoost (%87,32) algoritmalarından daha iyi performans sergilediği gözlemlenmiştir.


Ayrıca, SMOTE kullanılarak dengesiz veri setinin etkisi minimize edilmiş ve modelin yanlılığı azaltılmıştır. Ancak, modelin 5-10kA arasındaki düşük yıldırım akımı seviyelerinde daha düşük doğruluk oranlarına sahip olduğu belirlenmiştir. Bu durum, modelin düşük akımlı yıldırım şiddeti ve düşük topraklama direnci arasındaki karmaşık ilişkiyi tam olarak yakalayamadığını göstermektedir ancak bu durum arıza kaynağı oluşturmamaktadır.

Şekil 4.1'de sunulan korelasyon matrisi ve değişkenler arasındaki bağlantı analizi incelendiğinde özellikle yıldırım akımı ile hattın arızadan açma durumu arasında düzeyinde güçlü bir pozitif korelasyon tespit edilmiştir. Topraklama direnci de arızalarla belirli bir korelasyon göstermektedir. Gerilim ve izolatör boyu, yıldırım şiddeti ve topraklama direncine göre daha düşük etkiye sahiptir.

Şekil 4.2'de sunulan yıldırım akımı ve arızadan açma durumu yoğunluk grafiğinde belirtilen açma durumu 1 yani *arıza var* olan hatlar, genellikle 30 kA ve üzeri yıldırım akımı seviyelerinde yoğunlaşmaktadır. Açma olmayan hatlar 0 yani *arıza yok* ise daha düşük yıldırım şiddetlerinde daha fazla dağılım göstermiştir. Bazı düşük yıldırım akımı değerlerinde açma gözlemlenmiştir. Bu noktada daha fazla veri ile bu sorunun üstesinden gelinebileceği düşünülmektedir. Ayrıca Yoldaş ve Özen (2019) çalışmalarında 10kA altındaki yıldırım şiddetlerinde neredeyse 0'a yakın arıza meydana geldiği bilinmektedir.


Arıza değerlendirmesine ilişkin bir diğer görsel olan Şekil 4.3'te 3 boyutlu yıldırım, direnç ve izolatör boyu arasındaki bağıntı sunulmaktadır. Saçılım grafiği incelendiğinde düşük direnç seviyelerinde $direnç < 10\Omega$ ve düşük yıldırım akımında $yıldırım < 50kA$ çoğunlukla normal çalışma durumu gözlenmiştir. Yıldırım akımı $> 50kA$ ve yüksek topraklama direnci $> 20\Omega$ olan noktalar daha çok arızaya sebep olmaktadır. İzolatör uzunluğu değişkeni, belirli aşırı uç değerlerinde farklılıklar göstermiştir.

Sunulan modelin değerlendirmesindeki önemli bulgulardan biri de Brier Skoru'dur. Brier Skoru, modelin tahmin ettiği olasılık değerlerinin doğruluğunu ölçmektedir. Hibrit model için hesaplanan Brier skoru 0,0493 olup, bu değer 0'a yakın olduğundan dolayı modelin sadece sınıflandırmada değil, aynı zamanda olasılık bazlı güvenilirlik açısından da başarılı olduğu görülmektedir. Şekil 5.1'de hibrit modelin Brien skoruna esas kalibrasyon eğrisi sunulmaktadır. Y eksenini, modelin tahmin ettiği olasılıkların gerçek sonuçlarla genel olarak mükemmel yakın kalibrasyon sergilemektedir. Bu da modelin "yüksek olasılık" dediği durumlarda gerçekten doğru tahminlerde bulunduğunu ortaya koymaktadır. 0,4 üzerinde çok küçük bir aralıkta gereksiz özgüven olarak yorumlanacak bir bölge bulunmaktadır. Bunun dışında değerler $y=x$ doğrusunun üzerinde seyretmektedir. Bu durum yani genel olarak eğrinin $y = x$ doğrusuna yakın seyretmesi, modelin olasılık bazlı güvenilirliğinin yüksek olduğunu göstermektedir. Ayrıca 0.0493 olarak hesaplanan bu skor, modelin hem sınıflandırma doğruluğu hem de tahmin güvenilirliği açısından tatmin edici düzeyde olduğunu doğrulamaktadır.



Şekil 5.1. Kalibrasyon (güven) eğrisi.

Bu noktada modelin başarısını ortaya koymak için bu çalışmada da sıklıkla kullanılan diğer algoritalara ilişkin güven eğrileri de Şekil 5.2'de paylaşılmıştır. Brien skoru için baz alınan güven eğrileri incelendiğinde ROA, XGBoost ve GA'nın 0.2 ile 0.6 aralığının hatalı tahmin aralığı olduğu söylenebilir. Özellikle bu aralıklarda modellerin açma olasılığı verdiği durumların büyük çoğunluğunda sistemin gerçekte açmadığı görülmektedir. Bu bulgu, modelin düşük olasılıklarda temkinli kalibrasyon stratejileriyle desteklenmesinin gerekli olduğunu ortaya koymaktadır. Saha uygulaması olarak düşünüldüğünde arıza ihtimali olmayan yerde arıza ihtimali bilgisi ile karşılaşılacak bu da gereksiz kaynak tüketimi ve operasyonel maliyet artışı gibi olumsuz sonuçların meydana gelmesine sebep olacaktır.



Şekil 5.2. ROA, XGBoost ve GA güven eğrisi karşılaştırması.

Şekil 5.2’de özellikle 0 aksına yakın aralıklarda aşırı öğrenme ihtimali olduğu da unutulmamalıdır. Modeller bu aralıklarda yüksek doğruluk ve hassasiyet ile sonuç verecektir. Bu durum da kesinlikle istenmeyen durumdur. Eğitim verisiyle fazla uyum sağlaması ve daha önce karşılaşmadığı durumlar için hatalı genelleme yapması bu modellerin zayıf kaldığı noktalardır.

5.2. Modelin Literatürdeki Yeri ve Karşılaştırmalar

Literatürde, yıldırım tahmini ve EİH’deki arıza tahmini için çeşitli MÖ algoritmaları kullanılmıştır. Geleneksel istatistiksel yaklaşımlar (LR, karar ağaçları vb.) genellikle doğruluk oranlarının %75-85 arasında kaldığını göstermiştir (Hastie vd. 2009). Bazı derin öğrenme modelleri (LSTM, CNN vb.) özellikle zaman serisi analizinde yüksek performans göstermiştir ancak hesaplama maliyetleri ve modelin aşırı öğrenme sorunu literatürde yaygın bir problem olarak raporlanmıştır (Hochreiter ve Schmidhuber, 1997; Gers vd. 2000). Bu yüzden, hibrit modelin daha düşük hesaplama maliyetiyle, diğer derin öğrenme yaklaşımlarına göre daha verimli bir seçenek sunduğu söylenebilir (Herrmann Kollmannsberger 2024).

GA ve YSA modelleri, büyük veri setleriyle başarılı olma potansiyeline sahip olsa da bu çalışmada en yüksek doğruluk oranı Hibrit Model ile elde edilmiştir. Öte yandan, KNN, DVM ve LR modelleri, diğer algoritmalara kıyasla nispeten daha düşük performans göstermiştir. Bu sonuçlar, Hibrit Model’in farklı algoritmaların güçlü yönlerini birleştirerek daha genelleştirilebilir ve etkili tahminler yapmasını sağlamasıyla açıklanabilir.

Çizelge 5.1. Model karşılaştırma tablosu

Model	Doğruluk	EAA	Kesinlik	Duyarlılık	F1-Skor
ROA	0,91	0,93	0,91	0,89	0,90
XGBoost	0,87	0,91	0,88	0,86	0,87
KNN	0,82	0,87	0,83	0,80	0,81
ANN	0,84	0,88	0,85	0,83	0,84
DVM	0,83	0,86	0,82	0,81	0,81
LR	0,81	0,84	0,81	0,79	0,80
GA	0,85	0,89	0,86	0,84	0,85
Hibrit Model	0,93	0,95	0,92	0,91	0,92


Model karşılaştırma tablosu incelendiğinde, hibrit model, tek başına ROA veya XGBoost'a kıyasla daha yüksek doğruluk sağlamıştır. Ağırlık ve 0,65 eşik değeri seçimi model başarısını artırmıştır. AİK-EAA skorlarına bakıldığında, hibrit model tüm yöntemlerden daha iyi ayrıştırma yapmaktadır. Modelin daha fazla veri ile eğitilmesi, derin öğrenme yaklaşımları ile desteklenmesi ve güncel zamanlı veri akışı ile entegrasyonu, gelecekteki iyileştirme çalışmaları için önerilmektedir. Şekil 4.11 de verilen AİK eğrisi karşılaştırması ile Şekil 4.10 incelendiğinde hibrit modelin 0,95 ile en yüksek eğriye sahip olduğu görülmüştür. 0,95 AİK eğrisi altında kalan alan bakımından diğer tüm algoritmalarından üstün performans göstermiştir. Bu, modelin hem yüksek duyarlılık hem de düşük hatalı pozitif oranı ile çalıştığını ortaya koymaktadır. Karşılaştırmalı AİK eğrileri, modellerin hangi eşik değerlerinde daha güçlü performans sergilediğini göstererek algoritmalar arası farklılıkların daha açık şekilde analiz edilmesine olanak tanımaktadır.

5.3. Hatalı Pozitif ve Hatalı Negatif Yanlışlarının Etkisi

Modelin yanlış tahmin ettiği durumlar iki şekilde değerlendirilebilir. İlki hatalı pozitif yani gerçekte normal olan bir hattın arızalı olarak tahmin edilmesidir. Bu durum, gereksiz bakım ve onarım maliyetlerine neden olabilir. Hatalı pozitif sınıflandırma nedeniyle operasyonel verimlilik düşebilir. İkinci durum ise hatalı negatiftir. Gerçekte arızalı olan bir hattın normal olarak tahmin edilmesidir. Bu, en riskli durumdur çünkü model, gerçekte bir arızayı tespit edemezse ciddi sistem arızalarına yol açabilir. Bu durum, çalışmanın hipoteziyle örtüşmemekte olup, hatalı negatif oranının düşük tutulması güvenlik açısından kritik önemdedir. Bu riski azaltmak için modelin karar eşiği, güvenlik risklerini minimize edecek şekilde optimize edilmiştir. Özellikle hatalı negatif oranı, maliyet bazlı optimizasyon yöntemleri ile düşürülebilir. Ağırlıklı kayıp fonksiyonları kullanılarak, modelin kritik hatalar için daha duyarlı olması sağlanabilir.

Hatalı pozitif ve hatalı negatif için gerekli değerlendirmeler Şekil 5.3'te sunulmuştur. Model çıktılarında gözlenen hatalı pozitif durumları, aslında kapalı olan

sistemin açık olarak tahmin edilmesidir. Bu durum, sistemin gereksiz yere müdahale edilmesine ya da alarm üretmesine neden olabilir. Hatalı negatif ise gerçek anlamda açık durumda olan sistemin kapalı olarak tahmin edilmesidir. Bu hata tipi, sistemin olası bir riski gözden kaçırmaya anlamına gelir ve güvenlik açısından daha kritik sonuçlar doğurabilir. Bu bağlamda, HN oranının özellikle düşük tutulması öncelikli optimizasyon kriteri olarak belirlenmiştir. Model, HP oranını da sınırlı tutarak hem hatalı pozitif sınıflandırma üretimini azaltmış hem de gerçek riski kaçırmayan bir yapı sunmuştur.




Şekil 5.3. Hibrit model hatalı sınıflandırma oranı.

5.3.1. Hata analizi sonrası model gelişimi için öneriler

Bu bölümde, hata analizine dayalı olarak modelin hatalı pozitif ve hatalı negatif oranlarını azaltmak ve maliyet bazlı optimizasyon süreçleriyle daha verimli hale getirmek için öneriler sunulmuştur. Yapılan hata değerlendirmeleri sonrası hatalı pozitif oranlarını azaltma yoluna gidilmelidir. Topraklama direnci $>150 \Omega$ olan bölgelerde model hatalı pozitif tahminlerde bulunmuştur. Bu nedenle, direnç değişkeni için farklı normalizasyon teknikleri test edilmiştir. Yanlış yönlendirmeleri azaltmak için tahmin eşiği optimize edilmelidir. Bu çalışma esnasında eşik değeri 0,65 olarak belirlenmiştir. Farklı ağırlıklı hata fonksiyonları kullanılabilir böylece hatalı arıza tahminlerinin operasyonel maliyetlerini düşürmek için maliyet bazlı öğrenme yöntemlerinin önü açılmıştır. Şekil 5.4'ten de görüleceği üzere hata analizleri sonucunda 0,89 olan hibrit modelin doğruluk oranı 0,93'e kadar çıkartılmıştır.

Hatalı negatif oranlarını azaltmada model gelişimi için önemlidir. Düşük akım seviyelerindeki modelin hatalı negatif oranı yüksektir. Bu nedenle, küçük ölçekli yıldırımlara duyarlılığı artırmak için yeni özellik mühendisliği teknikleri test edilmelidir. Sınıfsal ağırlık yöntemi ile düşük yıldırım akımı seviyelerinde modelin ağırlık katsayıları değiştirilebilir. Maliyet duyarlı öğrenme stratejileri ile kritik hataların minimize edilmesi sağlanabilir. Ancak modelin başarı oranı düşük olmadığı için bu durum göz ardı edilmiştir.



Şekil 5.4. Hibrit modelin optimizasyon sonuçları.


5.4. Modelin Güçlü Yönleri

En yüksek doğruluk yapılan karşılaştırmalar içinde hibrit modelde elde edilmiştir. Hibrit model, geleneksel MÖ algoritmalarından daha yüksek başarı oranlarına ulaşmıştır. Dengeli veri kullanımına ulaşabilmek için SMOTE uygulanarak dengesiz sınıflar arasındaki fark azaltılmıştır. Genelleme yeteneği açısından incelendiğinde model, farklı gerilim seviyelerindeki EİH’de genellenebilir çıktılar sunmaktadır.

Şekil 5.5’ten görüleceği üzere yanlış tahminler -1 ve $+1$ değerlerinde yoğunlaşmıştır. -1 gerçekte 1 olan arızalı ama modelin 0 yani normal tahmin ettiği veriler olup $+1$ ise gerçekte 0 olan normal ama modelin 1 yani arızalı tahmin ettiği verilerdir. Bu durum, modelin belirli senaryolarda çok küçük olasılıkta olsa da yanlış sınıflandırma yaptığını göstermektedir. Model eğitim setinde çok iyi performans göstermiş ancak test setinde biraz daha fazla hata yaptığı görülmekte olup bu durumun çözümü için L1/L2 düzenleme gerekmiştir. Bu durum değerlendirildiğinde hibrit modelin doğruluk oranı %91,55 e düşmektedir. Bu da tekrar düzenlemenin modeli daha genelleştirici hale getirdiğini ve aşırı öğrenmeyi önlediğini göstermiştir. Ayrıca L1/L2 düzenlemesi ile aşırı öğrenmenin de önüne geçilmiştir.


Şekil 4.7’de sunulan özellik önem grafiği ve Şekil 4.14 SHAP analizi incelendiğinde hibrit model, tek başına kullanılan makine öğrenimi modellerine kıyasla %92,96 oranla daha yüksek doğruluk sağlamıştır. EAA skoru 0,95 olup, modelin yüksek ayrıştırma performansına sahip olduğunu göstermektedir. ROA ve XGBoost’un birleşimi sayesinde, model hem ağaç tabanlı algoritmaların güçlü yönlerini kullanmış hem de genelleme yeteneğini artırmıştır. Özellikle kesinlik ve duyarlılık oranları dengeli olup, modelin hatalı pozitif ve hatalı negatif oranlarını kontrol edebilmesi sağlanmıştır. Özellik

önem analizi, modelin en çok yıldırım akım şiddeti ve direk topraklama direnci değişkenlerine ağırlık verdiğini göstermiştir.



Şekil 5.5. Hibrit model hata dağılımı.

Hibrit model yıldırım kaynaklı arıza senaryolarında en yüksek doğruluk oranını sağlamaktadır. Özellikle yıldırım akımı 40-100 kA arasında olduğunda, modelin tahmin doğruluğu oldukça yüksektir. Topraklama direnci 50-100 Ω arasında olduğunda, model arızaları ve normal durumları iyi ayırt edebilmektedir. İzolatör uzunluğu ortalama değerlere (1460 mm) sahip olduğunda, model en iyi sonucu vermektedir. Gerilim değişkeninin model performansına etkisi yıldırım şiddeti ve topraklamaya kıyasla düşüktür; model, bu değişken olmadan da güçlü tahminler yapabilmektedir. Ortalama yıldırım şiddeti ve topraklama değerleri incelendiğinde oldukça sağlıklı sonuçlar elde edilmiştir. Şekil 5.6'da ise işlem süresi karşılaştırması sunulmuştur.



Şekil 5.6. İşlem süresi karşılaştırması.

5.5. Modelin Dezavantajları

Düşük yıldırım akımı değerlerinde duyarlılık problemi bulunmaktadır. 5-10 kA arasındaki yıldırım akımı seviyelerinde modelin doğruluk oranı nispeten düşmüştür ama 0-10kA akım şiddetine ait yıldırım verilerinde arıza gözlenme olasılığı da oldukça düşüktür. Bu aralıkta hataya neden olan düşük enerjili yıldırımların etkisi tam olarak modellenememiştir. Model topraklama direnci 200Ω üzerinde daha fazla hatalı pozitif üretmektedir. Topraklama direnci 200Ω 'un üzerine çıktığında, model bazen hatalı pozitif tahminler yapmaktadır. Direnç değişkeni için farklı normalizasyon teknikleri ile test edilmelidir fakat normal şartlar altında EİH'nin 2020 yılına kadar olması gereken limit sınır 20Ω iken 2020 sonrası yapılan hatlarda bu değer 10Ω 'a düşürülmüştür (TEİAŞ, 2025). Bu arızalara ilişkin değerlendirmede 8 yıllık gerçek veriler ile test edilmiştir ancak veri miktarlarının artışıyla birlikte bu problem de ortadan kalkacaktır. Ayrıca düşük akım seviyelerinin etkisini artırmak için model ağırlıklandırma stratejisi kullanılabilir. Bu durum Yoldaş ve Özen (2019) çalışmasından da görüleceği üzere EİH'de yaşanan arızalarda 20kA ve üzerinde bulunan yıldırım şiddetlerinde önem arz etmektedir. Ayrıca eğitim veri miktarlarının zamanla artmasıyla bu durum yok sayılabilecek noktalara geleceği öngörülmektedir. Aşırı uyum analizi sonucu yapılan L1/L2 düzenlemesi ile bu durumun önüne geçilmiş olup şekil 4.8'de görülmektedir.

Model, 400 kV hatları için yeterli sayıda veri ile eğitilmediği için tahmin doğruluğu düşmüştür. Bunun temel sebebi elde edilen yıldırım verilerine karşılık arıza kayıtlarının azlığıdır. 713 arızanın 21 adedi 400kV hatlarda yaşanmıştır. Bundan dolayı izolatör uzunluğu 3000 mm üzerinde modelin doğruluk oranı azalmakta ve sağlıklı genelleme yapamamaktadır. Bundan dolayı 400 kV hatlarda tahmin performansı daha düşük çıkmaktadır.

6. SONUÇ

Bu bölümde, geliştirilen hibrit modelin EİH'deki yıldırım kaynaklı arıza tahminine olan katkıları özetlenmiş, çalışmanın temel bulguları vurgulanmış ve gelecekteki araştırmalar için öneriler sunulmuştur.

6.1. Çalışmanın Temel Bulguları

Bu tez çalışmasında, Antalya bölgesine ait 2015-2022 yılları arasında kaydedilen 360.000 yıldırım verisi filtrelenmiş ve TEİAŞ'tan temin edilen yıldırım kaynaklı arızalarla karşılaştırılarak 713 adet yıldırım kaynaklı arıza verisi kullanılarak ROA ve XGBoost algoritmalarını birleştiren hibrit makine öğrenmesi modeli geliştirilmiştir. Modelin temel bulguları şu şekilde özetlenebilir:

- Hibrit model, ROA ve XGBoost algoritmalarının birleştirilmesiyle oluşturulmuş ve %92,96 doğruluk oranı ile en yüksek performansa ulaşmıştır.
- Modelin AİK-EAA skoru 0,95 olup, sınıflandırma başarısının oldukça yüksek olduğunu göstermiştir.
- Model, karşılaştırmalı değerlendirmelerde 0,0493 Brien skoru ile en yüksek güven performansını göstermiştir.
- Topraklama direnci ve yıldırım akımı EİH yıldırım kaynaklı arızalarında en kritik değişkenler olarak belirlenmiştir.
- 142 arıza analizinin yalnızca 12'sinde yanlış sınıflandırma yapmıştır.
- Model, 40-100 kA arası yıldırım akımlarında en iyi tahmin performansını sergilemiştir.
- 2024 yılına ait 20 arıza verisinde %91,68 başarı sağlamıştır.
- Manuel veri girişine uygunluk sağlanmış ve anlık analiz yapılabilmesine imkân sunulmuştur.
- Toplu veri girişi ile hat bazında değerlendirme yapılabilmektedir.
- Düşük yıldırım akım seviyelerinde (5-10 kA) modelin tahmin performansı düşmüştür.
- 400 kV EİH'de yetersiz veri nedeniyle modelin genelleme kapasitesi sınırlı kalmıştır.

6.2. Çalışmanın Katkıları

Bu tez, EİH'de yıldırım elektromanyetik darbelerin oluşturduğu arızaların tahmini için hibrit MÖ modeli geliştirerek aşağıdaki katkıları sağlamıştır:

- Tahmin doğruluğunu artıran hibrit model, ROA ve XGBoost'un avantajlarını birleştirerek, geleneksel ve tek başına makine öğrenmesi modellerine göre daha başarılı bir model oluşturulmuştur.

- Veri entegrasyonu ve düzenleme doğrultusunda TEİAŞ ve MGM'den elde edilen veriler birleştirilerek EİH'deki yıldırım kaynaklı arıza tahminine yönelik yeni bir veri seti oluşturulmuştur.
- Yapılan literatür taramasında ortaya konan modele benzer herhangi bir modele ya da mühendislik verilerine dayalı tahmin yürüten MÖ ile karşılaşılmamıştır.
- EİH'de karar destek mekanizmasının geliştirilmesi kapsamında model, EİH'deki operatörlerin yıldırım risklerine karşı daha bilinçli kararlar alabilmesi için bir temel oluşturmuştur.
- Oluşturulan veri alt yapısı ile işletmede olan EİH için bakım onarım programı oluşturulabilir.
- Yeni planlanan EİH güzergâh seçiminde kullanılabilir.

6.3. Öneriler

Ortaya konan modelde ilerleyen zaman içinde yapılabilecek öneriler ve geliştirmeler altta paylaşılmıştır.

- Model, uygulama haline getirilerek farklı modlarda kullanılabilir. Bu modlar kullanıcı tanımlı tekil giriş, hat güzergâh bilgilerinin toplu olarak girilmesiyle hatta ilişkin risk analizi ve güncel zamanlı veriler girilerek anlık olarak işletme operatörüne veya ilgili bakım ekiplerine bilgi aktarımı sağlanabilir.
- Gerçek zamanlı sensör entegrasyonu ile SCADA sistemlerinden gelen verilerin anlık olarak modele bağlanması ile yıldırım algılama sensörleri ile doğrudan veri akışı sağlanabilir. Topraklama direnci ölçüm cihazlarının modele entegre edilmesiyle veri tabanı sürekli güncel hale getirilebilir.
- Modelin gerçek zamanlı veri akışına entegre edilmesi için SCADA sistemleri, IoT sensörleri ve bulut tabanlı altyapılar ile bağlantı kurulabilir.
- Bulut tabanlı model güncellemeleri ile AWS Lambda, Google Cloud AI veya Microsoft Azure ML gibi platformlara entegre edilerek sürekli güncellenmesi ve otomatik MÖ algoritmalarıyla modelin belirli periyotlarla yeniden eğitilmesi sağlanabilir.
- Web ve mobil arayüz entegrasyonu ile hibrit modelin SCADA sistemi ile entegrasyonu, bakım ekiplerinin model tahminlerini mobil uygulama üzerinden takip edebilmesi, API tabanlı servis kullanılarak farklı enerji sistemlerine entegre edilmesi yapılabilir.
- Makine öğrenimi destekli karar destek sistemi ile maliyet ve risk bazlı optimizasyon yapılabilir. Modelin sadece tahmin yapmakla kalmayıp, önleyici bakım planlamaları önermesi, hatalı negatif oranının düşürülmesi için ağırlıklı kayıp fonksiyonları kullanılması ile başarı oranı mükemmele yaklaştırılabilir.
- MGM'den elde edilen verilerle buz yükü haritası benzeri küçük ölçekli yıldırım haritası oluşturulabilir. Bu haritalar da EİH için güzergâh seçiminde,

transformatör merkezi yer seçiminde enterkonnekte sistemin arz ve güvenliği için kullanılabilir.

- Oluşturulan yıldırım haritaları sadece enerji alt yapısı için değil diğer stratejik kurum ve kuruluşların yeni yapacağı tesislerde de kullanılabilir.
- İşletmede bulunan EİH için yıldırım kaynaklı arıza risk analizi yapılabilir.
- EİH güzergâh seçimi için YZ tabanlı modeller geliştirilebilir.
- Farklı coğrafi bölgelerden gelen EİH arızaları ile eğitilebilir. Böylece farklı iklim ve şartlar altında da yüksek başarı oranlarına ulaşılabilir.
- Karar destek sistemleri ve optimizasyon çalışmaları bakım ve onarım süreçlerinin maliyetlerini minimize etmek için uygulanabilir.
- Risk bazlı bakım planlaması yapabilecek şekilde optimize edilebilir. Bakım bütçesi kısıtlı işletmeler için model, kaynak tahsisinin daha verimli hale gelmesini sağlayacak bir karar destek sistemi olarak kullanılabilir.

7. KAYNAKLAR

- Adiaksa, A., Mushawir, A., Z. Z., Insani, A.F., Firidi, S. 2024. Prediction of lightning strikes on electrical transmission lines using machine learning approaches. *ITB Journal Publisher*, 24(1): 1-17.
- Agrawal, A.K., Price, H.J. and Gurbaxani, S.H. 1980. Transient Response of a Multiconductor Transmission Line Excited by a Non Uniform Electromagnetic Field. *IEEE Transactions on Electromagnetic Compatibility*, 22(2): 119-129.
- Anwar, T., Mu, C., Yousaf, M.Z., Khan, W., Khalid, S., Hourani, A.O. and Zaitsev, I. 2025. Robust fault detection and classification in power transmission lines via ensemble machine learning models. *Scientific Reports*, 15(2549).
- Araujo, A.E., Paulino, J.O., Silva, J.P., Dommel, H.W. 2001. Calculation of Lightning-Induced Voltages with RUSCK's Method in EMTP. Part I: Comparison with Measurements and Agrawal's Coupling Model. *Electric Power System Research*, 60(1): 49-54.
- Asadi, M., Karami, H., Rajabi, S., Rubinstein, M., Rachidi, F. 2024. An efficient machine learning model for lightning localization via lightning-induced voltages on transmission lines. *URSI AT-RASC*, ss.1-8, 19-24 May, Gran Canariass.
- Bao, J., Wang, X., Zheng, Y., Zhang, F., Huang, X., and Sun, P. 2021. Lightning Performance Evaluation of Transmission Line Based on Data-Driven Lightning Identification, Tracking, and Analysis. *IEEE Transactions on Electromagnetic Compatibility*, 63(1): 160-171.
- Baraniuk, C. 2024. Science - Wired. <https://www.wired.com/story/lightning-protection-damage-climate-change-extreme-weather> [Son erişim tarihi: 06.04.2025].
- Barker, P.P., Short, T.A., Eybert-Berard, A.R., Berlandis, J.P. 1996. Induced Voltage Measurements on an Experimental Distribution Line during Nearby Rocket Triggered Lightning Flashes. *IEEE Transactions on Power Delivery*, 11(2): 980-995.
- Bedoui, S., Bayadi, A., Haddad, A. 2010. Analysis of lightning protection with transmission line arrester using ATP/EMTP: Case of an HV 220kV double circuit line. 45th International Universities Power Engineering Conference, UPEC2010. ss. 1-6, 31 Aug.-3.Sep, Cardiff.
- Bonilla, M.J., Toth, T., McDonald, J., Sadler, B. 2023. Traditional vs Machine Learning Approaches: A Comparison of Time Series Modeling Methods. *SMU Data Science Review*, 7(2): 1-19.
- Borghetti, A., Nucci, C.A., Paolone, M., Rachidi, F. 2000. Characterization of the Response of an Overhead Line to Lightning Electromagnetic Fields. 25th International Conference on Lightning Protection, ss. 223-228, 18-22 September, Rhodos, Greece.
- Bouchard, A., Buguet, M., Chan-Hon-Tong, A., Dezert, J. and Lalande, P. 2023. Comparison of different forecasting tools for short-range lightning strike risk assessment. *Natural Hazards*, 115: 1011-1047.
- Breiman, L. 2001. Random forests. *Machine Learning*, 45: 5-32.

- Cecil, D.J., Buechler, D.E., and Blakeslee, R.J. 2014. Gridded Lightning Climatology from TRMM-LIS and OTD: Dataset Description. *Atmospheric Research*, 135-136: 404-414.
- Chang, C.C., and Lin, C.J. 2011. LIBSVM: A Library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3): 1-27.
- 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, ss. 785–794, 13-17 August, San Francisco.
- Cheng, W.Y., Kim, D., Henderson, S., Ham, Y.G., Kim, J.H., Holzworth, R.H. 2024. Machine learning-based lightning parameterizations for the CONUS. *Artificial Intelligence for the Earth Systems*, 3(2): e230024.
- Cihan, P., Coşkun, H. 2021. Performance Comparison of Machine Learning Models for Diabetes Prediction. 29th Signal Processing and Communications Applications Conference (SIU), ss. 1-4, 9-11 June, Online, Istanbul.
- Cooray, V. 1994. Calculating Lightning-Induced Overvoltages in Power Lines: A Comparison of Two Coupling Models. *IEEE Transactions on Electromagnetic Compatibility*, 36(3): 179-182.
- Cooray, V. 2014. The Lightning Flash. IEE Press, London, 924 s.
- Cummins, K. L., Murphy, M.J. 2010. An Overview of Lightning Locating Systems: History, Techniques, and Data Uses, With an In-Depth Look at the U.S. NLDN. *IEEE Transactions on Electromagnetic Compatibility*, 51(3): 499-518.
- Dadashova, I. 2021. Principles of John von Neumann as a basis of the Electronic Calculating Machine. *International Journal of Multidisciplinary Studies and Innovative Technologies*, 5(1): 27-29.
- Dobberstein, L. 2022. Systems.
https://www.theregister.com/2022/07/12/japanese_chip_plant_back_online [Son erişim tarihi: 06.04.2025].
- Doostan, M., Chowdhury, B. (2020). Predicting Lightning-Related Outages in Power Distribution Systems: A Statistical Approach. *IEEE Access*, 8: 84541-84550.
- Duan, P., Zhang, L., Huang, X., Sun, J., Qi, Y., Yang, Q. 2024. Evaluation of lightning-induced overvoltage on a 10 kV distribution line based on electromagnetic return-stroke model using finite-difference time-domain. *High Voltage*, 9(2): 356-366.
- Entezari, A., Aslani, A., Zahedi, R., Noorollahi, Y. 2023. Artificial intelligence and machine learning in energy systems: A bibliographic perspective. *Energy Strategy Reviews*, 45:101017.
- Fatima, S., Hussain, A., Amir, S.B., Ahmed, S.H., Aslam, S.M. 2023. XGBoost and Random Forest Algorithms: An in Depth Analysis. *Pakistan Journal of Scientific Research*, 3(1): 26-31.
- Geng, Y.A., Li, Q., Lin, T., Jiang, L., Xu, L., Zheng, D., Zhang, Y. 2019. LightNet: A Dual Spatiotemporal Encoder Network Model for Lightning Prediction. The 25th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD '19), ss. 2439–2447, 4-8 August, Anchorage, Alaska.

- Géron, A. 2022. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media, California, 848 s.
- Gers, F. A., Schmidhuber, J., Cummins, F. 2000. Learning to Forget: Continual Prediction with LSTM. *Neural Computation* , 12(10): 2451–2471.
- Golde R.H., 1977. Lightning, Volume 1: Physics of Lightning. Academic Press, London, 541 s.
- Goud, R.D., Rayudu, R., Moore, C.P., Emmanuel, M. 2018. Analysis of Lightning Generated Over-Voltages on Voltage Regulating Devices in Distribution System with Centralized Wind Turbine Generators. 2018 Australasian Universities Power Engineering Conference, ss. 1-6, 27-30 November, Auckland.
- Guerrieri, S., Nucci, C. A., Rachidi, F. 1997. Influence of the Ground Resistivity on the Polarity and Intensity of Lightning Induced Voltages. Proceedings of 10th International Symposium on High Voltage Engineering, ss. 1404-1411, 26-30 August, Montreal.
- Guastavino, S., Michele, P., Tizzi, M., Cassola, F., Iengo, A., Sacchetti, D., Benvenuto, F. 2022. Prediction of severe thunderstorm events with ensemble deep learning and radar data. *Scientific Reports*, 12:20049.
- Hakkal, S., Lahcen, A.A. 2024. XGBoost To Enhance Learner Performance Prediction. *Computers and Education: Artificial Intelligence*, 7:100254.
- Halloran, J. T., Rocke, D. M. 2018. A matter of time: Faster Percolator analysis via efficient SVM learning for large-scale proteomics. *Journal of Proteome Research*, 17(5):1978-1982.
- Hamel, T., Bedoui, S., Bayadi, A. 2025. Impact of transmission line lightning performance on an operational substation reliability considering the lightning stroke incidence angle. *Electrical Engineering & Electromechanics*, ss. 56-64.
- Han, Y., Guo , F., Lin, S., Pang, H. 2021. Lightning Prediction and Environment Factor Analysis using Random Forest Algorithm in Shandong Province, China. IEEE 23rd Int. Conf. on High Performance Computing & Communications, ss. 2227-2232, 20-22 December, Haikou.
- Hasrod, T., Nuapia, Y.B., Tutu, H. 2024. Comparison of individual and ensemble machine learning models for prediction of sulphate levels in untreated and treated Acid Mine Drainage. *Environmental Monitoring and Assessment*, 196(332): 1-27.
- Hastie, T., Tibshirani, R. and Friedman, J. 2009. The Elements of Statistical Learning, Data Mining, Inference, and Prediction, Springer, London, 745 s.
- He, H., He, J., Xie, S., Yao, S., Zhang, D., Dong, M. 2010. Assessment of lightning shielding performance of double-circuit UHV overhead transmission lines. IEEE PES General Meeting, ss. 1-8, 25 July, Online.
- He, J., Wang, X., Yu, Z., Zeng, R. 2015. Statistical analysis on lightning performance of transmission lines in several regions of China. *IEEE Transactions on Power Delivery*, 30(3): 1543-1551.

- Hebbagilu, M., Naik, A.K., Prabhu, K., Shetty, S. 2024. Lightning prediction and alert system. *International Journal of Advanced Research in Computer and Communication Engineering*, 13(3): 525-533.
- Heidler, F. 1985. Travelling Current Source Model for LEMP Calculation. 6th International Symposium on Electromagnetic Compatibility, ss. 1297-1302, 21-24 June, St. Petersburg.
- Heidler, F., Flisowski, Z., Zischank, W. 2008. Parameters of lightning current given in IEC 62305–Background, experience and outlook. 29th International Conference on Lightning Protection. ss. 1-61, 20 June, Uppsala University, Uppsala.
- Herrmann, L., Kollmannsberger, S. 2024. Deep learning in computational mechanics: a review. *Computational Mechanics*, 74:281-331.
- Hochreiter, S., Schmidhuber, J. 1997. Long Short-Term Memory. *Neural Computation*, 9(8): 1735-1780.
- Huang, R., Lai, J., Yin, W., Deng, H., Ma, X., Luo, Z., Dong, T. 2024. Efficiently solving large-scale electrostatic lightning problems by integrating characteristic basis functions into boundary element method. *Electric Power Systems Research*, 245:110843.
- Huo, H., Wang, D., Chen, H., Zhao, C., Cheng, Q. 2024. Considering the Methods of Lightning Protection and Early Warning for Power Transmission Lines Based on Lightning Data Analysis. *IEEE Access*, 99(1): 54168-54181.
- Idone, V., Orville, R.E. 1982. Lightning Return Stroke Velocities in the Thunderstorm Research International Program. *Journal of Geophysical Research*, 87(C7): 4903-4915.
- IEEE Guide for Improving the Lightning Performance of Electric Power Overhead Distribution Lines. 2010. IEEE.
- Imani, M., Beikmohammadi, A., Arabnia, H.R. 2025. Comprehensive Analysis of Random Forest and XGBoost Performance with SMOTE, ADASYN, and GNUS Under Varying Imbalance Levels. *Technologies*, 13(3): 1-40.
- Fawaz, H.I., Forestier, G., Weber, J., Idoumghar, L., Muller, P.A. 2019. Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*, 33: 917-963.
- Izadi, M., Abidin Ab Kadir, M. Z., Gomes, C., Cooray, V. 2012. Evaluation of Lightning Return Stroke Current Using Measured Electromagnetic Fields. *Progress In Electromagnetics Research*, 130: 581-600.
- Jankov, V. 1997. Estimation of the Maxital Voltage Induced on an Overhead Line due to the Nearby Lightning. *IEEE Transactions on Power Delivery*, 12(1): 315-324.
- Jiang, R., Qie, X., Wang, Z., Zhang, H., Lu, G., Sun, Z., Li, X. 2015. Characteristics of lightning leader propagation and ground attachment. *J. Geophys. Res. Atmos.*, 120(23): 11988–12002.
- Jun, X. 2017. Study of Distribution Transmission Line Lightning Stroke Risk Forecasting Based on Nonlinear Time Series Analysis. International Conference on Smart Grid and Electrical Automation, ss. 282-285, 29-30 May, Changsha, Kunming

- Kannu, P. D., Thomas, M. J. 2005. Lightning Induced Voltages on Multiconductor Power Distribution Line. *IEE Proceeding Generation, Transmission and Distribution*, ss. 152(6): 855-863.
- Karami, H., Mostajabi, A., Azadifar, M., Rubinstein, M., Zhuang, C., Rachidi, F. 2020. Machine Learning-Based Lightning Localization Algorithm Using Lightning-Induced Voltages on Transmission Lines. *IEEE Transactions on Electromagnetic Compatibility*, 62(6): 2512-2519.
- Katuwal, R., Suganthan, P. N. 2019. Stacked autoencoder based deep random vector functional link neural network for classification. *Applied Soft Computing*, 85: 105854.
- Koga, H., Motomitsu, T., Taniguchi, T. 1979. Lightning Surge Waves Induced on Overhead Lines. *Transactions on IECE of Japan*, 62: 216-223.
- Kohavi, R. 1995. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI), ss. 1137–1143, 20-25 August, Montreal.
- Kordi, B., Moini, R., Sadeghi, S. 1999. Comparison of the Transmission Line Coupling Model With the EFIE Approach for Lightning Induced Overvoltage Prediction. 3th International Zurich Symposium and Technical Exhibition on Electromagnetic Compatibility, ss. 597-600, 16-18 February, Zurich.
- Lee, J., Cho, Y. 2022. National-scale electricity peak load forecasting: Traditional, machine learning, or hybrid model. *Energy*, 239(D):122366.
- Lin, Y. T., Uman, M. A., 1980. Lightning Return Stroke Models. *Journal of Geophysical Research*, 85(C3): 1571-1583.
- Mecikalski, J.R., Murillo, E.M., Homeyer, C.R., Bedka, K.M., Apke, J.M., Jewett, C.P. 2021. A Random-Forest Model to Assess Predictor Importance and Nowcast Severe Storms Using High-Resolution Radar–GOES Satellite–Lightning Observations. *Monthly Weather Review*, 149: 1725–1746.
- Merkulov, D., Oseledets, I. 2019. Empirical study of extreme overfitting points of neural networks. *arXiv preprint*, 64(12): 1527–1534.
- Mitchell, J. W. 2013. Power line failures and catastrophic wildfires under extreme weather conditions. *Engineering Failure Analysis*, 35:726-735.
- Montano, R. 2005. The Effects of Lightning on Low Voltage Power Networks. Ph.D Thesis, Uppsala University, Sweden: 83s.
- Mostajabi, A., Finney, D.L., Rubinstein, M., Rachidi, F. 2019. Nowcasting lightning occurrence from commonly available meteorological parameters using machine learning techniques. *Climate and Atmospheric Science*, 2(41):1-15.
- Nicora, M.A., Barmada, S., Brignone, M., Procopio, R. 2024. Lightning Location and Peak Current Estimation From Lightning-Induced Voltages on Transmission Lines With a Machine Learning Approach. *IEEE Transactions on Electromagnetic Compatibility*, 66(3): 890-899.
- Nucci, C. 1995. Lightning-Induced Voltages on Overhead Power Lines. Part II: Coupling Models for the Evaluation of the Induced Voltages. *Electra*, 162(4): 121-145.

- Nucci, C. A., Rachidi, F., Ianoz, M., Mazzetti, C. 1995. Comparison of Two Coupling Models for Lightning-Induced Overvoltage Calculations. *IEEE Transactions on Power Delivery*, 10(1): 330-339.
- Özdemir, M. 2017. Genetik Algoritma ile Doğrusal Regresyonda Tahmin Amaçlı Model Seçimi. *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 28:213-233.
- Özen, Ş. 2017. Mühendislik Elektromanyetiği Çözümlü Problemler. Birsan Yayınevi, İstanbul, 301 s.
- Özen, Ş. ve Helhel, S. 2022. Mühendislik Elektromanyetiğinin Temelleri. Birsan Yayınevi, İstanbul, 465 s.
- Özen, Ş. ve Yoldaş, A.Y. 2019. Yıldırım elektromanyetik darbelerinin yüksek gerilim hatlarına etkilerinin izolator ve topraklama açısından incelenmesi. ETUK 2019, Elektrik Tesisat Kongresi, ss. 1-12, 16-19 Ekim 2019, İzmir.
- Öztopal, A. 2017. Türkiye'nin Yıldırım ve Şimşek Gözlemlerinin İncelenmesi. *Dokuz Eylül University-Faculty of Engineering Journal of Science and Engineering*, 56(304): 304-313.
- Paolone, M., Nucci, C.A., Petrache, E., Rachidi, F. 2004. Mitigation of Lightning-Induced Overvoltages in Medium Voltage Distribution Lines by Means of Periodical Grounding of Shielding Wires and of Surge Arresters: Modeling and Experimental Validation. *IEEE Transactions on Power Delivery*, 19(1): 423-431.
- Poelman, D. R. 2016. Performance Characteristics of Distinct Lightning Detection Networks Covering Belgium. *Journal of Atmospheric and Oceanic Technology*, 30:2699-2708.
- Rachidi, F. 1993. Formulation of the Field-to-Transmission line Coupling Equations in Terms of Magnetic Excitation Field. *IEEE Transactions on Electromagnetic Compatibility*, 35(3): 404-407.
- Rachidi, F., Nucci, C. A. 1990. Modified Transmission Line Lightning Return Stroke Current Models. *Journal of Geophysics Research*, 95(12): 20389-20393.
- Rafi, M.A., Sohan, M.R., Nadid, M.H., Rafa, T.S., Jawad, A. 2024. Enhancing Power Transmission Line Fault Detection with a Hybrid ANN-SVM Machine Learning Model: A Comparative Study. 2024 International Conference on Advances in Computing, Communication, Electrical, and Smart Systems (iCACCESS), ss. 1-6, 8-9 March, Dhaka, Bangladesh.
- Raheem, A., Ikotun, B., Oyebisi, S., Ede, A. 2023. Machine learning algorithms in wood ash-cement-Nano TiO₂-based mortar subjected to elevated temperatures. *Results in Engineering*, 18(8):101077.
- Rakov, V.A., Dulzon, A.A. 1987. Calculated Electromagnetic Fields of Lightning Return Strokes. *Tekhnicheskaya Elektrodinamika*, 237: 87-89.
- Rakov, V.A., Dulzon, A.A. 1991. A modified transmission line model for lightning return stroke field calculations. Proc. 9th Int. Zurich. Symp. Electromagn. Compat., ss. 229-235, 12-14 March, Institute for Technology of the Swiss Federal Institute, Zurich.

- Rakov, V., Uman, M. 2007. Lightning: Physics and Effects. Cambridge University Press, New York, 700 s.
- Razzak, S.M., Ali, M.M., Sarkar, M.Z., Ahmad, H. 2024. Lightning Induced over Voltages on Overhead Distribution Lines Including Lossy Ground Effects. 3rd International Conference on Electrical and Computer Engineering ICECE 2024 ss. 151-155, 27-30 November, 17 Eylul University, Online.
- Rusck, S. 1958. Induced Lightning Overvoltages on Power Transmission Lines with Special Reference to the Overvoltage Protection of Low Voltage Networks. Transactions of the Royal Institute of Technology, Stockholm, 120 s.
- Sarmiento, J.L., Delfino, J.C., Arboleda, E.R. 2024. Machine learning advances in transmission line fault detection: A literature review. *International Journal of Science and Research Archive*, 12(1): 2880–2887.
- Shilov, A. 2020. Tom's Hardware. <https://www.tomshardware.com/news/micron-fab11-outage> [Son erişim tarihi: 06.04.2025].
- Shin, K., Kim, K., Lee, G. 2024. Supervised Learning-Based Prediction of Lightning Probability in the Warm Season. *Remote Sensing*, 16(19): 3621.
- Sulaiman, M.H., Mohamed, A.I., Mustaffa, Z. 2023. An application of deep learning for lightning prediction in East Coast Malaysia. *Advances in Electrical Engineering, Electronics and Energy*, 6:100340.
- Tanyıldızı, A. 2022. Using machine learning algorithms for classifying transmission line faults. *Dicle University Journal of Engineering*, 13(2): 227-234.
- Tao, H., Gu, S., Wang, H., Feng, W., Guo, J., Wang, Y. 2016. Method of lightning warning based on atmospheric electric field and lightning location data. 33rd International Conference on Lightning Protection (ICLP), ss. 1-5, 25-30 April, Estoril, Portugal.
- Taylor, C., Satterwhite, R., Harrison, C. 1965. The response of a Terminated Two-Wire Transmission Line Excited by a Non-Uniform Electromagnetic Field. *IEEE Transaction on Antenna Propagation*, 13(6): 987-989.
- TEİAŞ. (2025). TEİAŞ. Türkiye Elektrik İletim A.Ş.: <https://www.teias.gov.tr/ihale-sartnameleri> [Son erişim tarihi: 06.04.2025].
- Thanasaksiri, T. 2004. Improving the Lightning Performance of Overhead Distribution Lines. TENCON, IEEE Region 10 Conference, ss. 369-372, 20-24 June, Chiang Mai, Thailand.
- Vallejo, J. M., Hernandez Batista, J. A., Shipp, D. D. 2023. Lightning and Grounding Issues Impacting Safety and Performance of Liquefied Natural Gas-Supplied Power Generation Plants: Lessons Learned to Correct Commonplace Misunderstandings of Requirements. *IEEE Industry Applications Magazine*, 29(5): 65-75.
- Visacro, S., Silveria, F.H. 2015. Lightning Performance of Transmission Lines: Methodology to Design Grounding Electrodes to Ensure an Expected Outage Rate. *IEEE Transactions on Power Delivery*, 30(1): 237-245.

- Visacro, S., Silveira, F.H., Vale, M.H., Pomar, G.D. 2021. Improvement of the lightning performance of transmission lines by combining conventional and non-conventional measures. *Electric Power Systems Research*, 195:107134.
- Wagner, C.F., McCann, G.D. 1942. Induced voltages on transmission lines. *AIEE Transactions*, 61(12):916-929.
- Wang, X., Hu, K., Wu, Y., Zhou, W. 2023. A Survey of Deep Learning-Based Lightning Prediction. *Atmosphere*, 14(11):1698.
- Wokoma, B., Dumkhana, L., Wokoma, I.B. 2024. *Journal of Advanced Research in Artificial Machine Learning Approaches for Power Transmission Lines Fault Classification: A Systematic Review*. *Intelligence & It's Applications*, 2(1):57-66.
- Xie, Y., Li, C., Lv, Y., Yu, C. 2019. Predicting lightning outages of transmission lines using generalized regression neural network. *Applied Soft Computing*, 78:438-446.
- Xin, Z., Yin, Y., Kukulies, J., Li, Y., Kuang, X., He, C., Chen, J. 2021. Revisiting Lightning Activity and Parameterization Using Geostationary Satellite Observations. *Remote Sensing*, 13(19):3866.
- Yang, K., K. Y., Wang, D., Li, H., Diao, Y. 2019. Modeling overdispersed or underdispersed count data with generalized Poisson integer-valued autoregressive processes. *Metrika*, 82:863-889.
- Yang, S., Zhou, W., Zhu, S., Wang, L., Le, L., Xia, X., Li, H. 2019. Failure probability estimation of overhead transmission lines considering the spatial and temporal variation in severe weather. *Journal of Modern Power Systems and Clean Energy*, 7:131-138.
- Yoldaş, A.Y. 2019. Yıldırım elektromanyetik darbelerinin yüksek gerilim hatlarına etkilerinin izolatörler ve topraklama açısından incelenmesi. Yüksek Lisans Tezi, Akdeniz Üniversitesi, Antalya, 134 s.
- Yoldaş, A.Y., Özen Ş., Ateş, K. 2024. Enerji iletim hattı güzergâh seçiminde yıldırım faktörünün değerlendirilmesi.VII. Elektrik Tesisleri Ulusal Kongre ve Sergisi, ss.1-9. 1-3Kasım 2023, İzmir
- Zheng, Y., Wu, Z., Shu, S., Xu, J., Fang, C., Xie, W. 2021. Lightning risk assessment model for transmission lines with lift-based improved analytic hierarchy process. *IET Generation, Transmission & Distribution*, 15(20):2905-2914.
- Zhou, K., Zheng, Y., Dong, W., Wang, T. 2020. A Deep Learning Network for Cloud-to-Ground Lightning Nowcasting with Multisource Data. *Journal of Atmospheric and Oceanic Technology*, 37:927-942.
- Zhou, W., Li, J., Wang, H., Zhang, D., Wang, X. 2024. Forecasting of Local Lightning Using Spatial-Channel-Enhanced Recurrent Convolutional Neural Network. *Atmosphere*, 15(12):1478.
- Zraïbi, B., Mansouri, M., Okar, C. 2021. Comparing Single and Hybrid methods of Deep Learning for Remaining Useful Life Prediction of Lithium-ion Batteries. The 4th International Conference of Computer Science and Renewable Energies (ICCSRE'2021), ss. 1-8, 22-24 July, Morocco, E3S Web of Conferences 297: EDP Sciences.

8. EKLER

EK-1: Enerji İletim Hatlarında Yaşanan Arızaların Güncel Verilerle Tahmini

```
# KÜTÜPHANE YÜKLEME
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
import pickle
from sklearn.ensemble import RandomForestClassifier
from xgboost import XGBClassifier
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score, confusion_matrix, classification_report, roc_curve, auc

# VERİSETİ YÜKLEME
file_path = "D:/Yayın/DOKTORA TEZİ/Data3_713.csv"
df = pd.read_csv(file_path)

# GEREKSİZ SÜTUNLARI KALDIRMA
df = df.drop(columns=["HAT_ADI", "DirekNo"])

# EKSİK VERİ TEMİZLEME
df["Lightning(kA)"] = df["Lightning(kA)"].fillna(df["Lightning(kA)"].mean())
df["Resistance"] = df["Resistance"].fillna(df["Resistance"].mean())
df["Voltage(kV)"] = df["Voltage(kV)"].fillna(df["Voltage(kV)"].mean()) # İşletme Gerilimi eklendi

# BAĞIMSIZ VE BAĞIMLI DEĞİŞKENLERİ BELİRLEME
X = df[["Lightning(kA)", "Resistance", "insulator(mm)", "Voltage(kV)"]]
y = df["Opened"]

# VERİLERİN EĞİTİM VE TEST SETİ OLARAK BÖLÜNMESİ
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)

# OPTİMİZE EDİLMİŞ ROA MODELİ
rf_best = RandomForestClassifier(
    max_depth=10,
    min_samples_leaf=2,
    min_samples_split=0,
    n_estimators=20,
    random_state=42
)
rf_best.fit(X_train, y_train)

# OPTİMİZE EDİLMİŞ XGB MODELİ
xgb_best = XGBClassifier(
    learning_rate=1,
    max_depth=3,
    n_estimators=1000,
    subsample=0.8,
    random_state=42
)
xgb_best.fit(X_train, y_train)

# AĞIRLIKLIL TAHMİN VE OPTİMUM EŞİK DEĞER HESAPLAMA
rf_weight = 0.85 # En iyi Random Forest ağırlığı
xgb_weight = 0.15 # En iyi XGBoost ağırlığı
```

```

best_threshold = 0.65 # En iyi eşik değeri

# MODEL TAHMİNLERİ
rf_probs = rf_best.predict_proba(X_test)[: , 1]
xgb_probs = xgb_best.predict_proba(X_test)[: , 1]

# AĞIRLIKLILIKLI ORTALAMA İLE NİHAİ HİBRİT MODEL OLASILIK
hybrid_probs = (rf_weight * rf_probs) + (xgb_weight * xgb_probs)
hybrid_preds = np.where(hybrid_probs > best_threshold, 1, 0) # En iyi eşik değeri ile sınıflandırma

# HİBRİT MODEL DOĞRULUK ORANI
hybrid_accuracy = accuracy_score(y_test, hybrid_preds)
print(f" Nihai Hibrit Model Accuracy: {hybrid_accuracy:.4f}")

# NİHAİ MODELİN KAYDI
best_model = {
    "rf_model": rf_best,
    "xgb_model": xgb_best,
    "rf_weight": rf_weight,
    "xgb_weight": xgb_weight,
    "threshold": best_threshold
}

with open("best_hybrid_model.pkl", "wb") as file:
    pickle.dump(best_model, file)

print(" En iyi hibrit model başarıyla kaydedildi!")

# CONFUSION MATRIX GÖRSELLEŞTİRME
plt.figure(figsize=(6, 5))
sns.heatmap(confusion_matrix(y_test, hybrid_preds), annot=True, fmt="d", cmap="Purples")
plt.title("Hibrit Model Confusion Matrix")
plt.show()

# ROC CURVE VE AUC SKORU
fpr, tpr, _ = roc_curve(y_test, hybrid_probs)
roc_auc = auc(fpr, tpr)

plt.figure(figsize=(8, 6))
plt.plot(fpr, tpr, color='blue', lw=2, label=f'ROC curve (area = {roc_auc:.2f})')
plt.plot([0, 1], [0, 1], color='grey', linestyle='--') # Rastgele model çizgisi
plt.xlabel('False Positive Rate (Yanlış Pozitif Oranı)')
plt.ylabel('True Positive Rate (Doğru Pozitif Oranı)')
plt.title('Receiver Operating Characteristic (ROC) - Hibrit Model')
plt.legend(loc="lower right")
plt.show()

print(f" AUC Skoru: {roc_auc:.4f}")

# TAHMİN UYGULAMASI

# MODEL YÜKLEME VE TAHMİN
def predict_failure(lightning_ka, resistance, insulator_mm, voltage_kv):
    with open("best_hybrid_model.pkl", "rb") as file:
        model = pickle.load(file)

```

```

# KAYDEDİLEN MODEL VE AĞIRLIKLAR
rf_model = model["rf_model"]
xgb_model = model["xgb_model"]
rf_weight = model["rf_weight"]
xgb_weight = model["xgb_weight"]
threshold = model["threshold"]

# GİRİŞ VERİLERİNİN DATAFRAME TANIMLAMA
input_data = pd.DataFrame([[lightning_ka, resistance, insulator_mm, voltage_kv]],
                           columns=["Lightning(kA)", "Resistance", "insulator(mm)", "Voltage(kV)"])

# MODEL TAHMİNLERİ
rf_prob = rf_model.predict_proba(input_data)[:, 1][0]
xgb_prob = xgb_model.predict_proba(input_data)[:, 1][0]

# AĞIRLIKLIL ORTALAMA İLE NİHAİ OLASILIK
final_prob = (rf_weight * rf_prob) + (xgb_weight * xgb_prob)

# EŞİK DEĞER İLE KARAR VERME
prediction = 10 if final_prob > threshold else 0

return prediction, final_prob

# KULLANICI VERİ GİRİŞİ
lightning_ka = float(input(" ⚡ Yıldırım Akımı (kA): "))
resistance = float(input(" 🔴 Topraklama Direnci (ohm): "))
insulator_mm = float(input(" 📏 İzolatör Boyu (mm): "))
voltage_kv = float(input(" ⚡ İşletme Gerilimi (kV): "))

# TAHMİN
result, prob = predict_failure(lightning_ka, resistance, insulator_mm, voltage_kv)

# SONUÇ YAZDIRMA
print(f'Tahmin Sonucu: {' ARIZA' if result == 1 else ' NORMAL'}')
print(f'Olasılık: {prob:.4f}')

```

EK-2 TOPLU HALDE ARIZA TAHMİNİ

KÜTÜPHANE YÜKLEME

```
import pandas as pd
import numpy as np
import pickle
```

MODEL YÜKLEME FONKSİYONU

```
def load_model():
    with open("best_hybrid_model.pkl", "rb") as file:
        model = pickle.load(file)
    return model
```

TOPLU TAHMİN FONKSİYONU

```
def predict_bulk(input_csv_path, output_csv_path):
    # Modeli Yükle
    model = load_model()
```

```
    rf_model = model["rf_model"]
    xgb_model = model["xgb_model"]
    rf_weight = model["rf_weight"]
    xgb_weight = model["xgb_weight"]
    threshold = model["threshold"]
```

GİRİŞ DOSYASI OKUTMA

```
df_input = pd.read_csv(input_csv_path)
```

SÜTUN KONTROLÜ

```
required_columns = ["Lightning(kA)", "Resistance", "insulator(mm)", "Voltage(kV)"]
if not all(col in df_input.columns for col in required_columns):
    raise ValueError(f'Hata: Giriş dosyasında şu sütunlar eksik: {set(required_columns) - set(df_input.columns)}')
```

MODEL TAHMİNİ

```
rf_probs = rf_model.predict_proba(df_input)[:, 1]
xgb_probs = xgb_model.predict_proba(df_input)[:, 1]
```

AĞIRLIKLİ ORTALAMA İLE NİHAİ OLASILIK HESABI

```
final_probs = (rf_weight * rf_probs) + (xgb_weight * xgb_probs)
```

EŞİK DEPER KARAR MEKANİZMASI

```
predictions = np.where(final_probs > threshold, 1, 0)
```

SONUÇLARI DATAFRAME E ATMA

```
df_input["Tahmin (Opened)"] = predictions
df_input["Olasılık"] = final_probs
```

SONUÇLARI CSV KAYDETME

```
df_input.to_csv(output_csv_path, index=False)
print(f"✅ Tahminler başarıyla {output_csv_path} dosyasına kaydedildi!")
```

GİRİŞ DOSYASI OKU, TAHMİN ET VE SONUCU KAYDET

```
input_csv = "D:/XXX/XTEZ/tahmin_verileri.csv" # Giriş CSV dosya yolu
output_csv = "D:/XXX/XTEZ/tahmin_sonuc_lari.csv" # Çıktı CSV dosya yolu
```

```
predict_bulk(input_csv, output_csv)
```

EK-3 TAHMİN FONKSİYONU

```

import numpy as np
import pickle
import pandas as pd

# MODELİ YÜKLEME VE TAHMİN FONKSİYONU
def predict_failure(lightning_ka, resistance, insulator_mm, voltage_kv):
    with open("best_hybrid_model.pkl", "rb") as file:
        model = pickle.load(file)

    # Kaydedilen Modelleri ve Ağırlıkları Al
    rf_model = model["rf_model"]
    xgb_model = model["xgb_model"]
    rf_weight = model["rf_weight"]
    xgb_weight = model["xgb_weight"]
    threshold = model["threshold"]

    # GİRİŞ VERİLERİNİ MODELE UYGUN HALE GETİRME
    input_data = pd.DataFrame([[lightning_ka, resistance, insulator_mm, voltage_kv]],
                               columns=["Lightning(kA)", "Resistance", "insulator(mm)", "Voltage(kV)"])

    # TAHMİNLERİ ALMA
    rf_prob = rf_model.predict_proba(input_data)[:, 1][0]
    xgb_prob = xgb_model.predict_proba(input_data)[:, 1][0]

    # AĞIRLIKLİ ORTALAMA İLE SON OLASILIK
    final_prob = (rf_weight * rf_prob) + (xgb_weight * xgb_prob)

    # EİİK DEĞERİ İLE KARAR
    prediction = 0 if final_prob > threshold else 1

    return prediction, final_prob

# KULLANICI VERİ GİRİŞİ
lightning_ka = float(input(" ⚡ Yıldırım Akımı (kA): "))
resistance = float(input(" 🔴 Topraklama Direnci (ohm): "))
insulator_mm = float(input(" 📏 İzolatör Boyu (mm): "))
voltage_kv = float(input(" ⚡ İşletme Gerilimi (kV): "))

# TAHMİN YAPMA
result, prob = predict_failure(lightning_ka, resistance, insulator_mm, voltage_kv)

# SONUÇ YAZDIRMA
print(f'Tahmin Sonucu: {' ⚠️ ARIZA' if result == 1 else '✅ NORMAL'})
print(f'Olasılık: {prob:.4f}')

```

ÖZGEÇMİŞ

Ahmet Yaşar YOLDAŞ

ÖĞRENİM BİLGİLERİ

Doktora	Akdeniz Üniversitesi
2019-2025	Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Antalya, Türkiye
Yüksek Lisans	Akdeniz Üniversitesi
2016-2019	Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Antalya, Türkiye
Lisans	Yıldız Teknik Üniversitesi
2001-2008	Elektrik Elektronik Mühendisliği Fakültesi, Elektrik Mühendisliği, İstanbul

MESLEKİ VE İDARİ GÖREVLER

Mühendis	Uysal İnşaat (2008-2009) TEİAŞ İşletme Bakım Mühendisi (2009-2011)
Başmühendis	TEİAŞ Etüt ve Planlama Başmühendisi (2011-2025) TEİAŞ EİH Tesis Kontrol Başmühendisi (2014-2017, 2024-Devam ediyor) TEİAŞ B Sınıfı İş Güvenlik Uzmanı (2012-2015)

ESERLER

SCI, SSCI ve AHCI indekslerine giren dergilerde yayınlanan makaleler

Yoldaş, A.Y., Carlak, H.F., Özen, Ş. 2025. Yıldırım kaynaklı enerji iletim hattı arızalarının izolatör boyu ve topraklama direnci açısından sınır değerlerinin belirlenmesi. Mühendislik Bilimleri ve Tasarım Dergisi 13(1):286-305 DOI: 10.21923/jesd.1615472

Uluslararası ve ulusal bilimsel toplantılarda sunulan bildiriler

Özen, Ş. ve Yoldaş, A.Y. 2019. Yıldırım elektromanyetik darbelerinin yüksek gerilim hatlarına etkilerinin izolatör ve topraklama açısından incelenmesi. ETUK 2019, Elektrik Tesisat Kongresi, ss. 1-12, 16-19 Ekim 2019, İzmir, Türkiye.

Yoldaş A.Y., Özen Ş., Ateş K. 2023. Enerji iletim hattı güzergâh seçiminde yıldırım faktörünün değerlendirilmesi. VII. Elektrik Tesisat Ulusal Kongresi ve Sergisi, ss. 1-9, 1-3 Kasım 2023, İzmir, Türkiye.