

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DAĞITIK ELEKTRİK ŞEBEKELERİNDEKİ ARIZALARIN TESPİTİ İÇİN MAKİNE ÖĞRENİMİ

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Müh. José Eduardo URREA CABUS

**TEMMUZ 2021
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**DAĞITIK ELEKTRİK ŞEBEKELERİNDEKİ ARIZALARIN TESPİTİ İÇİN MAKİNE
ÖĞRENİMİ**

José Eduardo URREA CABUS

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“ELEKTRİK YÜKSEK MÜHENDİSİ”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 25 / 06 / 2021

Tezin Savunma Tarihi : 28 / 07 / 2021

Tez Danışmanı : Prof. Dr. İsmail Hakkı ALTAŞ

Trabzon 2021

ÖNSÖZ

Her şeyden önce, bana hayattaki tüm zorluklara göğüs gerecek gücü ve enerjiyi verdiği ve hayallerime ulaşma cesaretini bana verdiği için Tanrı'ya minnettarım.

Ebeveynlerim Oscar URREA, Josefina CABUS ve genel olarak aileme sevgileri, manevi destekleri ve cesaretleri için teşekkür eder ve derin şükranlarımı sunarım.

Bu araştırma boyunca verdiği destek, engin bilgisi ve değerli rehberliği için danışmanım Prof. Dr. İsmail ALTAŞ'a en içten teşekkürlerimi sunarım.

Ayrıca arkadaşlarım Hatice OKUMUŞ ve Muhammed Fatih ÖZBAHÇECİ'ye teşekkürü bir borç bilirim.

Ayrıca, teşvik edici çalışma ortamı ve verimli tartışmalar, değerli zaman ve tavsiyeler için her zaman hazır oldukları için Elektrik ve Elektronik bölümündeki geçmiş, şimdiki meslektaşlarım ve öğretmenlerime de minnettarım.

Türkiye Cumhuriyeti devletine teşekkür etmek istiyorum. Bana Türkiye Burslarına katılma fırsatı veren Başbakanlık, Yurtdışı Türkler ve Akraba Topluluklar Başkanlığı (YTB) ve Karadeniz Teknik Üniversitesi'ne yüksek lisansımı yapma şansı verdiği için teşekkür ederim.

José Eduardo URREA CABUS

Trabzon 2021

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “DAĞITIK ELEKTRİK ŞEBEKELERİNDEKİ ARIZALARIN TESPİTİ İÇİN MAKİNE ÖĞRENİMİ” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. İsmail H. Altaş’ın sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 28/07/2021.

José Eduardo URREA CABUS

İÇİNDEKİLER

	<u>Sayfa No.</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VIII
SUMMARY.....	IX
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ.....	XIII
KISALTMALAR DİZİNİ.....	XV
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Literatür Araştırması.....	2
1.3. Amaçlar.....	8
1.3.1. Genel Amaç.....	8
1.3.2. Belirli Amaçlar.....	9
1.4. Çalışmanın Amacı.....	9
1.5. Tez Taslağı.....	10
2. GÜÇ ELEKTRİK ŞEBEKESİ.....	11
2.1. Gidiş.....	11
2.2. Elektrik Güç Sistemi.....	12
2.3. Konvansiyonel Güç Şebekelerini Akıllı Şebekelere Dönüştürme.....	13
2.4. Elektrik Şebekelerinde Dağıtılmış Üretim.....	15
2.5. Güç Şebekesi Çalışmaları.....	16
2.5.1. Güç Şebekelerindeki Elektrik Arızalarına Genel Bakış.....	17
2.6. Elektrik Güç Sisteminin Korunmasında Yeni Yaklaşımlar.....	21
3. MAKİNE ÖĞRENİMİ.....	22
3.1. Giriş.....	22
3.2. Makine Öğrenimi Uygulamaları.....	23
3.3. Makine Öğrenimi Modeli.....	24

3.3.1.	Makine Öğrenmesi Algoritmalarının Türleri.....	25
3.4.	Python’u Makine Öğrenimi İçin Kullanmak.....	27
4.	YAPILAN ÇALIŞMALAR.....	28
4.1.	Giriş.....	28
4.2.	Sistemin Genel Görünümü.....	29
4.3.	Çalışma Durumu.....	31
4.4.	Veri Üretimi.....	32
4.5.	Ayrık Dalgacık Dönüşümü.....	33
4.5.1.	Optimum Ayrıştırmanın Seçilmesi.....	35
4.6.	Özellik Hesaplamaları ve Eğitmensiz Boyut Azaltma Teknikleri.....	37
4.6.1.	Doğrusal Projeksiyon Teknikleri.....	40
4.6.1.1.	Temel Bileşen Analizi.....	40
4.6.1.2.	Çekirdek Temel Bileşen Analizi.....	42
4.6.2.	Manifold Öğrenme.....	43
4.6.2.1.	Yerel Doğrusal Gömme.....	43
4.6.2.2.	İzometrik Haritalama Algoritması.....	45
4.6.3.	Diğer Yöntemler.....	46
4.6.3.1.	Sözlük Öğrenme.....	46
4.6.3.2.	Bağımsız Bileşen Analizi.....	47
4.7.	Eğitmenli Makine Öğrenimi Algoritmalarına Genel Bakış.....	49
4.7.1.	Lojistik Regresyon Algoritması.....	49
4.7.2.	Destek Vektör Makine Algoritması.....	51
4.7.3.	Karar Ağaçları Algoritması.....	52
4.7.4.	Rassal Orman Algoritması.....	53
4.7.5.	K-En Yakın Komşu Algoritması.....	54
4.8.	Hiperparametre Seçimi.....	56
4.9.	Sınıflandırma Metrikleri.....	57
5.	BULGULAR VE TARTIŞMA.....	59
5.1.	Veri İşlemi.....	59
5.2.	Dalgacık Ailesi Seçim Sonuçları.....	65
5.3.	Özellik Önem Analizi.....	69
5.4.	Boyutsal Küçültme ve Makine Öğrenimi Algoritmaları Sonuçları.....	73
5.4.1.	Arıza Tespit Sonuçları.....	74

5.4.2.	Toprak Arıza Tespit Sonuçları.....	78
5.4.3.	Arıza Sınıflandırma Sonuçları.....	82
6.	SONUÇLAR.....	89
6.1.	Sonuç Bölüm.....	89
6.2.	Başlıca Sonuç.....	90
7.	ÖNERİLER.....	92
8.	KAYNAKLAR.....	93
ÖZGEÇMİŞ		



Yüksek Lisans

ÖZET

DAĞITIK ELEKTRİK ŞEBEKELERİNDEKİ ARIZALARIN TESPİTİ İÇİN MAKİNE ÖĞRENİMİ

José Eduardo URREA CABUS

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. İsmail H. ALTAŞ
2021, 101 Sayfa

Bu araştırma, elektrik şebekelerinde simetrik ve asimetrik kısa devrede meydana gelen arazaların algılanması, sınıflandırılması ve analizleri için makine öğrenimi algoritmalarının uygulamalarını kapsamaktadır. Gerekli üç fazlı voltaj ve akım değerleri DIGSILENT yazılımı ile değişik kısıadevre durumlarına göre simülasyon yapılarak üretilmiş ve analizler Python yazılımı ile gerçekleştirilmiştir. İlk olarak, ayırık dalgacık dönüşümü uygulanarak ön veri işleme yapılmış, sonrasında da minimum entropi ayrışma ve Destek Vektör Makinesi algoritması uygulanarak ana dalgacık ve ayrışma seçimi seviyesi için bir model geliştirilmiştir. Eğitimli makine öğrenimi modellerinin performansını artırmak için makine öğrenimi eğitim adımı sırasında eğitmensiz boyut azaltma teknikleri uygulanmıştır. Son olarak, düşünülen özellikler özellik çıkarma yoluyla minimize edilmiş ve daha az özellik göz önünde bulundurarak, model veri kümelerinin aşırı yüklenmesi veya yetersiz kalması önlenmiş ve algoritmaların performansı artırabilmiştir. Geliştirilen algoritma ve yaklaşımlar daha güvenilir koruma yöntemleri elde etmek için farklı arıza problemleri için de uygulanabilir.

Anahtar Kelimeler: Boyutsal Küçültme, Özellikler, Makine Öğrenimi, Eğitimli Öğrenme

Master Thesis

SUMMARY

MACHINE LEARNING FOR FAULT DETECTION IN DISTRIBUTED NETWORKS

José Eduardo URREA CABUS

Karadeniz Technical University
Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Prof. Dr. İsmail H. ALTAŞ
2021, 101 Pages

This research includes applications of machine learning algorithms for the detection, classification, and analysis of disturbances, emphasizing symmetric and asymmetric short-circuit faults in electrical networks. The required triphasic voltage and current values were obtained by simulation with DlgSILENT software according to different short-circuit states, and the analyzes were performed through Python software. First, the preliminary data processing is done by applying the discrete wavelet transform, where a model is developed to select the mother wavelet and level of decomposition by applying the minimum entropy decomposition and Support Vector Machine algorithm. Additionally, unsupervised dimensionality reduction techniques were applied to improve machine learning models' performance during the training step. Finally, features considered are minimized through feature extraction and, by considering fewer features, prevent model data sets from being overfitting and underfitting; hence, the performance of the algorithms can be enhanced. The algorithms and approaches developed can also be applied to different fault problems to obtain more reliable protection methods.

Key Words: Dimensionality Reduction, Features, Machine Learning, Supervised Learning

ŞEKİLLER DİZİNİ

Sayfa No.

Şekil 1. Konvansiyonel güç sistemi.....	12
Şekil 2. Akıllı şebeke temsili	15
Şekil 3. Simetrik arıza, (a) gerilim ve (b) akım değişimleri	18
Şekil 4. Faz-faz arızası sırasında, (a) gerilim ve (b) akım değişimleri	19
Şekil 5. Faz-Faz-Toprak arızası sırasındaki, (a) gerilim ve (b) akım değişimleri	19
Şekil 6. Faz-toprak arızası sırasında oluşan (a) gerilim ve (b) akım değişimleri	20
Şekil 7. Tahmine dayalı modelleme makine öğrenimi iş akışı.....	26
Şekil 8. Önerilen modele genel bakış	30
Şekil 9. Önerilen model akış şemasına genel bakış	31
Şekil 10. IEEE 34 baralı testi değiştirildi	32
Şekil 11. Ayırışma seviyesi temsili	35
Şekil 12. Dalgacık ailesinin akış şeması ve ayırıştırma seviyesi seçimi	37
Şekil 13. PCA tekniği akış şeması gösterimi.....	41
Şekil 14. KPCA tekniği akış şeması gösterimi döndürün	43
Şekil 15. LLE tekniği akış şeması gösterimi	45
Şekil 16. Isomap tekniği akış şeması gösterimi.....	46
Şekil 17. DL tekniği akış şeması gösterimi	47
Şekil 18. ICA tekniği akış şeması gösterimi.....	48
Şekil 19. Simetrik ve asimetrik arıza simülasyonları	60
Şekil 20. (a) Normal koşullar altında, (b) Arızalı koşullar altında	66
Şekil 21. Dört farklı hata türü ve normal koşullar altında Z_v 'nin gösterimi.....	66
Şekil 22. Dalgacık ailesi seçimi için sıfır bileşen gerilim bileşeni doğruluğu sonuçları	67
Şekil 23. Sıfır bileşen gerilim bileşeni hesaplama süresi sonuçları.....	67
Şekil 24. Detay ve yaklaşım katsayıları gösteriminin dokuz ayırıştırma seviyesi	68
Şekil 25. Arıza tespiti için özellik önemine genel bakış.....	69
Şekil 26. Toprak arıza tespiti için özellik önemine genel bakış	69
Şekil 27. Arıza sınıflandırması için özellik önemine genel bakış	70
Şekil 28. Basit bir ML modelleri için işlem hattı akış şeması.....	72
Şekil 29. Önerilen modelden boru hattı akış şeması özeti.....	74

Şekil 30. Arıza tespiti için LR model sonuçları.....	76
Şekil 31. Arıza tespiti için SVM modeli sonuçları	76
Şekil 32. Arıza tespiti için DT model sonuçları	76
Şekil 33. Arıza tespiti için RF model sonuçları.....	77
Şekil 34. Arıza tespiti için KNN model sonuçları	77
Şekil 35. Toprak arıza tespiti için LR model sonuçları	79
Şekil 36. Toprak arıza tespiti için SVM modeli sonuçları	80
Şekil 37. Toprak arıza tespiti için DT model sonuçları.....	80
Şekil 38. Toprak arıza tespiti için RF model sonuçları	80
Şekil 39. Toprak arıza tespiti için KNN model sonuçları.....	81
Şekil 40. Arıza sınıflandırması için LR model sonuçları	83
Şekil 41. Arıza sınıflandırması için SVM modeli sonuçları.....	83
Şekil 42. Arıza sınıflandırması için DT model sonuçları	84
Şekil 43. Arıza sınıflandırması için RF model sonuçları.....	84
Şekil 44. Arıza sınıflandırması için KNN model sonuçları.....	84

TABLÖLAR DİZİNİ

Sayfa No.

Tablo 1. Arıza verileri yapılandırması.....	33
Tablo 2. İstatistiksel Özellikler.....	38
Tablo 3. Ortak çekirdekler.....	52
Tablo 4. Ana metrikler.....	58
Tablo 5. Python kitaplıkları uygulandı.....	58
Tablo 6. Arıza AG sonuçları; üç fazlı gerilim ve akım simülasyonu I.....	61
Tablo 7. Arıza AG sonuçları; üç fazlı gerilim ve akım simülasyonu II.....	62
Tablo 8. Arıza AG sonuçları; sıfır sıralı gerilim ve akım.....	63
Tablo 9. Basit bir ML modeli için doğruluk sonuçları.....	72
Tablo 10. Arıza tespiti için LR hatası ve CM modeli sonuçları.....	77
Tablo 11. Arıza tespiti için SVM hatası ve CM modeli sonuçları.....	77
Tablo 12. Arıza tespiti için DT hatası ve CM modeli sonuçları.....	78
Tablo 13. Arıza tespiti için RF hatası ve CM modeli sonuçları.....	78
Tablo 14. Arıza tespiti için KNN hatası ve CM model sonuçları.....	78
Tablo 15. Toprak arıza tespiti için LR hatası ve CM model sonuçları.....	81
Tablo 16. Toprak arıza tespiti için SVM hatası ve CM modeli sonuçları.....	81
Tablo 17. Toprak arıza tespiti için DT hatası ve CM modeli sonuçları.....	81
Tablo 18. Toprak arıza tespiti için RF hatası ve CM model sonuçları.....	82
Tablo 19. Toprak arıza tespiti için KNN hatası ve CM model sonuçları.....	82
Tablo 20. Arıza sınıflandırma modeli için LR hata sonuçları.....	84
Tablo 21. Arıza sınıflandırma modeli için SVM hata sonuçları.....	85
Tablo 22. Arıza sınıflandırma modeli için DT hata sonuçları.....	85
Tablo 23. Arıza sınıflandırma modeli için RF hata sonuçları.....	85
Tablo 24. Arıza sınıflandırma modeli için KNN hata sonuçları.....	85
Tablo 25. Arıza türüne göre arıza sınıflandırma modeli sonuçları.....	85

SEMBOLLER DİZİNİ

$A_j(\cdot)$	: Yaklaşıklık Katsayısı
a	: Genişleme Faktörü
b	: Çeviri Faktörü
$Cov_{j,q}$	: Kovaryans Matrisi
$\mathbf{D}$	: Sözlük Matrisi
$\mathbf{d}$	: Orijinal Boyutlu Uzam
D_h	: Köken Kümesi
$D_j(\cdot)$	: Detay Katsayısı
D_{left}	: Kök Düğüm, Sol Küçük Düğüme Bölünür
D_{opt}	: Sözlük Optimize Edildi
D_{right}	: Kök Düğüm Sağ Küçük Düğüme Bölünür
D_x	: Köken Kümesi
$DWT_{m,\tau}$	: Kesikli Dalgacık Dönüşümü
E	: Enerji Fonksiyonu
$E_A(A_j)$	: Yaklaşım Katsayılarından Shannon Entropisi
$E(W)$	: Maliyet Fonksiyonu Gösterimi
FP	: Yanlış Pozitif
FN	: Yanlış Negatif
f_α	: Bölmek İçin Uygulanan Özellik
$\mathbf{H}$	: Ağırlık Matrisi
h	: Yüksek Filtre
h_{th}	: Küçük Düğüm
I	: Safsızlık Ölçümü
$J(\theta)$	: Log-Loss Fonksiyon
$\mathbf{K}$	: Çekirdek Matrisi
$\mathbf{K}'$	: Merkez Çekirdek Matrisi
$\mathbf{k}$	: Yeni Boyutlu Alt Uzam
$\kappa()$	: X Çekirdeğini Uygulayan Denklem
l	: Düşük Filtre
m	: Tamsayı Parametresi
N	: Sinyalin Uzunluğu
N_h	: Sayı Örnekleri
$\tilde{n}$	: Örneklerin Uzunluğu
$\mathbf{p}$	: Algoritma Türü
$\mathbf{R}$	: Optimizasyon Sözlüğünden Hata
$S(\cdot)$	: Verilen Sinyal
$\bar{S}$	: Anlamına Gelmek
$\vec{S}$	: Örnek Vektör
S_i	: Ortogonal Bazda S Katsayısı
S_j^i	: Veri Kümesinden J Özelliği
S_q^i	: Veri Kümesinden Q Özelliği
S_{j-1}	: Seviyenin Yaklaşıklığı
S_{clear}	: Açıklık Faktörü

S_{crest}	: Tepe Faktörü
S_{Kurt}	: Kurtosis
S_{MAV}	: Ortalama Mutlak Fonksiyon
S_{RMS}	: Kare Kök Ortalama
S_{Skew}	: Skewness
S_{IF}	: Dürtü Faktörü
S_{SF}	: Şekil Faktörü
SE	: Shannon Entropisi
SDT'	: Standardizasyon Fonksiyonu
TN	: Gerçek Negatif
TP	: Gerçek Pozitif
W	: Dönüşüm Matrisi Düşük Boyutlu Alt Uzay
w_{ij}	: Her Girdinin En İyi Yeniden Yapılandırma Ağırlıkları
Y	: Katsayı Matrisi
y	: Açgözlü Bir Şekilde Katsayı
y_j	: Kısmi Özvektör Ayırıştırması
Y_{opt}	: Açgözlü Bir Şekilde Optimize Edilmiş Katsayı
$\tilde{z}$	: Yeni Düşük Boyutlu Vektör
α	: Düzenleştirme Parametresi
τ	: Tamsayı Değişkeni
$\psi(\cdot)$	: Ana Dalgacık Dönüşümü
$\overline{\mu_j^i}$	: J Özelliğinin Örnek Ortalaması
$\overline{\mu_q^i}$	: Q Özelliğinin Örnek Ortalaması
λ	: Özdeğer
v	: Özvektör
σ^2	: Varyans
σ	: Standart Sapma
$\emptyset$	: Doğrusal Olmayan Öngörülen Fonksiyon
$\Phi(Y)$	: Düşük Boyutlu Uzay Gösterimi LLE
Θ	: Parametre Vektörü
Σ	: Düşük Boyutlu Denklem
$\vartheta(\cdot)$	: Sigmoid İşlevi
$\hat{p}$	: Lr Kullanılarak Tahmin Edilen Olasılığın Vektörleştirilmiş Formu
γ	: Düzenleştirme Parametresi
$()^T$	: Devrik
1_n	: N×N Boyutlu Matris

KISALTMALAR DİZİNİ

AI	: Yapay Zeka
AUC	: Eğri Altında Kalan Alan
CM	: Karışıklık Matrisi
DG	: Dağıtım Üretimi
DL	: Sözlük Öğrenme
DT	: Karar Ağaçları Algoritması
DRT	: Eğitimsiz Boyut Azaltma
DWT	: Kesikli Dalgacık Dönüşümü
ECC	: Enerji Kontrol Merkezi
FT	: Fourier Dönüşümü
HV	: Yüksek Gerilim
IG	: Bilgi Kazancı
ICA	: Bağımsız Bileşen Analizi
Isomap	: İzometrik Haritalama
KNN	: K-En Yakın Komşu Algoritması
KPCA	: Çekirdek Temel Bileşen Analizi
LG	: Faz-Toprak
LL	: Faz-Faz
LR	: Lojistik Regresyon Algoritması
LV	: Alçak Gerilim
LLE	: Yerel Doğrusal Gömme
LLG	: Faz-Faz-Toprak
LLL	: Faz-Faz-Faz
ML	: Makine Öğrenimi
PV	: Fotovoltaik
OvR	: Bire Karşı Geri Kalan
PCA	: Temel Bileşen Analizi
RF	: Rassal Orman Algoritması
RBF	: Dairesel Baz Fonksiyonları
ROC	: İşlem Karakteristik Eğrisi
SPS	: Güvenlik Güç Kaynağı
SVM	: Destek Vektör Makine Algoritması
UPS	: Kesintisiz Güç Kaynağı
WT	: Dalgacık Dönüşümü

1. GENEL BİLGİLER

1.1. Giriş

Günümüzde, güç sistemlerinin yapısı ve kullanılan cihaz teknolojisi sürekli yenilenerek değişmektedir. Güç sistemleri ne zaman ve nasıl meydana geldiği önceden bilinmeyen arızalara maruz kalırlar. Gerekli önlemler alınmaz ve zamanında müdahale edilerek bu arızalar giderilmezse sistem kararsız hale gelip çökebilir. Oysa tüketicilere sağlanan enjinin sürekli ve kesintisiz olması gerekir. Tüketici, yani enerjiyi tüketen müşteri ihtiyaç duyduğunda buna ulaşabilmelidir. Güç sistemi güvenilir olmalıdır. Bunun için de oluşabilecek muhtemel arızaların önceden kestirilmesi veya anında hızlı bir şekilde tespiti ve tanınması gerekmektedir. Günümüz teknolojisi veri toplama, depolama ve hızlı iletimini mümkün kılmaktadır. Toplanan verilerin hızlı değerlendirilip akıllı karar verme mekanizmalarıyla işlenmesi birçok arızanın önceden kestirilmesi veya oluştuğu anda arıza hakkındaki bilgilerin oluşturulması mümkün görünmektedir. Dolayısıyla artık önemli olan hususların başında verilerin sağlıklı toplanması, depolanması ve güvenilir bir şekilde iletilerek değerlendirilmesi gelmektedir. Yapılacak hızlı ve doğru değerlendirmeler güç sistemine olan güveni de artıracaktır.

Elektrik dağıtım sistemlerindeki arızalar, beklenmeyen ve kaçınılmaz olaylara bağlı olarak meydana gelirler. Bu nedenle arızalar, güç sistemini işleten ve enerji temini sürekliliğini sağlayanlar için en önemli endişe kaynağıdır. Alışlagelmiş güç dağıtım sistemlerinde üretim birimleri uzak konumlarındaki elektrik santrellerinde olup, tüketiciye varıncaya kadar transformatörler ve iletim hatlarından geçtikten sonra dağıtım sahasında radyal veya ring yapıda görevlerini yaparlar. Günümüzde bu dağıtım sahasında artık yenilenebilir enerji kaynakları da şebekeye bağlandığından uzaktaki kaynağa bir de yakındaki kaynaklar eklenmektedir. Dolayısıyla yenilenebilir kaynakların tüketim sahasında şebeke ile birleştirilmesi şebekenin yapısını değiştirmekte ve endişelerin daha da artmasına yol açmaktadır. Alışlagelmiş şebeke yapısı dağıtık şebeke yapısına dönüşürken güç sistemi işleticilerinin dağıtık ve akıllı şebekeler hakkındaki endişeleri devam etmektedir. Dağıtık şebeke sorunlarının aşılabilmesi ister istemez akıllı şebekelerin oluşmasına yol açmıştır.

Akıllı şebeke yapısı, işletim ortamlarını standart ve güvenli bir durumda tutmak için sistemlerin sürekli olarak izlenmesine katkıda bulunur. Akıllı şebekelerin uygulanmasıyla ilgili temel zorluklardan biri, gerçek zamanlı sistemlerde güvenilirliği ve performansı

geliştirmek için kullanılan ağdan ve kurulu cihazlardan toplanan verilerdir. Arızaları hızlı bir şekilde tespit etmek ve güç sisteminin hasar görmesini veya bozulmasını önlemek için sağlam bir koordinasyon koruma sistemi de uygulanmalıdır.

1.2. Literatür Araştırması

Dağıtık şebekelerin yapıları gereği veri toplanması, iletilmesi ve değerlendirilerek control, koruma ve işletme amaçlı kullanılması gerekir. Bu amaçla farklı yöntem ve yaklaşımlar karşımıza çıkmaktadır. Örneğin, mevcut çalışma durumunu optimal olarak tahmin etmek için fazladan ölçümler gerektiren bir durum kestirim fonksiyonu [1]'de, uygulanmıştır. Güç sistemi pratik üretim, iletim ve dağıtım olarak üç alt kategoriye bölünmüştür. Enerji sürekliliği güç sistemlerinin bu üç aşamasının iyi işletilmesine bağlı olup, işlevselliği ve kullanılabilirliği insan yaşamı için önemli hale gelmiştir [2, 3]. Bir elektrik güç şebekesi, büyük bir coğrafi alan içerisinde güç iletim ve dağıtım ağları aracılığıyla elektrik enerjisini jeneratörlerden tüketicilere aktaran karmaşık bir sistem olarak tanımlanabilir.

[3]'te ise elektrik şebekesini insanların güvendiği basitçe geliştirilen fakat dünyanın her yerinde başarıyla kullanılan dünyanın en kapsamlı sistemi olarak ifade etmektedirler. Ayrıca, güç cihazlarının ve hatlarının yeterlilik ve güvenilirlik kısıtlamaları altında elektrik gücünün ekonomik olarak sağlanması gibi işlevlerini de tanımlamışlardır. Elektrik şebekelerinin güvenilirliğini artırmak ve güç iletimini daha ekonomik ve sürdürülebilir hale getirmek için şebeke yapısının modernize edilmesi, koruma cihazlarının güvenilirliklerinin ve performansının artırılması gerekir. Özellikle dağıtık üretim ve tüketim şebekelerinin yaygınlaşmaya başlaması, akıllı şebeke ve akıllı şehir kavramlarının ortaya çıkmasıyla cihaz güvenilirliği ve veri aktarımı önemli bir hal almıştır. Artık kullanılan cihazların da akıllı olması, kendi başlarına veya uzaktan operatör desteği ile karar verebilir yapıda olmaları beklenmektedir. Anlaşılabileceği gibi akıllı cihazlar, akıllı şebekeler ve akıllı şehirler derken aslında kastedilen şey büyük veri akışı, depolanması ve kullanılmasıdır. Her cihazdan veri alınması elbetteki beraberinde yeni mali yükler getirirken, bu verilerin iyi kullanılmasıyla bakım ve işletme maliyetlerinin azaltılabilmesi de mümkündür [2,3].

Elektrik şebekelerinin güvenilirliğine olan talep ve gelişen teknolojiyle birlikte artan istek ve beklentiler akıllı elektrik şebekelerindeki sürekli değişim ve yenilikleri de beraberinde getirmektedir. Dolayısıyla, akıllı şebekeler, dağıtılmış üretim, araç şarj

istasyonları, yenilenebilir enerji kaynakları gibi üretim tarafının yanısıra talep tarafı yönetimi için de gelecekteki ihtiyaçları da karşılayacak bir altyapının oluşturulmasına öncülük edebilir [4-7]. Ayrıca, güvenlik ve güvenilirliği sağlamak için enerji sisteminin durumunu izlemesini de sağlar. Güç sisteminde meydana gelen olaylar ve etki sürelerine ait veriler bu sistemin risk veya başarısızlık tarihi hakkında bilgi verebilir. Bu verilerin değerlendirilmesi ile akıllı şebeke güvenilirliği ve altyapı güvenlik açığı analizleri yapılabilir. Aslında araştırmacılar güç sistemleri güvenirliliği ve güvenliğine yönelik arıza tanımlama ve algılama konusunu uzun zamandır çalışmaktadırlar [4-7]. Çalışmalar genelde karmaşık güç sisteminin normal koşullar altında nominal değerlerinde düzgün çalışırken bu büyük ve karmaşık güç şebekesinin belirli bir yerindeki olumsuzluklara odaklanmakta ve bunlara çözüm getirmeye yöneliktir. Ancak iyi bilinmektedir ki, özel bir elemandaki bir arıza tipik olarak tüm sistemin performansını etkiler. Bu nedenle üretim döngülerinde gecikmelere veya hayati önem taşıyan makinelere zarar gelmesini önlemek için sistemdeki arızaların analizi mümkün olan en kısa sürede yapılması ve tüm şebekeye yayılması önlenmelidir [8-12].

[13, 14]'te bilinmeyen veya gizli hataları belirlemek için makine öğrenimi algoritmalarının sağlamlığından hareketle ağ yönetimini iyileştirmek için Bayes algoritmasını kullanan olasılık temelli bir çözüm önerdiler. Ayrıca, verimli ve dayanıklı güç şebekeleri için [15]'te büyük ölçekli veri iletimi ve analiz altyapısının devreye alınmasını gerekli olduğunu ortaya koydular. Bu şekilde merkezi olmayan sistemlerle başa çıkmak için geniş alanlı bir ölçüm sistemi (WAMS) geliştirip, akıllı şebekelerde ölçüm verilerinin iletimi için karmaşık bir iletişim ağı topolojisi hazırladılar. [16]'da güç sisteminin güvenilirliğini artırmak için bir mesafe koruma yaklaşımı kullanarak, iletim hatlarındaki arıza tespiti ve konum belirlenmesi için Sinir Ağları Geri Yayılım algoritmalarını (NNBP) önerdiler. [17]'de, geleneksel Hızlı Fourier Dönüşümü (FFT) incelemesine benzetildiği DC sistemlerinde ark hatası tespiti için dalgacık dönüşümü tabanlı bir yaklaşım kullandılar. Ayrıca, [18]'de genelleştirilmiş yerel olabilirlik oranı testine dayalı bir düzeltme algılama algoritması geliştirerek, fotovoltaiik enerji (PV) sisteminin farklı çıkış sinyallerini değerlendirmek için çoklu sayaç kullanımı gibi yaklaşımlar önerdiler.

Son on yılda, güç sistemlerinde dağıtılmış üretim uygulamalarının artmasıyla merkezi olmayan bir enerji dağıtım modeline doğru hızlı bir geçiş başladı. Dağıtık üretime sahip mikro şebekelerde üretim artışına ihtiyaç duyulduğunda bunun bu şebeke içindeki kaynaklardan karşılanması halinde iletim kayıplarının ekonomik açıdan değerlendirmeye alınmasına gerek kalmaz [19, 20]. [21 ve 22]'de, dağıtılmış üretim birimlerini dağıtım

şebekesine veya sayacın tüketici tarafına bağlanan küçük üretim adacıkları olarak tanımlanmışlardır. Dağıtık dağıtım şebekelerindeki arıza analizi karmaşıklığının bir sonucu olarak, son yıllarda dağıtık nesillerin kullanımı gelişmiştir. Geleneksel güç dağıtım sistemleri, bir yönlü akış ağacı şeklinde yükleri besleyen radyal bir sistem olarak tasarlanmaktadır. Bazen ring (kapalı çevrim) yapıya da sahip olsalar, uzaktaki kaynaktan beslendikleri için aradaki transformatör ve hat empedanslarını da barındırdıklarından arızalar sönümlü olur. Dağıtılmış üretim yapısı ring içerisinde farklı noktalardan ve farklı kaynaklardan beslendiğinden artık radyal değildir. Dolayısıyla arıza mesafesi ve konumlarını bulmak radyal yapıya göre daha karmaşıktır. Arıza konumlarını elde etmek için araştırmacılar ek arıza yön sinyalleri önermektedirler [19]. Ayrıca yapılan çalışmalarda dağıtık güç sistemlerin korunmasını ve güvenilirliğini garanti altına almak için farklı arıza tespit yaklaşımları geliştirilmiştir [23-26]. Arıza başlangıcı ile ifşası arasındaki gecikmeyi analiz ederek, Yapay Sinir Ağları (YSA), Bulanık Mantık ve her ikisinin birleşimi ile akıllı karar verme yöntemleri bunlardan birisi olarak gösterilebilir [27]. Tüm arıza türlerini doğru bir şekilde ayırt edebilmek için daha fazla tanıma testi ve tasarım optimizasyonu gereklidir.

[28]'de Dağıtım Sistemi Planlaması (DSP) için ekonomik ve operasyonel avantajlarla başa çıkmak amacıyla elektrik güç temini sorunu olmayacak şekilde yük artışı ihtiyaçlarını uygun bir fiyata karşılama kararlılığı sunan bir yaklaşım önerdi. Ayrıca [29]'da dağıtık güç ağ mimarisini optimize etmek için Parçacık Sürü Optimizasyon algoritması (PSO) ile her bir alt sinir ağını paralel veya seri olarak birleştiren çok aşamalı bir çerçeve önerdi.

Yenilenebilir kaynaklarla yapılan üretim artışı ve talep tarafının bu kaynaklara yönelim isteği, dağıtık güç sistemlerinin yapısını gittikçe karmaşıklık ve belirsiz bir duruma sokmaktadır [30]. Dağıtık üretimdeki belirgin ve durdurulamaz artışın etkisi ile güç iletim ile uğraşan mühendisler sistemin bağlantı konfigürasyonları ve performansı için yeni görüş ve istekler ortaya koymaya başladılar [21-30]. Akıllı şebekenin amacına uygun çalışabilmesi için şebeke ağı içerisine yayılmış tüm şebeke elemanları ve tüketiciler arasında yaygın bir algılama ve iletişim kurulabilmesi ancak bilgi teknolojilerinin kullanılmasıyla mümkün olabilir. Son yıllarda araştırmacılar izmet güvenilirliğini koryrken, şebeke performansını iyileştirmek ve kontrol etmek için Yapay Zekâ (Artificial Intelligence – AI) temelli yöntemler kullanmaya başladılar.

Bu araştırma, güç kalitesi bozukluklarını ayırt etmek için akım ve gerilim dalga biçimlerine ait sinyallerin Makine Öğrenimi (Machine Learning – ML) algoritmaları ile değerlendirilmesine odaklanmaktadır. Yapılan çalışma, literatürdeki benzerlerini

tamamlayıcı özelliktedir. Örneğin, radyal şebekelerdeki arızaları ayırt edebilmek için genelde gerilim ve akım transformatörleri üzerinden alınan sinyallerin analizi için yapay sinir ağı destekli vektör makinesi algoritmalarının birleşiminden oluşan yaklaşımlar halihazırda araştırmacılar tarafından çalışılmıştır [31-36]. Yaptıkları çalışmada [37] güç sistemlerinin güvenilirliğini korumak için geleneksel sayısal yöntemlerin kullanılması halinde çevrimiçi güvenlik değerlendirmesinin hesaplama açısından pahalı ve zorlu olduğunu, bunun da sistemi büyük ölçekli elektrik kesintilerine karşı duyarlı hale getirdiğini gösterdiler. Bu eksiklikleri gidermek amacıyla uygulanan ML algoritmaları, sağlam örüntü tanıma, öğrenme yetenekleri ve potansiyel güvenlik işaretlerini hızlı sınıflandırabilmeleri nedeniyle farklı bir yaklaşım olarak ortaya çıkmışlardır. ML algoritmalarının güç sistemlerindeki bir uygulaması tarafından yapılmıştır [38]. Burada yazarlar yüksek kestirim yetenekleri nedeniyle ML algoritmalarını fiyat aralıklarının iyileştirilmesinde ve belirsizlik içeren kestirimlerin doğrulanmasında kullandılar.

[39]'da sezgisel işlem gerçekleştirebilen modern cihazlar ve stratejilerine ihtiyaç duyan güç sistemi uygulamalarında büyük hacimli endüstriyel verilerin üretilebildiğini ve aktif olarak toplandığını göstermişlerdir. Güç sistemindeki yoğun sınırlama koşulları karar verme algoritmalarını daha karmaşık hale getirmektedir. Bu nedenle, büyük hacimli verileri işleme kapasiteleri ve iddialı olmaları nedeniyle ML algoritmaları uygulanarak daha iyi karar verme sonuçlarına ulaşılabilmektedir.

[40]'te yazarlar, bir iletim hattındaki koruma sistemleri için arka yayılma nöral ağıları gibi denetimli makine öğrenmesini uyguladı. Çalışma, Faz-Toprağa, Faz-Faz-Toprağa, Faz-Faz arızalar ve sistem üzerinde çift hat hatalarına analiz etme hattı yapıldı. Analizden elde edilen sonuçlara rağmen, analiz sırasında uygulanan veri işleme veya özelliği, önemli ölçüde değişebilir, bu da eğitim modelleri sürecinde gizli katmanlar tasarımını ve karmaşıklığı ve hesaplamalı zamanını etkileyebilecek olan, önemli ölçüde değişebilecek bir kanıt yoktur.

[41]'de yazarlar, olaylar tarafından üretilen artık akımlara dayanarak yüksek empedans hatalarını (HIFS) tespit etmek için veri madenciliğini makine öğrenme ortamı olarak uyguladı. HIFS sınıflandırıcısını geliştirmek için, WEKA (Bilgi Analizi için Waikato Ortamı) adı verilen bir çerçeve uygulandı. Bu çerçeve, HIFS niteliklerine uygulanan sınıflandırma kurallarına veya karar ağaçları modellerine dayanmaktadır. Bununla birlikte, modellerin tanımlanması ve ön işleme adımlarının anlaşılması eksikliği, makine öğrenme modelleri sırasında HIF açıklaması için sorgulanabilir.

[42]'de yazarlar, Makine öğrenme modellerinin adaptasyonu olan Intelarc adlı bir model uygulayarak DC sistemlerinde ark hataları belirlendi. Model, çalışma koşullarında geçici davranış sırasında sinyal ön işleme için zaman frekansı ve zaman alanını uygulamak için çeşitli senaryoları değerlendirir. Makine öğrenme modellerinin seçimi, farklı sistem çalıştırma koşullarında tanısal hassasiyet ve klişeleşmenin iyileştirilmesi gerekliliği ile tetiklendi. Bununla birlikte, yaklaşımlarının ana dezavantajı, genellikle kullanılamayan hata verileri için bir gerekliliktir ve modelin daha tatmin edici doğruluk seviyelerine ulaşabilecek özelliklerin belirlenmesi.

[43]'de yazarlar, güç sistemlerinde hata algılama ve sınıflandırma için makine öğrenimine dayanarak bir yaklaşım geliştirmiştir. Ana fikir, hatalı operasyonları daha iyi tanımak için Phasor ölçüm akışlarının gecikme bilgilerini kaldırmaktır. Böylece, analizinin ana özellik olarak hata algılama süresini dikkate alıyordu. Bununla birlikte, özellikleri analiz edilen farklı senaryolar için analizi sınırlandırdı. Öte yandan, çalışma, farklı makine öğrenme modelleriyle doğrulamak ve karşılaştırmak için gerçek ağ veya gerçek zamanlı simülasyon verileri tarafından test edilmesi gereken simülasyon verileri yoluyla yapıldı.

[44]'te yazarlar, makine öğrenme modellerini uygulayarak çok aşamalı hata tanımlamayı çözmek için bir yöntem önerdi. İlk olarak, analizleri için kullanılan veriler, voltaj ve akımın toplandığı ve analiz edildiği IEEE 13 veri yolu testi kullanılarak simüle edildi. Daha sonra, arıza tanımlaması için denetimli öğrenme uygulandı ve K-arac kümelenme tekniği, genel verimliliği arttırmak için eksik verileri prognostatlamak için kullanılır. Bununla birlikte, analiz, tahmini için sadece enerji hesaplamasını kullanarak, analiz faz arızasına dayanıyordu. Bu nedenle, ön işleme verileri ve farklı özellikler, çalışma sırasında daha iyi analiz sonuçları üretebilir.

[45]'te yazarlar, hatalı besleyici algılama için sürekli dalgacık dönüşümü ve konvial nöral ağını uygulayan bir çalışma önerdi. Çalışma, bir hatayı bir hatayı tespit etmek için ses besleyicilerine karşı karşılaştırmaktan ibarettir. Çalışma sonuçlarının, önerilen yaklaşımın, geleneksel makine öğrenme algoritmasından daha iyi performans gösterdiğini doğrulamıştır. Bununla birlikte, sürekli dalgacık dönüşümünün uygulanması performansı etkileyebilir. Önceki araştırma, sinyal ön işleme için sürekli dalgacık dönüşümünün uygulanmasının dezavantajlarından birinin, sinyalin yeniden yapılanması sırasında yüksek karmaşıklık hesaplama süresi ve sınırlaması olduğunu doğrulamıştır.

[46]'da yazarlar, analiz için dalgacık dönüşümü ve karar ağaçları uygulayan mikrogritler için akıllı bir koruma sistemi sundu. Enerji, entropi ve standart sapma,

sinyallerden çıkan özellikler ve dalgacık dönüşümü yoluyla ön hazırlanmıştır. Bu çalışmada en kritik mesele, güvenilirliği ve güvenilirliği artırabilecek veri madenciliği modellerini geliştirmek için zaman-frekans verilerini kullanmaktır.

[47]'de yazarlar, indüksiyon motorları için arıza teşhisi için makine öğrenme modelleri uygulandı. Mevcut sinyal, birkaç istatistik önlemi çıkarılan ayrık dalgacık dönüşümü ile uygulandı ve işlendi. Bu araştırmanın en alakalı katkısı, veri ön işleme için önemli bir unsur olan ana dalgacıkların ilk tanıtımıydı; En alakalı anne dalgacıklarının seçilmesinin, makine öğrenme algoritmalarından yüksek performans yaratabileceği kanıtlanmıştır. Ancak, bu araştırmada manuel bir uygulama yapıldı. En iyi anne dalgacık dönüşümünü seçmek ve ayırma seviyesi önemli bir görevdir. Bu nedenle, seçim sürecini optimize etmek için farklı yaklaşımlar uygulanabilir.

[48]'de yazarlar, çapraz korelasyon uygulayarak dağıtılmış bir ağ sistemi üzerinde hata algılamayı çalıştı ve genetik algoritma bir regülatör olarak uygulanır. Analiz, sıfır dizilim akımını sistemden normal veya hatalı koşullar altında çıkarmaktan ibarettir. Bu metodolojinin dezavantajı, modelin hesaplamalı zamanı ve karmaşıklığıdır. Bununla birlikte, desen tanıma teknikleri ve yeterli makine öğrenme modelleri uygulanarak daha iyi sonuçlara ulaşılabilir.

[49]'da yazarlar, bir güç sistemindeki arıza tespiti ve sınıflandırması için bir perürbans sırasında frekans sinyalleri uygulanarak bir makine öğrenme çerçevesi sunmuştur. Veri ön işleme için, Dalgacık Dönüşümü ve istatistik katsayıları kullanılmıştır. Bu çalışma, farklı eğitim özelliklerinin uygulanmasının, doğruluk sonuçlarında önemli varyasyona ulaşabileceğini doğrular. Bununla birlikte, Dalgacık Dönüştürme Uygulaması, sinyal rekonstrüksiyonu ve ayırma sırasında kayıplar nedeniyle hesaplamalı olarak pahalı ve daha az güvenilir bir sistem yapar. Ayrıca, özellik seçimi veya boyutsallık azaltma tekniklerini uygulayarak daha iyi performansın ulaşılabilir. Böylece, veri ön işleme adımlarındaki bir dezavantaj sunulmuştur.

[50]'de yazarlar, bir gemi güç sisteminde arızaların otomatik sınıflandırması için makine öğrenme tekniklerinin yeterli olabileceğini okudu. Yapılan testler, boyutsallığın azaltılmasının bu amaç için sınıflandırma oranlarını önemli ölçüde artırmadığını ve bu hata türlerinin önemli ölçüde artmadığını göstermektedir. Bununla birlikte, lineer projeksiyon teknikleri ve eğrisel bileşen analizi ve Sammon haritalama gibi lineer projeksiyon teknikleri ve doğrusal olmayan modeller gibi boyutsallık azaltma tekniklerinin tanıtılması, özellik

ekstraksiyon tekniklerinin yapıldığı zaman şekli olmayan bağımlılığın araştırılması için başlatılan noktaya verir.

Bu tez çalışmasında, dağıtık bir üretim sistemindeki elektriksel arızaların algılanması, sınıflandırılması ve analizleri için makine öğrenme modellerinin uygulanması incelenmiştir. Bu araştırma boyunca incelenen kısadevre arızaları Faz-Toprak (Line-Ground – LG), Faz-Faz-Toprak (Line-Line-Ground – LLG), Faz-Faz (Line-Line – LL), Faz-Faz-Faz (Line-Line-Line – LLL) türü arızalardır. Başvuru modellerinin daha önce belirtilen literatürdeki referanslara başvurarak analiz için beş eğitmenli makine öğrenimi modeli uygulanmıştır. Ek olarak, modellerin giriş sinyalindeki zorluklarını tanımlamak için sinyallerin on iki çeşit özelliği dikkate alınır. Literatürde, analiz için kullanılan veri özelliklerinin yeterince keşfedilmediği, makine öğrenme algoritmalarının hassasiyetini etkileyebilecek beklentileri oluşturduğu görülmüştür. Dolayısıyla, bu çalışmada, eğitmenli makine öğrenme modelinin doğruluğunu ve etkinliğini ve elektrik sistemlerinde arızaların tespiti alanındaki uygulamalarını iyileştirmek için özelleştirme teknikleri ile birlikte denetimli makine öğrenme modelleri incelenmiştir. Aynı zamanda, sinyal işleme için dalga paketlerini seçme optimizasyon yöntemi önerilmiştir. Önceki çalışmalarda, sinyal işleme için farklı ortogonal dalgalar uygulanmıştır. Ancak, hiçbirisi sonuçları beklenen doğrulukta sağlamamıştır. Bu nedenle, asgari entropiye ayrışan ve destek vektör makinesine dayanan bir model, sinyallerin ayrışma seviyelerinin uygun seçimi için bu çalışmada gözden geçirilmiştir.

1.3. Amaçlar

1.3.1. Genel Amaç

Bu araştırma, dağıtılmış bir ağ üzerindeki arızaların tespiti ve sınıflandırılmasında kullanılan yaklaşımlardaki çeşitli algoritmalar arasında bir karşılaştırma yaparak öneriler sunmayı amaçlamaktadır. Yapılan çalışma, geçmişe ait arıza anlarındaki gerilim ve akım verilerini matematiksel modeller ve makine öğrenimi algoritmalarında kullanarak arıza riskini tahmin eden modellere dönüştürmeyi amaçlamaktadır.

1.3.2. Belirli Amaçlar

1. Güç sistemlerinin izlenmesini, doğruluğunu ve güvenilirliğini iyileştirmek için örüntü tanıma analizine dayalı bir arıza tespit ve sınıflandırma yaklaşımı geliştirmek.
2. Farklı makine öğrenimi tekniklerini arıza ayırt edici olarak değerlendirmek.
3. Öznitelik çıkarma modelleri olarak eğitimsiz boyut indirgeme tekniklerinin uygulamalarını incelemek.
4. En iyi ayırıştırma seviyesini ve dalgacık ailesini seçmek için bir dalgacık dönüşüm modeli geliştirmek.

1.4. Çalışmanın Amacı

Elektrik arızı, yakın geçmişte büyük ve hızlı gelişmeler yaşayan en talepkar yüksek kaliteli hizmetlerden biridir. Bu nedenle, hata tespit sistemlerindeki gelişmeler, verilerin hızlı bir şekilde toplanmasını, depolanmasını ve iletilmesini sağlaması nedeniyle güvenilir hizmetler için kritik öneme sahiptir. Günümüzde Makine Öğrenimi, esnekliği ve karar vermeye yardımcı olan etkileyici bilgi işleme hızları nedeniyle veri analizi için dünya çapında moda bir kelime haline geldi ve onu zorlu koruma sistemleri standartlarına uygun hale getirdi. Bu araştırma, çeşitli arıza tespit ve sınıflandırma yaklaşımlarını karşılaştırmayı ve geçmiş elektrik şebekesi verilerini eğitimsiz özellik çıkarma teknikleri ve makine öğrenimi algoritmalarını kullanarak arıza riskini tahmin eden modellere dönüştürmek için genel bir yöntem geliştirmeyi amaçlamaktadır.

Hataları ayırt eden bir kıyaslama seti tanımlayan ve hata durumlarını diğer durumlardan etiketlemek için veri madenciliği tekniklerini kullanan bu modeller, ilgili verileri elde edip sentezleyebilir ve bunları karar verme için yeterli şekilde ifade edebilir. Makine Öğrenimi modellerini kullanmanın tüm faydalarına ek olarak, analiz edilen verilere odaklanmak gerekir. Veriler, modelin değerlendirildiği verilerin kalitesine dayalı olarak tahminlerin doğruluğunu etkileyebilecek kritik bir yönü temsil eder. Ne yazık ki, literatür taramasında bahsedilen önceki katkılara rağmen, veri ön işleme ve özellik analizi adımı ilgi eksikliği gözlemlendi. Ek olarak, önceki literatür, sinyal analizi için farklı dalgacık ailelerinin kullanıldığını bildirmiştir; ancak hiçbirisi seçimleri için herhangi bir gerekçe veya prosedür sunmamıştır. Bu nedenle, kullanılan verilerin kalitesini garanti etmek ve makine

öğrenimi modellerinin performanslarını artırmak için bu araştırma, veri ön işleme için dalgacık seçimi ve eğitmensiz boyut azaltma tekniği uygulamalarına dayalı bir model önermektedir.

1.5. Tez Taslağı

Tez şu şekilde organize edilmiştir:

1. Bölümde güç sistemlerinin genel yapısı ve mevcut arızalar sorunları hakkında genel bir giriş bilgisi verilmiştir.
2. Bölümde güç sistemlerindeki mutemel arıza türlerinin tanımları, kritik açıklamaları tezin altyapısı için literatür taraması yapılarak elde edilen gözlem ve bilgilendirmeler verilmiştir.
3. Bölümde çalışmada uygulanan ML uygulamaları ve programlama dili tanıtılmıştır.
4. Bölümde bu çalışmada uygulanan metodoloji sunulmuştur.
5. Bölümde simülasyonlar ve uygulamalardan elde edilen sonuçlar verilmiş ve bir arıza oluştuğunda algoritmaların verdiği kararların doğrulukları gösterilmiştir.
6. Bölümde elde edilen sonuçlar değerlendirilmiş ve gelecekteki araştırmalar için öneriler verilmiştir.

2. GÜÇ ELEKTRİK ŞEBEKESİ

Bu bölümde güç sistemlerinin genel yapısı hakkında bilgi verilmektedir. Klasik (alışlagelmiş) ve dağıtık üretime sahip güç sistemi yapıları bu bölümde açıklanmaktadır. Dağıtık üretime sahip güç sistemlerinden dağıtık şebeke ve akıllı şebeke kavramlarına geçiş ve bu kavramların ne olduğu konusunda bilgi verilmektedir. Son olarak da dağıtık güç sistemlerindeki arıza türleri, özellikleri ve dalga biçimleri tartışılmıştır.


2.1. Gidiş

Elektrik enerjisi, yüksek iletim verimliliği, iletim güvenirliliği ve esnek maliyeti nedeniyle en iyi bilinen ve tercih edilen enerji türüdür. Elektrik, dünya çapında her bireyin günlük yaşamının her aşamasında yer alan ve yaşam standardını yüksek tutmak için kullanılan temel araçtır. Yüksek yaşam standardı için belkemiği olduğunu söylemek yanlış da olmaz. Bu nedenle, insanların konforunu ve yaşam standardının etkilemeyecek şekilde güvenilir bir güç sistemi ağı ve işletilmesi herkesin beklentisidir. Sürdürülebilir güvenirliliğe sahip bir güç sistemi ağı aslında karmaşık bir yapıya sahip olup istikrarını artırmak için disiplinler arası çalışmalar yapılmasını da gerektirmektedir [1]. Özellikle elektrik mühendisliğinin yanı sıra elektronik, haberleşme ve bilgisayar mühendisliklerinin de çalışmalara önemli katkıları olacağı düşünülmektedir.

Aslında enerji, herhangi bir ulusun gelişmesi için vazgeçilmez bir gerekliliktir. Son yıllarda yenilenebilir enerji kaynaklarının kullanımındaki artışın bir sonucu olarak, fosil yakıt tüketimi önemli ölçüde azalmıştır. Güç sistemleri, benzersiz özelliklere sahip en büyük, en karmaşık ve gelişmiş yapay sistemlerdir [1, 51]. Bir güç sisteminin verimli olması için kararlı, güvenilir ve uygun maliyetli olması gerekir. Bu nedenle, güç sistemlerinin izlenmesi ve analizi elektrik mühendisleri için en önemli çalışma alanıdır. Güç sistemi değişik kademelerinde farklı gerilim sevipleri ve akım değerlerinde çalışır. Bu durum çoklu voltajlarda çalışan iletim ve dağıtım hatlarından da farklı akımların aktığı, farklı güçlerin iletildiği bir yapı ortaya koyar [51, 52]. Sadece bu durum bile güç sistemlerinin ne kadar karmaşık bir yapıya sahip olduğunu göstermektedir.

2.2. Elektrik Güç Sistemi

Bir Elektrik Güç Sisteminin geleneksel bir temsili Şekil 1’de gösterilmiştir ve dört ana unsura ayrılmıştır: üretim, iletim ve alt iletim, dağıtım ve yükler/müşteriler [52]. Bir elektrik şebekesi, güç sistemlerinin temel bir parçası olarak üretim noktasında başlar. Hidrolik, termik veya nükleer santrallerde üretilen elektrik gücü kayıpları azaltmak ve iletimi kolaylaştırmak için yükseltici transformatörler (YT) ile 154 kV veya 380 kV gibi yüksek gerilime yükseltilir ve havai hatlarla uzak mesafelere iletilir. Tüketim sahasına varınca indirici transformatörler (İT) ile 69 kV, 34.5 kV veya daha düşük dağıtım gerilimi düzeyine indirilir. Dağıtım, arazi ve yerleşim durumuna bağlı olarak havadan veya yeraltından yapılır. Dağıtımın uç noktasında dağıtım transformatörleri (DT) yer alır ve dağıtım gerilimi de tüketim gerilimi değerine düşürülür. 1000 V altı alçak gerilim (AG) olarak isimlendirilen tüketim gerilimidir. En uçtaki tüketiciye ulaşan gerilim değeri ülkelere göre farklılıklar gösterebilir. Örneğin Türkiye’de bu gerilim DT çıkışında 230/400 iken kuzey Amerikada biri 120/208 V olmak üzere 4 farklı NEMA standardı vardır.



Şekil 1. Konvansiyonel güç sistemi

Enerji, insanlığın ilerlemesi ve hayatta kalması için hayati önem taşımaktadır. İhtiyaca bağlı olarak, bir şeyleri çalıştırma yeteneği (örneğin, kinetik veya potansiyel enerjiyi elektrik enerjisine dönüştürmek) olarak tanımlanabilir. Son yıllarda, fosil yakıtı dayalı kömür, gaz ve petrol tüketiminin dünya çapında hava kirliliğine ve küresel ısınma artışlarına yol açtığı iyice aşikâr olmuştur. Kirlilik sorunlarını ve sera gazlarını azaltmak isteyen ülkeler,

yenilenebilir enerji kaynaklarının kullanımını artırıp, fosil yakıta dayalı tüketimi azaltmaya çalışmaktadırlar. Güneş, rüzgar, gelgit, hidroelektrik ve biokütle enerjisi gibi yenilenebilir enerji kaynaklarından sağlanan elektrik gücü üretimi ve tüketimi artarken, fosil yakıta dayalı termik santraller ve enerji dönüşüm aşamalarında riskler bulunması nedeniyle nükleer enerjinin de daha az kullanılması [51- 53] hedeflenmektedir.


2.3. Konvansiyonel Güç Şebekelerini Akıllı Şebekelere Dönüştürme

Elektriği tüketicilere güvenilir bir şekilde sunmak, her zaman geleneksel elektrik şebekelerinin amacı olmuştur. Şebeke genişletmeleri (yani, artan üretimler ve hatların oluşturulması), elektrik şebekesinin güvenilirliği ile ilgili sorunlarla başa çıkmak için bir önlem olarak kabul edilmekteydi. Ancak bu yöntem yüksek maliyetlere neden olmaktaydı [6]. Günümüzde, maliyetleri düşürme ve elektrik şebekesinin güvenilirliğini artırma isteği nedeniyle, işletmeciler şebekenin benzersiz gereksinimlerini düşük bir maliyetle yeterince karşıladığından emin olmak için kapsamlı değerlendirmeler yapmışlardır [2]. Örneğin, gömülü sistemlerin uygulanmasındaki gelişmeler, şebekedeki izleme ve kontrol işlevlerini iyileştirdi. Bununla birlikte, artan talepler ve gelişmiş bileşenlerin mevcudiyetinin elektrik enerjisi endüstrisini gelecekteki elektrik şebekelerinin zorluklarının neler olduğunu ve bunları başarmak için alternatiflerin neler olduğunu yeniden değerlendirmeye yönlendirmek zorunda kaldığı güç şebekeleri daha karmaşık hale geldi [5, 6, 14]. Öte yandan, sistemin dinamik güvenliğini gerçek zamanlı olarak değerlendirmek, güç sistemi işletimindeki ana zorluklardan biri olmuştur. Ayrıca, güç sistemi güvenliği veya güvenilirliği, sistemin beklenmedik bozulmalar ve belirsizlikler altında kesintiler oluşturmadan kararlı ve kontrol edilebilir kalabilmesi gibi tanımlanabilir [6].

Toplumdaki kullanımları açısından güç sistemlerinin üç temel özelliği ortaya çıkmıştır. Örneğin, güvenlik sistemleri ve gözlem teknolojilerindeki gelişmeler nedeniyle insanların güç sistemleriyle doğrudan teması azaltılmıştır. Bu durum can kayıplarının da azalmasını sağlamıştır. Elbetteki insan çalışma güvenliği işletmeciler için birinci öncelik olarak kabul edilmektedir [4, 6]. İkinci öncelik, sistemlerin normal çalışma koşullarında çalışmasını sağlamaktır, yani güvenilir ve ekonomik bir çalışma için tüm sistemin izlenmesi esastır [6]. Dolayısıyla, araştırmacılar, Enerji Kontrol Merkezi (ECC) adı verilen yeni bir birleşik kontrol sistemi uygulamaya karar verdiler. Başka bir deyişle, şebekenin geneline yayılı uzak ve yakın noktalarından toplanan bilgiler (sinyaller) merkezi bir bilgisayarda

toplanıp burada değerlendirilmektedir [52]. Son olarak, cihazların ve elektrik hatlarının korunması olarak üçüncü bir öncelik öne çıkmaktadır. Son yıllarda gelişen teknolojiler, güvenlik riskleri konusundaki farkındalığı ve güvenilir bir altyapıyı sürdürmek için bilgilerin doğru yönetimini sağladı [2, 4]. Bu nedenle, akıllı şebekelerin uygulamaları üzerinde yürütülen araştırmalar, güç şebekelerinde hizmet güvenilirliğini, uyarlanabilirliği, üretkenliği ve sürdürülebilirliği artırmıştır [1]. Akıllı şebeke, şebeke durumuyla ilgili hizmetlere daha iyi “durumsal farkındalık” sağlamak için ara bağlantı ve veri teknolojilerini kullanmaktadır.

Örneğin, tahmin analizi gerçekleştirmek için veri toplama sistemlerini kullanmak, akıllı talep tahminlerinden gelen gücü dengeleyebilir. Ayrıca, sistem üzerinden akıllı ara bağlantılar, yük atma ile birbirini dengeleyen pik talebi azaltabilir. Üstelik, tüketicilerin kapasitesi, enerji maliyetlerini kontrol etmelerine yardımcı olan fiyat sinyallerini elde edebilir ve bunlara yanıt verebilir [3]. Sonuç olarak, Avrupa Teknoloji Platformu Akıllı Şebekeler, akıllı elektrik şebekeleri terimini şu şekilde tanımlamaktadır [54]: “Elektrik şebekeleri, kendisine bağlı tüm kullanıcıların (jeneratörler, tüketiciler ve her ikisini de yapanlar) davranış ve eylemlerini akıllı bir şekilde entegre edebilen, sürdürülebilir, ekonomik ve güvenli”. Şekil 2’de akıllı şebeke modeli verilmiştir. Akıllı şebeke yapısında bütün üretim ve tüketim birimleri arasında bir veri transfer ağı da mevcuttur. Toplanan veriler dağıtık kontrol üniteleri (DKÜ) veya merkezi kontrol üniteleri (MKÜ) tarafından değerlendirilir. Dağıtık kontrol üniteleri şebekenin içerisine serpiştirilmiş üniteler olup gerekli işletme ve kontrol kararlarını ilgili cihaz ve bölge içinde verirler. Merkezi kontrol üniteleri ise şebekenin en uç noktası da dail farklı noktalardan toplanan verileri değerlendirip merkezi bir kararla sonuca varır. Her iki durumda da yoğun bir veri akışı vardır. Bu verilerin doğru ve güvenli bir şekilde iletilmesi çok önem kazanmaktadır. Bu verilerin korunması ile ilgili siber güvenlik konusu ayrıca ele alınması ve üzerinde çok ciddi çalışılması gereken bir usustur ve bu tezin kapsamında değildir.



Şekil 2. Akıllı şebeke temsili

2.4. Elektrik Şebekelerinde Dağıtılmış Üretim

Günümüzde toplumun hayatına giren teknoloji donanımlı cihazlar giderek artan bir şekilde toplumu elektrik enerjisine bağımlı hale getirmektedir [23]. Buna elektrik üretimindeki kaynak çeşitliliği de eklenince şebeke yapısıyla birlikte akıllı şebeke felsefesi oluşmaya başladı. Böylece, elektrik şebekelerini işleten ve yöneten kurumlar bu şebekelerin kararlılık ve güvenilirlik uygulamalarına yönelik dikkate değer değişikliklere gittiler [15, 23]. Karmaşık kontrol ve izleme uygulamalarına sahip güç sistemleri dünya genelinde giderek daha bölgesel ve güvenilir hale geldi. Örneğin, başlangıçta, güç sistemleri radyal bir topoloji ile tasarlandı. Yani tek yönlü güç akışı olan bir topoloji ile kaynaktan yüklerle doğru tek yönde ilerleyen bir yapıya sahipti. Bu durum kaynak tarafında meydana gelen bir arıza durumunda radyal şebekenin diğer kısımlarının enerjisiz kalmasına yol açmaktaydı [15, 23].

Bu sorunu aşmak için enterkonnekte ve ring şebekeler geliştirilmiştir. Böylece arızalı kısım yalıtıldıktan sonra şebekenin diğer bölümlerine güç iletimi ve dağıtımı sağlandı. Son yıllarda dünya genelinde tüketim ile iç içe yerleşik vaziyette kurulumları hızla artan yenilenebilir enerji kaynaklarından sağlanan elektrik üretiminin bağlanmasıyla şebekenin yapısı iyice değişikliğe uğradı. Artık üretim, şebeke içinde dağıtık üretim haline, dağıtım şebekesi de dağıtık şebekeye dönüştü. Bu durum merkezi yönetim ve merkezi kontrol işlemlerini zorlaştırdı ve dağıtık yönetim ve dağıtık kontrol kavramları doğdu. Artık birçok şeye müdahale merkezi olmaktan çıkıp konumsal uygulamalara dönüşmeye başladı. Tabii ki bu durum dağıtık yapıdaki güç sistemlerinin güvenilirliğini ve korunmasını da farklı bir evreye taşımış oldu [15, 23]. Dağıtılmış veya merkezi olmayan bir üretim sistemi, sistemin

gerçek zamanlı olarak izlenmesi ve kaydedilmesi için bir arayüz ile donatılmış cihazların (düğümlerin) iletişim ağları tarafından birbirine bağlanması olarak tanımlanabilir. Gerçek zamanlı uygulamalarda, sistem performansının doğru hesabı sadece işlemlerin mantıksal çıkarımlarına değil, aynı zamanda sunulan bu sonuçlar altındaki fiziksel anlara da bağlıdır. Dağıtık sistemlerin avantajlarından biri, işletici kuruluşun faaliyetlerini daha üretken ve verimli bir şekilde koordine etmelerine izin vermesidir. Ayrıca, ölçeklenebilirliği ve onu karakterize eden tasarım esnekliği nedeniyle başarısızlık toleransı daha geniş tutulabilir [8].

2.5. Güç Şebekesi Çalışmaları

Elektrik güç şebekeleri, kararlılık ve kontrol çalışmaları için çeşitli temel veri ve bilgilere sahiptir. Elektrik şebekelerinin işletilmesi için gerekli olan bu bilgiler yakın zamana kadar düzenli ve kullanılabilir bir formatta mevcut değildi. Var olan bilgilerin doğruluğu şüpheliydi. İşlenmesi uzun sürmekteydi ve güvenilir değildi. Bu durum, elektrik sistemlerinin güvenilirliği ile uğraşan uygulama mühendislerinin işini zora sokmaktaydı. Günümüzdeki gelişmiş teknolojiler, tepki hızı yüksek aparatlar, doğru veri toplayabilen cihazlar, hızlı güç akışı ve veri analizi yapabilen bilgisayarlar nedeniyle kararlılık çalışmaları ve arıza tahminlerine yönelik çalışmalar biraz daha kolaylaşmış ve uygulamayı da önemli ölçüde iyileştirmiştir. Bu ilerlemeler, elektrik şebekelerinin tasarımına, uygulanmasına ve bakımına önemli ölçüde katkıda bulunmuştur [53]. Öngörülemeyen ve kaçınılmaz elektrik arızaları ile ilgili olarak, elektrik şebekesinin topolojisi üzerinde güç akış analizi uygulanarak elde edilen arıza öncesindeki nominal ve kararlı koşullara ait akım değerleri arıza sonrasında akan akım değerleri ile karşılaştırma ve gözlemler yapılabilmektedir. Beklenmedik arıza durumlarında cihazların güvenilirliğini ve korumasını iyileştirmek için elektrik şebekesi üzerinden bulunan röle, kesici ve diğer koruma cihazlarının seçiminde de bu analizler kullanılır. Şebeke üzerinde arızalar oluşunca, sistemin kararlılığını ve güvenilirliğini artırmak için kullanılan röleler ve diğer koruma cihazları bu verilere göre seçilir ve ayarlanırlar. Elektrik şebekelerinin korunması ve işletilmesiyle uğraşan mühendisler sistemi sürekli takip ederek meydana gelen beklenmedik arıza ve ani yük değişimlerinde generatörlerin kararlı çalışmalarını sağlayacak önlemleri alırlar. Bu kararlı çalışmalar sürekli çalışma kararlılığının yanı sıra geçici kararlılık çalışmalarını da kapsar. Elektrik generatörünün kararlı çalışması güç sistemi için hayati önem taşır. Çünkü generatörün çökmesi şebekenin de çökmesi anlamına gelir. Klasik şebekelerdeki generatörlere ek olarak dağıtık şebekelerde diğer güç

üretim birimleri vardır. Yani rüzgâr türbinleriyle kullanılan generatörler ve fotovoltaik panellerin de kararsız duruma düşmeden şebekeyi beslemeleri gerekir. Dağıtık şebekelerin kararlı çalışması her ne kadar klasik şebekelerdekine benzese de güç üretim biriminin farklı olması ve tüketimle iç içe olmaları farklı sorunları da beraberinde getirmektedirler. Günümüzde dağıtık şebekelerden sürekli veriler toplanmakta ve çalışma geçmişi sürekli hatırd tutulmaktadır. Hem nominal değerlerde kararlı çalışan sistem geçmişi, hem de arızalı ve kararsız durumlardaki sistem geçmişi artık veri bankalarında kullanılmak üzere beklemektedir. Güç sistemi mühendisleri artık bu geçmişe ait verileri güncel verilerle karşılaştırarak gerekli kararları verebilmektedirler. Bu veriler akıllı algoritmaları kullanan bilgisayarlarda da değerlendirilerek insansız karar vericiler geliştirilebilir. Güç sisteminden toplanan çok sayıda veri, akıllı şebeke çalışmalarına önemli ölçüde katkıda bulunabilir ve elektrik şebekesinin öngörülebilirliğini artırabilir [53-57].


2.5.1. Güç Şebekelerindeki Elektrik Arızalarına Genel Bakış

Günümüzde gelişen teknolojiler, enerji sistemlerinin iyileştirilmesine önemli ölçüde katkıda bulunmuştur. Gerçekten de paydaşlar, birincil hedef olarak güvenilir ve istikrarlı bir enerji sistemine sahip olmak için uğraşmaktadırlar. Ancak, güç dağıtım şebekelerinde ister istemez kaçınılmaz arızalar meydana gelmektedir. Örneğin, önceki deneyimler, elektrik kesintilerinin çoğunun, sistem koşullarının kademeli olarak bozulmasına ve toplam arz kaybıyla sonuçlanan, ağ genelinde kademeli arızalara neden olabilecek veya olmayabilecek sistemlerde bir bozulma ile başladığını göstermiştir. Ayrıca, arızalar insan hayatını tehlikeye atabilir veya ekipmanlara kalıcı hasar vererek önemli ekonomik kayıplara neden olabilir. Bu çıkarımlar, güç sistemleri kararlılık analizinde hızlı arıza teşhisi için önleyici tedbirler almayı ve acil durumlardan kaçınmayı zorunlu kılmıştır [32, 37].

Bazı durumlarda, şebekelerin elektriksel eksiklikleri, iletkendeki mekanik hasardan, aşırı ısınmadan, aşırı voltajlardan veya yalıtım bozulmasından kaynaklanabilir. Örneğin, aktif iletkenler arasında veya aktif bir iletken ile iletken bir ortam üzerinden toprak arasında, kopma veya temas nedeniyle bir arıza meydana gelebilir [53-58]. Bu nedenle arıza değerlendirmesi, şebeke elemanlarının özelliklerinde bir değişiklik veya çalışma biçiminde meydana gelen istenmeyen durumlara göre yapılır [8]. Yıllar geçtikçe, ağlara yönelik artan talepler ve bileşenlerin kullanılabilirliği, elektrik şebekesi uygulamalarını insan hayatında kritik bir unsur haline getirdi. Bu nedenle, hata yönetiminde doğru yönetim, ağ üzerinden


hataları tespit etmek ve tanımlamak için esastır [13]. Güç sistemlerindeki arızaların yönetimini doğru yapabilmek için şebeke üzerindeki arızaları tespit etmek ve tanımlamak gerekir [13]. Örneğin, bazı arızalar, sinyal özellikleri nedeniyle tespit edilmesi zor olan büyük veya küçük akımlar ve gerilimler üretebilir. Gerilim ve akımların temel frekansları normal koşullar altında simetriktir. Bununla birlikte, arızalı fiderde, sağlıklı ve arızalı fazlar arasındaki akımların temel frekansının değişimindeki farklılıklar oldukça büyüktür ancak artık akımla uyumludur. Buna rağmen sağlıklı faz akımları arasında sıfırdır. Arıza çalışmaları, güç sistemi analizinde önemli bir bileşendir. Örneğin, bir arızayı bulmak için birkaç arıza sırasında bara voltajlarını ve hat akımlarını sınırlandırmak gerekebilir [52]. Bu nedenle, bu tezde arıza kaynaklı sinyal özellikleri gözden geçirilmiş ve 3-faz simetrik (LLL) ve asimetrik arızalar (LG, LLG, LL) olmak üzere iki ana grupta sınıflandırılmıştır.

- a. Simetrik arızalar veya üç fazlı dengeli arızalar: Şekil 3, bir elektrik sistemi üzerindeki en kritik arıza modeli temsili ve bunların voltaj ve akım sinyallerinin büyüklük davranışını göstermektedirler. Bu nedenle, bu tip arıza, üç fazın tamamında aynı anda kısa devre olması nedeniyle dengeli bir arızayı gösterir. Sistem genelinde kritik arıza akımları ve kesintiler üretir [58, 59].



Şekil 3. Simetrik arıza, (a) gerilim ve (b) akım değişimleri

- b. Faz-Faz arızaları: Şekil 4, sırasıyla arıza modelinin şematik temsili ve bunların gerilim ve akım sinyalleri büyüklüklerini göstermektedir. Bu tip arıza iki faz arasında kısa devre olarak tanımlanabilir; havanın iyonlaşması ile veya çevrelerindeki herhangi bir ihtimal ile iki faz hatları temas ettiğinde [59-61] meydana gelir.



Şekil 4. Faz-faz arızası sırasında, (a) gerilim ve (b) akım değişimleri


1. İki faz arasındaki kısa devrenin voltaj üzerindeki etkileri

- Arızalı iki faz üzerindeki gerilim faz açıları benzer hale gelir.
- Her iki arızalı fazda yaklaşık olarak eşit büyüklükte bir voltaj düşüşü meydana gelir.
- Sağlıklı faz herhangi bir değişiklik göstermez.

2. İki faz arasındaki kısa devrenin akım üzerindeki etkileri

- Arızalı iki fazın akım büyüklüğü artar.
- Arızalı iki faz üzerindeki akımlar arasında bir faz kayması meydana gelir.
- Toprak veya nötr akım yokluğu.

c. Faz-Faz-Toprak arızası: Şekil 5, sırasıyla faz-faz-toprak arızasının şematik gösterimi ve arıza sırasındaki akım ve gerilim değişimlerini göstermektedir. Bu tür bir arıza, iki faz hattının birbirleriyle ve toprakla temas ettiğinde meydana gelir [59-61].



Şekil 5. Faz-Faz-Toprak arızası sırasındaki, (a) gerilim ve (b) akım değişimleri


1. Faz-Faz-Toprak arızasının voltaj üzerindeki etkileri

- a) Arızalı fazlar üzerinde bir voltaj arızası meydana gelir.
- b) Sağlıklı fazın voltajı üzerinde önemli bir etki görülmez.
- c) Pozitif ve negatif bileşen voltajı eşitlenir.

2. Faz-Faz-Toprak arızasının akım üzerindeki etkileri

- a) Arızalı fazlar üzerindeki akım büyüklüğü artar.
- b) Arızalı fazların akımları arasındaki arıza öncesi faz açısı ($\angle 120$) korunuyor.
- c) Önemli toprak akımı akışı olur.
- d) Pozitif, negatif ve sıfır bileşen akımları oluşur.
- e) Bileşen akımı: pozitif bileşen akımının büyüklüğü, negatif ve sıfır bileşen akımlarının toplamına eşittir.

d. Faz-toprak arızaları: Şekil 6, sırasıyla faz-toprak arızasının şematik gösterimi ve arıza sırasındaki akım ve gerilim değişimlerini göstermektedir. Bu durum, bir faz iletkeni yere düştüğünde veya nötr iletkenle temas ettiğinde meydana gelir. En yaygın arıza türüdür [59-61].



Şekil 6. Faz-toprak arızası sırasında oluşan (a) gerilim ve (b) akım değişimleri

1. Faz-toprak arızasının voltaj üzerindeki etkileri

- a) Arızalı fazın gerilim büyüklüğünde bir düşüş meydana gelir.
- b) Sağlıklı fazların voltaj büyüklüklerinde de bir değişiklik meydana gelebilir (yükselme veya düşme).

2. Faz-toprak arızasının akım üzerindeki etkileri

- a) Arızalı fazda maksimum akım oluşur.

- b) Yüksek toprak akımı oluşur.
- c) Negatif ve sıfır bileşen akımları oluşur.
- d) Pozitif, negatif ve sıfır bileşen akımları eşit büyüklüktedir.

2.6. Elektrik Güç Sisteminin Korunmasında Yeni Yaklaşımlar

Elektrik güç şebekeleri beklenmedik anlarda tüketicilerin enerjisiz kalmalarına yol açan arızalara maruz kalabilir. Bazen bu sıkça görülür. Bu arızalara genelde çevresel koşullar veya cihaz bozulmaları neden olur. Elektrik şebekesi boyunca meydana gelebilecek bu arızalar, farklı yayılma özelliklerine ve davranışlarına sahiptir. Günümüzde, modern şebeke koruma ve güvenlik sistemleri, şebeke genelinde meydana gelen önceki arıza kayıtlarını veya bozulma veritabanını muhafaza etmekte, böylece güvenilirlik ve belirsizliklerin ön kestirimleri yapılabilmektedir [33, 37]. Arızalara ve bozulmalara yol açan etkenler, bazı durumlarda tüm şebeke üzerinde güç kesilmesi gibi önemli bir etkiye neden olabilir. Bazen de bu etki bölgesel olarak görülebilir. Güç şebekesi üzerindeki aparatlarda meydana gelen arıza ve bozulmalar da kısmen ve ya tamamen güç kaybı oluşmasına neden olan frekans veya voltaj dalgalanmaları oluşturabilirler [37]. Bu nedenle, güç sistemindeki arızalı parçalarının hızlı bir şekilde tespit edilerek diğer kısımlardan yalıtılması gerekir. Bu yalıtım sürecinin önceden planlanması ve uygulanması gerekli elektrik kesintilerini önler [6]. Elektrik dağıtım şebekesi üzerindeki aparatların veya tüketici cihazlarının arızalanmalarını önlemek, can kayıplarına engel olmak ve daha fazla hasar oluşmasının önüne geçmek için hızlı ve güvenilir elektrik koruması sağlanmalıdır [53].

Elektrik şebekelerinden gerçek zamanlı veri toplanması ve izlenmesi gittikçe daha kolay hale gelmektedir. Fakat dağıtık üretim ve dağıtık tüketimin de yaygınlaşmaya başlaması dağıtım şebekesini daha karmaşık ve işletilmesi daha zor bir yapıya büründürmüştür. Bu karmaşıklık ve zorluğu yenmenin yolu da bu karmaşıklıkla birlikte büyüyen akıllı uzamın sistemlerin kullanılmasıdır. Yüksek düzeyde doğruluk ve güvenilirlik ile daha iyi bir çözüm sunabilecek, örüntü tanıma, öğrenme yetenekleri, akıllı karar vericiler ve potansiyel güvenlik sınırlarını belirlemedeki yüksek hızları nedeniyle makine öğrenme teknikleri kullanılabilir [37].

3. MAKİNE ÖĞRENİMİ

Tezde kullanılacak yöntemlerin başında gelen makine öğrenimi bu bölümde genel hatlarıyla ele alınmıştır. Makine öğrenimi örüntü tanımada esnek ve yüksek yeteneklere sahip olduğu için bu tezde kullanılmıştır. Ayrıca veri analizinde kullanılan Python yazılımı ve en uygun kütüphaneleri de bu bölümde gözden geçirilmiştir.

3.1. Giriş

Veri bilgi demektir. Veriler gibi bilgiler de depolanır, saklanır ve gerektiğinde kullanılır. Günümüzde gelişen ölçme ve algılama cihazları, iletişim hızı ve yaygınlığı ile very toplamak da kolaylaşmıştır. Ancak toplanan verilerin depolanması değil, faydalı amaçlarla kullanılması önemlidir. Çünkü kullanılan veri bilgiye bilgi de iyi kullanılırsa faydaya dönüşür. Veri toplamının ve kullanmanın önemini son yıllarda yaşanan dijital dönüşüm süreçleriyle rahatça görmek mümkündür. Ticari faaliyetlerin yüz yüze alışverişten hızla internet üzerinden alışverişe dönüşmesi, Covid-19 öncesinde başlayan ve Pandemi sürecinde iyice yaygınlaşan uzaktan eğitim, uzaktan toplantılar, uzaktan çalışma ve daha pek çok uygulama hep verilerin bilgiye dönüştürülmesiyle hız kazanmıştır.

Güç sistemlerinde very toplama ve kullanmaya dayalı uygulamalar da son onlu yıllarda hızla artmaya başlamıştır. Analog koruma rölelerinin yerini sayısal koruma röleleri almaya başlamıştır. Elektrik santrallerinden toplanan verilerin uzaktaki merkeze ulaştırılarak santralin çalışma durumunun gözlenmesi zamanla uzaktan kontrole ve müdahaleye dönüşmüştür. Günümüzde, üretimden tüketime artık güç sistemlerinin her noktasından very toplanmakta ve değerlendirilebilmektedir. Başlangıçta sadece gözlem ve izleme amaçlı kullanılan veriler, akıllı şebekelerin gelişmesiyle artık müdahale ve control amaçlı da kullanılmaya başlanmıştır. Uzamanlar verinin gücünü anladıktan sonra bunu hızlı ve faydalı kullanmanın yolunu da aramaya başladılar. Aslında uzaman sistemlerin 1990'lı yılların başından itibaren hızla yaygınlaşması veri kullanımının bir sonucudur.

Akıllı karar verme ve öğrenme algoritmalarının da desteğiyle uzman sistemler akıllı karar verebilen makinalara dönüşmüştür. Günümüzde makina öğrenimi olarak bilinen yöntemlerin başlangıcı da akıllı uzaman sistemlerin geliştirilmesine dayalıdır. Bulanık mantığın belirsiz verileri temsil etme ve insansı karar verme yetenekleri, yapay sinir ağlarının öğrenme ve kendisini eğitebilme becerileri ve görüntü işlemedeki kullanılabilirliği

yumuşak hesaplama ve optimizasyon yöntemleri ile birleşince büyük verilerinin kullanılması ve bilgiye dönüştürülerek işlenmesi daha kolay hale gelmiştir. Geriye bu verileri işleyecek hızlı bilgisayarlar ve donanımlar kalmaktadır. Günümüz bilgisayarları bir şekilde bu sorunu çözebilmektedir. Ancak daha hızlı haberleşme sistemleri ve daha hızlı bilgisayarlar bu süreci hızlandıracaktır.

Verilerin özellikleri ve yapıları uygulamaya göre değişir. Ticari faaliyetlerden toplanan verilerin kullanım amacı ile güç sistemlerinden toplanan verilerin kullanım amacı müşteri tarafından bakıldığında benzerlik gösterse de işletim ve yönetim açısından farklılıklar gösterir. Dolayısıyla veriler hangi sahada kullanılacaksa o sahada uzman olanlar tarafından değerlendirilmesi gerekir. Yani verileri bilgiye o konunun uzmanları dönüştürür. Güç sistemlerinden toplanan verileri de güç sistemlerinde uzman olan mühendisler ve operatörler tarafından bilgiye dönüştürülür. Bu tez çalışmasında, güç sistemlerinden toplanan verilerin bu sistemde meydana gelen arızaların tespitinde nasıl kullanıldığı gösterilmektedir.

3.2. Makine Öğrenimi Uygulamaları

Makine Öğrenimi, esnekliği ve güvenilirliği nedeniyle son yıllarda dillendirilen en moda kelimelerden birisidir. Araştırmacılar, “Makine Öğrenimi” terimini, bilgisayarların sağlanan verileri programlanmadan öğrenme yetenekleri nedeniyle öğrenmesini ve insan gibi davranmasını sağlayan bir bilim olarak tanımlanmıştır [62]. Dolayısıyla genel amaç verinin bilgiye dönüştürülmesidir. Yani “bilginin keşfi” dir. Uygun ve doğru çıkarımların yapılabilmesi için, sağlanan verilerin doğru olması, doğru analiz edilmesi ve doğru değerlendirilmesi gerekir [7, 37]. Esneklik, öğrenme çerçevesinde makine öğreniminin en dikkat çekici özelliklerinden biridir. Makina öğrenimi modelleri, çeşitli endüstrilerde veri yönetimi ile ilgili bazı sorunları çözmek için uygulanmıştır. ML modelleri, yüz ve ses tanıma özellikleri nedeniyle güvenlik sistemlerinde önemli uygulama alanı bulmuştur. Öte yandan, sağlık endüstrisinde görüntü analizi tanıları, karmaşık hastalık tanıları veya konumlarını veren özelliklerin belirlenmesinde de kullanılmışlardır. Ayrıca eğlence sektöründe, teklif seçenekleri üzerinden müşteri davranışlarını toplamak ve analiz etmek için uygulanmıştır [62].

Makine öğreniminin mevcut verilerden kalıpları ve ilişkileri öğrenme yeteneği, güvenilir ve esnek gelecekteki operasyonları ve karar vermeyi genelleştirebilir [30]. Ayrıca,

artan karmaşıklıkları, belirsizlikleri ve istikrar ve güvenilirliklerini korumak için güç dağıtım sistemlerinde de mevcut verilerin verimli kullanımına dayalı bir modernizasyon gereklidir. Enerjinin kullanım kalıpları, yenilenebilir üretim sistemleri ile ilişkiler ve talep tarafında daha yüksek düzeyde katılım, şebekenin artan işlevselliğini desteklemek için karmaşık tahminler ve kontrol teknikleri ve algoritmaları hakkında bilgi sağlanması esastır. Böylece, güvenilir operasyonlar elde edilir ve sistem modellerinde, yönetimde ve karar vermede iyileştirmeler yapılabilir [3, 30]. Örneğin, elektrik şirketleri, arızalar veya cihaz arızaları ile ilgili olarak şebekenin geçmiş veri kayıtlarını tutarak ML modellerinin bilgi keşfine dayalı uygulamasıyla, elektrik şebekelerinin güvenilirliğini artırmak için daha aktif bakım programları oluşturulmasını sağlarlar [7].

3.3. Makine Öğrenimi Modeli

Makine öğrenmesi, işlevselliğine katkıda bulunan farklı kavram kombinasyonlarını dahil ederek veri yönetiminde bir devrime neden olmuş ve veriyi bilgiye dönüştürmede sihirli bir yöntem haline gelmiştir. Örneğin, AI uygulamalarının dahil edilmesi, sistemlere, daha önce gerçekleştirilmesi için programlanmadan, çevresiyle etkileşim yoluyla edinilen deneyimlerden otomatik olarak öğrenme ve performanslarını iyileştirme yeteneği sağlar. ML analizini gerçekleştirmek için üç öğeye ihtiyaç vardır. Bunlar, giriş verileri, beklenen çıktı örnekleri ve algoritmaların beklenen sonuçlara ilişkin doğru çalışmasını anlamaya yardımcı olan algoritma performans geri bildirimleridir [62, 63].


Makine öğrenimi algoritmaları, bu işlemleri öğrenme süreci ile ilişkilendirerek, giriş verilerini gelecekteki yorumlar için anlamlı sonuçlara dönüştürmeyi amaçlar. Bu kavramı anlamak için insanların okuma ile ilgili öğrenme süreçlerine bakılabilir. İyi okumak için insanların okumaya başlamadan önce alfabeyi bilmeleri gerekir. Öğrenme sürecinde önce harflerin her birini sonra da okumayı öğrenirler. Harflerin her birini nasıl öğrendikleri, okuma yeteneklerinin önemli bir bölümünü temsil eder. Bu nedenle ML, öğrenme sürecini gerçekleştirmek için girdi verilerinin nasıl dönüştürüldüğünden veya analiz edildiğinden etkilenir ve böylece beklenen sonuçlara daha yakın temsiller elde eder [63]. ML süreci aşağıdaki kavramları içerir.

1. Veri toplama: Veriler, makine öğrenimi performansı için en önemli unsurlardan birini temsil eder; veri olmadan ML yapmak imkansızdır. Toplanan veri miktarı ne kadar fazla olursa, daha iyi sonuçlar elde edilmesini sağlayacaktır.
2. Veri ön işleme: Veri ön işleme, ML uygulamasındaki en kritik adımlardan biridir. ML model eğitime başlamadan önce, farklı formatları (int, double, string) nedeniyle ham veriyi rafine etmek veya veri kaybını önlemek için gereklidir. Bu nedenle, sonuçların elde edilmesinde daha fazla kesinlik sağlamak için veri ön işleme gereklidir.
3. ML model seçimi: Bu süreç, elde edilmesi beklenen sonuçlara bağlıdır. Ayrıca, sağlanan veri tipini, sınıflandırma veya regresyon problemini ve veri miktarını dikkate alır. Örneğin, veri türü etiketli veya etiketsiz veri olabilir.
4. Eğitim modeli: Yukarıda belirtildiği gibi, öğrenme sürecine bilgi sağlamak için elde edilen verilerden belirli bir oranda modeli eğitmek gerekir.
5. Öğrenme modelinin test edilmesi: Model belirli bir miktarda bilgi ile eğitildikten sonra, en iyi çözümü veya beklenen sonuçları elde etmek için modelin güvenilirlik testlerini yapmak ve veri doğrulama ayarlamalarını yapmak gereklidir.
6. Modeli ayarlama: Test sonuçları beklendiği gibi çıkmasa da güvenilir ve uygulanabilir çözümlere ulaşmak için modelin tekrar uydurulması gerekmektedir.
7. Tahminler yapın: ML modeli doğru bir şekilde ayarladıktan sonra tahminlerde bulunmak ve beklenen sonuçları elde etmek mümkün olacaktır.

3.3.1. Makine Öğrenmesi Algoritmalarının Türleri

Yeni teknolojik gelişmelerle birlikte bilgi, kökenine göre yapılandırılabilen veya yapılandırılmayan verinin en bol bulunan kaynaklarından biri haline gelmiştir. Bu verileri yönetmek ve onlardan öğrenmek için, aşağıda tanımlanan birkaç kategoriye giren öğrenme paradigmaları ile karakterize edilen ML algoritmaları gibi veri ön işleme teknikleri uygulanmıştır [63-65]:

- Eğitmenli öğrenme: en yaygın öğrenme durumudur. Tahmin edilecek bilginin ek nitelikleri veya hedefleri giriş verilerinden gelir. Genellikle sınıflandırmalar ve regresyon algoritmalarından oluşur [63-65].
- Eğitmensiz öğrenme: Eğitmenli sistemlerden farklı olarak, bu modeller tahmin edilecek çıkışla ilgisi olmayan giriş verilerine sahiptir. Başka bir deyişle, algoritmalar, gruplamalar veya yoğunluk tahminleri yoluyla herhangi bir spesifik özelliğin yardımı olmadan girdi verileri arasındaki ilişkileri bulmaya çalışır. Genellikle boyut azaltma ve kümelemeden oluşur [63-65].
- Yarı eğitmenli öğrenme: Gerçek dünyada, etiketlenmiş ve etiketlenmemiş bazı verilerle aynı anda uğraşmak oldukça normaldir. Ayrıca, veri biliminde verileri işlemek için yeni etiketler bulmak gerektiğinde veya birkaç etiketle uygulanan yarı eğitmenli algoritma adı verilen bir tür eğitmenli ve eğitmensiz hibrit algoritmalar [64, 65].
- Takviyeli öğrenme: Son olarak, takviyeli öğrenme, çevre ile etkileşimlere dayalı olarak performansını artıran bir yöntem geliştirmeyi amaçlayan bir öğrenme türüdür (yani, deneme-yanılma stratejisine benzer bir öğrenme türü) [63].



Şekil 7. Tahmine dayalı modelleme makine öğrenimi iş akışı

3.4. Python’u Makine Öğrenimi İçin Kullanmak

Python son yıllarda geliştirilen veveri bilimi için kullanılabilecek açık kodlu yazılım dillerinden biridir. Bu programlama dili, güçlü bir nesne yönelimli programlama dili olup, geniş bir açık kaynak topluluğu, standart kütüphane işlevleri ve kullanıcıların sistemlerini hızlı ve verimli bir şekilde entegre etmelerini sağlayan etkileşimli geliştirme ortamı özellikleri ile çok çeşitli sözel yapılara sahiptir [64, 66]. Python programlama dilini kullanmanın en dikkat çekici faydaları şunlardır [66]:

- Kodların okunmasını, anlaşılmasını ve test edilmesini kolaylaştıran basit sözdizimleri.
- Python, çeşitli genel programlama görevlerini destekleyen geniş bir standart kitaplık ve açık kaynak lisansı içerir.
- Diğer programlama dillerinde uygulanan yeni modüller eklenerek kolayca genişletilebilen ölçeklenebilir bir sistemdir.

Python’da kullanılan bilimsel hesaplama, veri bilimi ve makine öğrenimi için en uygun paketler şu şekilde tanımlanır [66]:

- NumPy: C ve Fortran gibi programlama dillerini Python’a birleştirmek için kullanılan açık ve zarif bir köprü olarak tanımlanabilir. Temel amacı çok boyutlu dizilerle çalışmaktır ve veri değerlendirmesinde uygulanır [66, 67].
- SciPy: NumPy kitaplığı olarak SciPy, çok boyutlu dizilerle çalışan ücretsiz ve açık kaynaklı bir Python kitaplığıdır. Optimizasyon, cebir, hesap, sinyal ve görüntü işleme için geniş modülleri nedeniyle bilimsel ve teknik hesaplama ve mühendislikte veri modelleme için uygulanmaktadır [68, 69].
- Pandas: Verileri çıkarma, dönüştürme ve Python arayüzüne yükleme gibi veri analizi için güçlü ve kolay bir açık kaynaklı Python kitaplığıdır [70].
- Scikit-learn: SciPy olarak, veri modellemede uygulanan açık kaynaklı bir Python kütüphanesidir. Şu anda makine öğrenimi görevlerinden bahsetmek için moda bir kelimedir ve eğitmenli ve eğitmensiz öğrenmeyi destekler [71].
- Matplotlib: Python’da (yani veri sunumu) statik, hareketli ve etkileşimli görselleştirmeler oluşturmak için genel bir açık kaynaklı kitaplıktır [72].

4. YAPILAN ÇALIŞMALAR

Bölüm 2’de tartışıldığı gibi, yenilenebilir enerjiyi dağıtım şebekelerine dahil eden teknolojiye son gelişmeler ve sistemler üzerinde oluşabilecek öngörülemez arızalar nedeniyle güç şebekelerinin istikrarı ve güvenilirliği zorludur. Bu nedenle, bu bölüm arıza tespiti ve sınıflandırma problemlerinin yaklaşık çözümüne yönelik yaklaşımları araştırmaktadır. İlk olarak, kullanılan modelin genel bir açıklaması sunulmaktadır. Daha sonraki bölümlerde, birkaç analitik ve sayısal yaklaşık algoritma incelenmiştir.

4.1. Giriş

Elektrik arzı, yakın geçmişte büyük ve hızlı gelişmeler yaşayan en talepkar yüksek kaliteli hizmetlerden biridir. Öte yandan, insanın günlük hayatında vazgeçilmez olması, ülkelerin ekonomileri ve ilerlemeleri için önemi nedeniyle elektrik şebekeleri, dünya çapında en kapsamlı mühendislik sistemi olarak tanımlanmaktadır. Sonuç olarak, sistemlerinin istikrarını ve güvenilirliğini korumak için paydaşlara son derece önem vermişlerdir. Literatür incelemesine ve ön çalışmalara dayanarak, elektrik şebekelerinin stabilitesi ve güvenilirliğinin kavramsallaştırılması aşağıdaki kriterlere odaklanmayı amaçlamaktadır [73]:

- a. Ölçeklenebilirlik: Artan talep veya yük tarafında yenilenebilir kaynakların dâhil edilmesi nedeniyle elektrik şebekeleri sürekli değişmektedir. Bu nedenle, şebekedeki talebe göre artma veya azalma yeteneğine sahip olmalıdırlar.
- b. Güven: Sistem, sağlıklı elektriksel durumlarla ilgili olarak onları daha alakalı ve genişletilebilir hale getirecek gerçek zamanlı izleme durumları üretmelidir.

Son yıllarda, Makine Öğrenimi, yüksek uyarlanabilirliği ve etkileyici bilgi işleme hızları nedeniyle dünya çapında bir moda haline geldi. Bu bağlamda, bu araştırma, güç dağıtım şebekelerinde arıza tespiti ve sınıflandırmasında ML’nin verimliliği ve uygulanabilirliğine odaklanmaktadır. ML kullanmanın bir avantajı, algoritmaların güvenilir kararlar ve sonuçlar üretmek için verilerden karmaşık davranışları ve ilişkileri değerlendirip öğrenebilmesidir [80]. Ek olarak, esneklikleri nedeniyle çok boyutlu ve çok değişkenli verilerle dinamik ortamlarda kullanılabilirler [73].

ML algoritmalarını kullanmanın tüm faydalarına ek olarak, giriş verilerine odaklanmak gerekir. Girdi verileri, modelin ayarlandığı verilerin kalitesine dayalı olarak tahminlerin doğruluğunu etkileyebilecek önemli bir yönü temsil eder [73]. Önceki araştırmalar, arıza öncesi ve sonrası voltajların ve akımların geçici sinyallerinin, ML algoritmalarının etkinliğini biraz gürültü hale getirdiğini gösterdiler. Bu nedenle, makine öğrenimi algoritmalarını eğitmek ve hata öncesi ve sonrası sinyallerden en uygun özellikleri çıkarmak için kullanılan verilerin kalitesini garanti etmek amacıyla bu araştırmada Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform – DWT) uygulanmıştır. DWT seçimi, arıza varlığı tespiti, toprak arıza tespiti ve arızalı fider tanımlamasına dayalı bir model önerilmiştir. Bu çalışmada ayırım ve tahmin gerçekleştirmek için beş ML algoritması seçilmiştir. Ön araştırmaya dayalı olarak sunulan modeller Lojistik Regresyon algoritması (Logistic Regression – LR), Destek Vektör Makinesi algoritması (Support Vector Machine – SVM), Karar Ağacı algoritması (Decision Trees – DT), Rassal Orman algoritması (Random Forest – RF) ve K-En Yakın Komşu algoritması (K-Nearest Neighbor – KNN) ile birlikte boyutsallığı azaltmak için birkaç eğitimsiz tekniktir. Aşağıdaki bölümlerde, güç dağıtım şebekelerinde sinyal ön işleme ve arıza tanımlama için genel yöntem ayrıntıları verilmektedir.


4.2. Sistemin Genel Görünümü

Şekil 8 ve Şekil 9, bu tezde önerilen modeli sunmaktadır. Amaç, belirli bir dağıtılmış sistemdeki hataları tespit etmek ve sınıflandırmak için ML algoritmalarını ve uygun DWT seçimini geliştirmek amacıyla eğitimsiz boyut azaltma uygulamaktır. Süreç aşağıdaki gibi yedi adıma bölünmüştür:


1. Veri üretimi: ML algoritmaları hataları algılamadan ve sınıflandırmadan önce bir ön eğitim gerektirir. Bu adımda, benzetilmiş IEEE-34 baralı testi modelinden üç fazlı gerilimler ve akımlara ait simülasyon verileri toplanır. Toplanan veriler, eğitim verileri olarak kullanılmadan önce ön işleme tabi tutulur ve Excel dosyalarında saklanır.
2. Dalgacık seçimi: Grid Search algoritması ve SVM algoritması tarafından ayarlanan birkaç dalgacık ailesi uygulanarak ve en iyi ayrıştırma seviyeleri

hesaplanarak gerçekleştirilir. Doğruluk ve zaman açısından en iyi sonuç, önerilen modelde sinyal ön işleme için en iyi dalgacık ailesi olarak seçilir ve ayarlanır.

3. Özellikler hesaplama: Bu bölüm, toplanan sinyallerden on iki istatistiksel özelliğin çıkarılmasından oluşmaktadır. İstatistiksel özellikler, dalgacık sürecinden toplanan geçici olayın daha iyi çözülmesini sağlayabilir. Standartlaştırma işlevi, önceden işlenmiş özelliklerden gelen verileri normalleştirmek için bu düzeyde işlenir.
4. Boyutsal küçültme: Verileri yüksek bir boyuttan düşük bir boyuta dönüştürmek, hesaplama karmaşıklığını azaltmak ve ML algoritmalarının performansını artırmak için altı eğitimsiz boyut indirgeme tekniği uygulanmaktadır. Bu çalışma, eğitimsiz algoritmalar uygulayarak ML algoritmalarının boyutsallık azaltma yoluyla sağlamlıklarını nasıl artırabileceğini kanıtlamayı amaçlamaktadır.
5. Arıza tespiti: Bu adım, şebekede bir arıza olup olmadığının tespit edilmesine dayanmaktadır. Geçici sinyaller sırasındaki duyarlılığı nedeniyle, analizi gerçekleştirmek için sıfır bileşen gerilim bileşeni uygulanmıştır.
6. Toprak arıza tespiti: Arıza oluşumu tespit edildikten sonra arızanın bir toprak arızası ile ilgili olup olmadığının incelenmesi gerekir. Bu nedenle, sıfır bileşen akım bileşeni, geçici toprak arızalarını tespit etmek için uygulanmıştır. Arıza tespit adımında sunulan şematik modelin aynısı bu bölümde de uygulanmaktadır.
7. Arıza sınıflandırması: Bu son adımda amaç, arızalı fider üzerinden arıza tipini doğru bir şekilde sınıflandırmaktır. Üç fazlı gerilim ve akımlardan eğitmenli makine öğrenimi yaklaşımları ile birlikte öznelilik çıkarma teknikleri kullanılarak arıza sınıflandırmasını gerçekleştirmek için önceki adımlardaki aynı modeller kullanılmıştır.



Şekil 8. Önerilen modele genel bakış




Şekil 9. Önerilen model akış şemasına genel bakış

4.3. Çalışma Durumu

Elektrik şebekeleri, güç sistemlerinin omurgası olarak tanımlanmıştır. Bu nedenle, sistemlerin güvenilirliğini ve sürekliliğini sağlamak için dengeli veya dengesiz sistemlerde sürekli izleme gereklidir [74]. Son yıllarda, tüketici talep artışları, taleplerini karşılamak için alternatif enerji kaynakları arayışını tetiklemiştir (yani, merkezi olmayan üretimin yük tarafına dahil edilmesi). Bu nedenle, paydaşların araştırmaları sistemlerin güvenilirliğine odaklanmıştır. Bu sebeple, bu araştırma, kararlı durumlar üzerinde dağıtık üretimli bir elektrik şebekesinde oluşabilecek arızaları analiz etmek için deneysel bir yöntemle

dayanmaktadır; vaka çalışmasının detayları aşağıda sunulmuştur. Bu araştırmadaki vaka çalışması, bir IEEE 34 baralı test sistemi olan Arizona, ABD’de bulunan gerçek bir besleyiciye dayanmaktadır. Sistem, nominal voltajın 24,9kV olduğu iki voltaj seviyesinde yapılandırılmıştır. Sırasıyla 814-850 ve 832-852 hat bölümlerine monte edilmiş uzun ve hafif yüklü, iki ototransformatör ile karakterize edilmiştir. 888 ve 890 uçları için 4,16 kV transformatör vardır. 844 ve 848 bölümlerinde dengesiz yükleme ve şönt kapasitörler bulunmaktadır [75, 76]. Test sistemi, DIgSILENT PowerFactory 2019 sürüm x64 yazılımı kullanılarak modellenmiştir. Ek olarak, 816 ve 832 nolu düğümler arasında 2,5 km uzunluğunda ve 301 konfigürasyonlu bir trifazık ağ topolojisi düzenlemesi dahil edilmiştir [77]. IEEE 34 baralı test sistemine bağlı dağıtık üretim sistemlerinin modellenmesi analizine sistemin en zayıf noktaları da dahil edilir. DIgSILENT PowerFactory 2019 sürüm x64 yazılımının statik jeneratör kütüphanesinde bulunan iki adet üç fazlı fotovoltaiik sistem ve bir jeneratör sırasıyla 840, 848 ve 890 düğümlerine yerleştirilmiştir. Şekil 10, bu incelemede uygulanan sistemde yapılan konfigürasyonların bir özetini göstermektedir.



Şekil 10. IEEE 34 baralı testi değiştirildi

4.4. Veri Üretimi

Algoritmalar için verilerin önemi, insanlar için oksijenin önemi gibidir. Bu benzetme, makine öğrenimi sürecinde gerçekleştirilmek üzere toplanan verilerin önemini vurgulamaktadır. Test seti için tahmin yapabilmek amacıyla ML algoritmalarının önceden eğitilmesi gerekir. Yani veri olmadan ML yapmak imkansızdır. Bu nedenle, bu araştırmada, Şekil 10 farklı arıza durumlarının simüle edildiği DIgSILENT yazılımında modellenen test besleyicisini göstermektedir. Arıza verileri, DPL kodu ve rastgele arıza direnci, rastgele

konumlar, dağıtılmış neslin seviye penetrasyonu ve çeşitli arıza akımı başlangıç açısı gibi farklı koşullar aracılığıyla üretilir. Tablo 1, analiz için gerekli verileri oluşturmak için uygulanan arıza koşullarının bir özetini göstermektedir. Simüle edilen modelden, üç fazlı gerilimler ve akımlar kaydedilir. Ardından, toplanan veriler, gerilim ve akımın sıfır bileşen bileşenini elde etmek için Clarke Dönüşümü (1) kullanılarak ön işleme tabi tutulur; (bkz. Bölüm 2.5.1). Analizlerin performansı için sisteme enerji verilirken herhangi bir bozulmanın amortismanına tabi tutulduğunu belirtmek önemlidir.

$$\begin{bmatrix} \alpha \\ \beta \\ 0 \end{bmatrix} = \frac{2}{3} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix} \quad (1)$$

Tablo 1. Arıza verileri yapılandırması

Durum	Değerler
Arıza tipi	LLL, LL, LLG, LG
Arıza direnci (Ω)	0, 20, 50, 80, 100
Arıza yeri (%)	10, 25, 50, 75, 95
Fay açısı başlangıcı (θ)	0, 45, 90, 120
DG düzey (%)	0, 25, 50, 75, 100

4.5. Ayrık Dalgacık Dönüşümü


Yüksek veya düşük frekanstaki geçici durum çalışmaları, hat boyunca iletim sürecinde yayılma hızının ve sinyal zayıflamalarının analiz edilmesini sağlar. Farklı frekans bileşenlerinde iletim özelliklerinde varyasyonların veya bozulmaların varlığı, hareket eden dalgaları bozacak ve ilk hareket eden dalgaının varyanslarını artıracaktır [58]. DWT, sinyal işlemede düşük ve yüksek geçişli filtreler gerektiren uygulamalar için özellikle uygun olmasını sağlayan dikkat çekici özelliklere sahip güçlü bir araçtır [58, 78, 79]. Bu nedenle, DWT bu araştırma boyunca gerilim, akım ve sıfır bileşen dalga biçimi sinyal işleme için uygulanmaktadır. DWT'yi tanımlamaya başlamadan önce, kökenini anlamak gerekir. Sinyal analizi hakkında konuşurken, genellikle Dalgacık Dönüşümü (Wavelet Transform – WT) ile Fourier Dönüşümü (Fourier Transform – FT) karşılaştırılır. Ancak bu fonksiyonlar arasındaki temel fark, WT'lerin hem zaman hem de frekans uzaylarında yer almasıyla

ilgilidir. Buna karşılık, FT yalnızca frekans uzayında bulunur. Bu nedenle, kısa süreli yüksek frekanslı sinyaller veya uzun süreli düşük frekanslı sinyaller ile sinyallerde geçici olayların mevcudiyeti olduğunda, sırasıyla daha yüksek hassasiyetli bir frekans çözünürlüğünün yanı sıra daha yüksek hassasiyetli bir zaman çözünürlüğü gereklidir [79]. Frekans çözünürlüğünü uyarlamaya yönelik bu öznetelik, sinyalin analizine ve sinyal özelliklerinin saptanmasına önemli ölçüde yardımcı olabilir; bu, geçici olayların nedenini veya bozulma sonrası sistem durumlarını ayırt etmek için oldukça faydalı olabilir [78]. Bu nedenle, DWT, dalgacık dönüşümünün her ölçekleme adımında yüksek ve düşük geçişli filtre setleri içerir [73], DWT'nin bir temsili denklem (2)'de sunulmuştur. Burada, $S(i) \in L^2(R)$ ve $m \in Z(R)$, $a = a_0^m$ ve $b = ib_0a_0^m$, sırasıyla genişleme ve öteleme faktörüdür.

$$DWT_{m,\tau} = \int_{-\infty}^{\infty} S(i)\psi(i)di = \frac{1}{\sqrt{a_0^m}} \sum_i S(i)\psi\left(\frac{\tau - ib_0a_0^m}{a_0^m}\right) \quad (2)$$

DWT'deki Yüksek ve Alçak geçiren filtreler sayesinde çoklu çözünürlüklü analizler yapılabilmektedir. Yaklaşım ve detay bileşenleri, birbirini izleyen evrişim süreçleri yoluyla elde edilir. Orijinal sinyal, yüksek frekanslı bileşenleri ortadan kaldırarak alçak geçiren filtreden yaklaşık bileşenlerin elde edildiği farklı çözünürlük ölçeklerine bölünmüştür. Buna karşılık, detay bileşenleri, analiz edilen sinyallerin yüksek frekans içeriğini seçen yüksek geçiren filtreden elde edilir. DWT için maksimum dalgacık ayrıştırma seviyesi sayısı, orijinal sinyalin uzunluğu, seçilen belirli dalgacık ve gerekli detay seviyesi ile belirlenir [78, 79]. İşletim seviyelerinin bir temsili Şekil 11'de sunulmuştur.

Sinya analizi için farklı dalgacık ailelerinin kullanıldığı önceki literatürde bildirilmişti. Ancak bunların hiçbiri belirli dalgacığın seçilmesi için herhangi bir gerekçe veya prosedür sunmamıştır. Dalgacık seçimi ve ayrıştırma seviyeleri, özellik vektörlerinin boyutunu güçlü bir şekilde etkileyebilir. Dolayısıyla analizden farklı sonuçlar elde edilebilir. Bu araştırmada, dalgacık ortogonal aile seçimi ve ayrıştırma seviyelerini optimize etmek için minimum entropi ayrıştırması ve Grid Search algoritması ile SVM algoritmasının bir kombinasyonu uygulanmıştır.



Şekil 11. Ayrışma seviyesi temsili

4.5.1. Optimum Ayrıştırmanın Seçilmesi

Önceki bölüm, ortogonal bir dalgacıyı böldükten sonra, daha sert bir ölçekte iki farklı vektör (yani, yaklaşım ve detay katsayıları) elde etmenin mümkün olduğundan bahsedilmişti. Burada, yaklaşım katsayılarından kaçırılan bilgiler, asla yeniden analiz edilmeyen detay katsayılarında toplanır [82]. Belirli bir ortogonal dalgacıktan dalgacık ailelerinin ve ayrıştırma seviyelerinin seçilmesi ortak bir konudur. Çünkü bunlar özellik vektörlerinin boyutunu etkileyebilir ve analizden farklı sonuçlar elde edilebilir. Boyutluluğu optimize etmek ve analiz sonuçlarını artırmak için, α 'nın farklı şekillerde genişletilmiş $G = 2^N$ uzunluğundaki bir sinyalden optimal ayrıştırma seviyelerini bulmak için minimum entropi ayrıştırması uygulanmıştır; burada α , bir nesnenin ikili alt ağaçlarının sayısıdır N derinliğinin tam ikili ağacı [82]. Minimum entropi ayrıştırma algoritmasının bir özeti aşağıda sunulmuştur ve dalgacık ailesi seçiminin bir akış şeması Şekil 12'de verilmiştir.

Algoritma: Minimum Entropi Ayrışımı.

1. Başlat, G uzunluğunda giriş sinyali S .
2. S sinyalinden Shannon entropisinin (14) hesaplanması.
3. S sinyalini işlemek için herhangi bir ortogonal dalgacık ailesi WT 'nin seçimi.
4. Çok çözünürlüklü bir ayrıştırma prosedürü için denklemler (3) ve (4) aracılığıyla sinyal S 'den yaklaşıklık ve detay katsayısını hesaplayın.

$$A_j(S) = \sum_i l(k) S_{j-1}(n-i) \quad (3)$$


$$D_j(S) = \sum_i h(k) S_{j-1}(n-i) \quad (4)$$

Burada l ve h sırasıyla düşük ve yüksek filtreyi temsil eder. A_j ve D_j , sırasıyla $(j, j) = 1, 2, 3, \dots, J$ çözünürlükteki yaklaşıklık ve detay katsayısıdır. S_{j-1} , seviyenin yaklaşıklığı olarak tanımlanır ve $i = 1, 2, 3, \dots, I$, burada I filtre vektörünün uzunluğunu temsil eder [82].

5. Yaklaşım katsayısından Shannon'ın entropisini hesaplayın.

$$E_A(A_j) = - \sum_i A_{j_i} \log A_{j_i} \quad (5)$$

6. Elde edilen entropiyi, Shannon'ın entropisinin değeri maksimize edilene kadar (yani, $\Sigma E(S) = 0$), önceki entropi ile karşılaştırın, aksi takdirde 4 ile 6 arasındaki adımları tekrarlayın.
7. Entropi maksimize edildiğinde son değeri alın ve bunu bir sinyalin minimum ayrışma seviyesi değeri olarak ayarlayın.
8. Son



Şekil 12. Dalgacık ailesinin akış şeması ve ayrıştırma seviyesi seçimi

4.6. Özellik Hesaplamaları ve Eğitimsiz Boyut Azaltma Teknikleri

Daha önce de belirtildiği gibi, veriler ML analizlerini geliştirmek için çok önemli bir unsurdur, bu nedenle sistemler, modelin daha önce hiç görülmemiş veriler üzerinde tahminler yapmak için uygun olduğu eğitim sürecini gerçekleştirirken gerekli ve gereksiz olmayan özelliklere sahip olmalıdır [83]. Bu nedenle, ML başarısının önemli bir parçası, algoritma eğitim sürecini yürütmek için bir dizi kullanışlı özelliğe sahip olmaktır. Bu süreç iki aktivitede özetlenebilir:

- Özellik seçimi: Mevcut tüm özellikler üzerinden en değerli özelliklerin değerlerinin seçiminde ortaya çıkan özellikler.
- Özellik çıkarma: Bu eylem, daha önemli özellikler oluşturmak için mevcut özelliklerin kombinasyonunu ifade eder.

Bu araştırmada, önerilen yöntem, bir arıza durumundaki bir besleyiciyi ayırt etmek için sırasıyla DWT tarafından önceden işlenmiş, sıfır dizilerdeki polarite değerleri ve üç fazlı voltaj ve akım büyüklükleri ile bunların değerlerini kullanır [45]. Arızalar gibi geçici olaylar sırasında hayati bilgileri içeren bir dizi istatistiksel nitelik sinyallerden çıkarılır [46]. Sinyallerdeki varyasyonları buluşsal bir şekilde yakalamaya izin veren istatistiksel özniteliklerin ayrıntıları Tablo 2’de sunulmaktadır [9, 45, 46, 83-86].

Tablo 2. İstatistiksel Özellikler

Özellikler	Açıklamalar	Denklemler
Enerji	Bu istatistiksel işlev, bozulma meydana geldiğinde geçici olayların görselleştirilmesine izin verdiği ve bozulmamış sinyale kıyasla, sinyalde önemli artışlar sunduğu için uygulanmaktadır.	$E = \sum_{i=1}^N S_i^2 \quad (6)$
Mutlak hata	Sistemde bozulma olduğunda, ortalama değer sıfırdan farklı olacaktır. Başka bir deyişle, normal koşullar altında sinyalin ortalama değeri sıfırdır.	$S_{MAV} = \frac{1}{N} \sum_{i=1}^N S_i \quad (7)$
R.M.S	Bir sinyalde geçici olayların varlığında önemli artışları göstermek için uygulanır.	$S_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i)^2} \quad (8)$
Varyans	Bu özellik, sinyaldeki herhangi bir dalgalanma nedeniyle geçici varlıkları ölçmek için kullanılır.	$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (S_i - \bar{S})^2 \quad (9)$
Standart sapma	Bu işlev, bozulmaların varlığında artışların sunulduğu ortalamadan verilerin dağılımını ölçer.	$\sigma = \sqrt{\sigma^2} \quad (10)$
Kurtosis	Bu özellik, sinyalin aykırı değerlere ne kadar yatkın olduğunu ölçer. Geçici mevcudiyette basıklık değerleri artar. Buna karşılık, normal dağılım altında basıklık 3’e eşittir.	$S_{Kurt} = \frac{\frac{1}{N} \sum_{i=1}^N (S_i - \bar{S})^4}{\left[\frac{1}{N} \sum_{i=1}^N (S_i - \bar{S})^2 \right]^2} \quad (11)$
Skewness	Sinyal deseninin asimetrisini ölçün. Geçici, frekans simetrisini etkileyebilir ve bu nedenle “skewness” seviyesini yükseltebilir.	$S_{Skew} = \frac{\frac{1}{N} \sum_{i=1}^N (S_i - \bar{S})^3}{\left[\frac{1}{N} \sum_{i=1}^N (S_i - \bar{S})^2 \right]^{3/2}} \quad (12)$
Şekil faktörü	Sinyal şekline bağlı olması nedeniyle, geçici sinyallerde önemli artışlar görülür. Aksi takdirde, normal şartlar altında ve sinyal boyutlarının bağımsızlığı altında alakasız enerji sunulur.	$S_{SF} = \frac{S_{RMS}}{S_{MAV}} \quad (13)$
Shannon’ın entropisi	Bağıntılı dalgacık uzamı, bağımsız doğrusallık uzamına grafiklemek ve zaman-frekans alanının enerji dağılımı belirsizliğini belirtmek için uygulanmaktadır.	$SE = - \sum_i S_i \log S_i \quad (14)$

Tablo 2'nin devamı

Dürtü faktörü		$S_{IF} = \frac{\max_i S_i }{S_{MAV}} \quad (15)$
Kret faktörü	Bu özellikler, dürtüsel ölçümler olarak da adlandırılan sinyalin tepe noktalarıyla ilgilidir. Bir sinyalin tepe noktasındaki kaymalar üzerindeki ilk tezahürleri nedeniyle arızalar için gelişmiş bir uyarı sağlayabilir.	$S_{crest} = \frac{\max_i S_i }{S_{RMS}} \quad (16)$
Açıklık faktörü		$S_{clear} = \frac{\max_i S_i }{\left[\frac{1}{N} \sum_{i=1}^N \sqrt{ S_i } \right]^2} \quad (17)$

Öte yandan, veri ölçeği, ML analizi üzerinde çalışırken çok önemli bir adımdır, çünkü bu veriler, uygulanan algoritmaların performansını etkileyen büyüklük, birim ve aralığa göre önemli ölçüde değişen özellikler içerebilir. Önceki araştırmalar, veri ölçekleme sürecinin algoritmaların doğruluğunu ve performansını geliştirdiğini göstermiştir. Bu araştırmada, denklem (18)'de temsil edilen standardizasyon fonksiyonu, veri kümelerinden istatistiksel özellikleri yeniden ölçeklendirmek için uygulanmıştır. Bu fonksiyon, Eğitimensiz Boyut Azaltma Teknikleri (Dimensionality Reduction Techniques – DRT) uygulamadan önce veri setinde ortalama 0 değerine ve standart sapma 1'e sahip olmayı amaçlar. S_i ve $i = 1, 2, 3, \dots, R$ sinyallerden ölçülen bir örneği temsil ederken, $\bar{S}$ gözlemlerin ortalamasını temsil eder ve σ , denklem (10)'a atıfta bulunan standart sapmadır.

$$SDT' = \frac{S_i - \bar{S}}{\sigma} \quad (18)$$

Önceki araştırmalara dayanarak, eğitimli algoritmaların, bu aramanın bir zamandan beri oldukça karmaşık hale geldiği ve karmaşıklığı hesapladığı çok yüksek boyutlu bir uzamda doğru kararları almak için örüntüleri nasıl sınıflandıracağını ve işlevsel yaklaşımlar inşa etmeyi öğrenmesi gerektiği bilinmektedir [65]. Bunu ele almak için, bilgiyi işlemek için birkaç eğitimensiz boyut azaltma tekniğini uygulayan bir düzenleyici olarak özellik çıkarma teknikleri önerilmiştir [64, 65]. Bu teknikler, orijinal öznitelik kümesindeki en göze çarpan öznitelikleri bulmayı ve bunları en alakalı bilgileri koruyarak yeni bir öznitelik uzamına

dönüştürmeyi veya yansıtmayı ve önceden bilgi sahibi olmadan veri setindeki farklı kalıpları ayırt ederek ML algoritmalarının karmaşıklığını azaltmayı amaçlar (yani, etiketsiz) [64, 65].

Boyut azaltmanın iki önemli dalı vardır, bunlar Doğrusal Projeksiyonu ve Manifold Öğrenme [65]. Bu çalışmada uygulanan en dikkat çekici eğitimsiz boyut azaltma tekniklerinin ayrıntıları aşağıdaki bölümlerde gözden geçirilmektedir.

4.6.1. Doğrusal Projeksiyon Teknikleri

Doğrusal izdüşüm tekniği, doğrusal bir izdüşüm veya verilerin yüksek boyutlu bir alandan düşük boyutlu bir alana eşlenmesinden oluşur; temel bileşenler analizi, tekil değer ayrıştırması ve rastgele projeksiyon gibi [65].

4.6.1.1. Temel Bileşen Analizi

Temel Bileşen Analizi (Principal Component Analysis – PCA), orijinal yüksek boyutlu uzamdan çok fazla varyans tutan verilerin düşük boyutlu uzam temsiline oluşan, boyutsallığı azaltmak için kullanılan basit ama güçlü bir doğrusal tekniktir. Başka bir deyişle, verilerin makro düzeyde anlaşılmasından sadece en alakalı özellikleri bırakarak veri kümelerindeki özelliklerin sayısını azaltmak mümkündür [65, 87]. Bu nedenle, PCA, ML tahminlerini ve sonuçlarını gerçekleştirmeden önce sırasıyla üç fazlı gerilimler ve akımlardan istatistiksel özellikler ve bunların sıfır bileşen değerleri arasındaki korelasyona dayalı olarak veri kümelerinde kalıpları bulmak için bir tür boyutluluk azaltma mimarisi olarak uygulanır. Boyut azaltma için PCA'nın bir temsili denklem (19) aracılığıyla sunulur.

Aşağıdaki ifade, örneklenmiş bir vektör $\mathbf{S}$ 'nin orijinal $\mathbf{d}$ boyutlu uzamdan ($\mathbf{k} \ll \mathbf{d}$) daha az boyut içeren yeni bir $\mathbf{k}$ boyutlu alt uzam üzerine eşlendiği $\mathbf{d} \times \mathbf{k}$ -boyutlu bir dönüşüm matrisi $\mathbf{W}$ 'nin oluşumu olarak anlaşılabilir [88]. Şekil 13'te sunulan bir akış şeması, yeni bir boyuta dönüştürülmüş en uygun özellikleri seçmek için PCA sürecini göstermektedir.

$$\begin{aligned}
\vec{S} &= [s_1, s_2, \dots, s_d], & \vec{S} &\in \mathbb{R}^d \\
\downarrow \vec{S}W, & & W &\in \mathbb{R}^{d \times k} \\
\vec{Z} &= [z_1, z_2, \dots, z_k], & \vec{Z} &\in \mathbb{R}^k
\end{aligned} \tag{19}$$

PCA uygulaması aşağıdaki gibi tanımlanan üç ana adımdan oluşur:


1. Veri setinden kovaryans matrisinin hesaplanması, özelliklerin ne kadar ilişkili olduğunu ölçen (20)'de sunulmuştur.

$$Cov_{j,q} = \frac{1}{n-1} \sum_i (S_j^i - \bar{\mu}_j)(S_q^i - \bar{\mu}_q) \tag{20}$$

2. Kovaryans matrisinden özdeğerlerin ve özvektörlerin hesaplanması. Bu hesaplamalardan, v özvektörleri, yeni özellik uzamını temsil eden kovaryans matrisi $Cov_{j,q}$ 'nin temel bileşenleri olarak bilinir ve özdeğerler λ onların büyüklükleridir.

$$Cov_{j,q} v = \lambda v \tag{21}$$

3. En uygun özellik vektörlerini seçmek ve verileri indirgenmiş boyutluluk vektörüne dönüştürmek için özdeğerlerin ve özvektörlerin uygulanması. Diğer bir deyişle, düşük büyüklüklere (düşük özdeğerlere) sahip özvektörler, veri dağılımı hakkında daha az bilgi içerir; dolayısıyla atılırlar.



Şekil 13. PCA tekniği akış şeması gösterimi

4.6.1.2. Çekirdek Temel Bileşen Analizi

Doğrusal olmayan bir boyut indirgemesi gerçekleştirmek için, yüksek boyutlu özellik uzamlarının “*Kernel Trick*” [89] kullanılarak hesaplandığı PCA’nın genişletilmiş bir versiyonu uygulanmaktadır. Bu yaklaşım, orijinal özellik seti doğrusal olarak ayrılabilir olmadığında uygulanır. Bu tekniğin işlevselliği, PCA’ya oldukça benzer, özellik uzamını yüksek bir boyutta haritalamak ve doğrusal olmayan analiz gerçekleştirmek için bir tür çekirdeğin uygulanmasında değişkenlik ile orijinal veri kümesinden daha az boyutlu örtük özellikler oluşturmak [64, 65]. Bu teknikte, yerleşmek için gereken parametre, istenen bileşenlerin sayısı, çekirdek tipi (yani, Dairesel Baz Fonksiyonları (Radial Basis Function – RBF), Polinom ve Sigmoid) ve çekirdeğin katsayılarıdır (yani, gama) [64, 65]. Bu teknik, sınıfların doğrusal olmayan olarak ayrılabilir hale geldiği yüksek boyutlu yeni bir uzama yansıtılacak olan doğrusal ayrılabilir bir problemi tanımlar. Bu yeni yüksek boyutlu uzamın temsili denklem (22)’de gösterilmiştir. Burada ϕ , doğrusal olmayan öngörülen fonksiyonu temsil eder [65].

$$\phi = \mathbb{R}^d \rightarrow \mathbb{R}^k \quad (k \gg d) \quad (22)$$

Ölçekli üç fazlı gerilim ve akımlara ve sıfır dizilere uygulanan işlem şu şekildedir: önce verileri yüksek boyutlu bir uzama dönüştüren KPCA aracılığıyla doğrusal olmayan izdüşüm yapılır, denklem (23). Daha sonra, doğrusal bir sınıflandırıcının örnekleri ayırabileceği düşük boyutlu bir veriye yansıtmak için standart PCA uygulanır, denklem (20) ve (21)’e atıfta bulunur. Ancak, yüksek hesaplama karmaşıklığı oluşabilir. Bu nedenle, hesaplama karmaşıklığını azaltmak için, yansıtılan özellik uzamındaki örneklerin hesaplanmasından kaçınmak için özelliklerin orijinal özellik uzamına benzer şekilde iyileştirme yapabildiği bir “*Kernel Trick*” uygulanır, burada denklem (24) benzerlik çekirdek matrisini temsil eder ve denklem (25), polinom, sigmoid veya RBF fonksiyonu olabilen bir çekirdek fonksiyonunun uygulanması altındaki denklemi (24) temsil eder. Bu adımda, çekirdek matrisini denklem (26) aracılığıyla merkezlemek gerekir (1_n , tüm değerlerin $\frac{1}{n}$ ’ye eşit olduğu $n \times n$ boyutlu bir matristir) çünkü yeni özellik uzamının yeni hesaplamaları bir dönüşümden önceki gibi sıfırın ortalaması [65]. Şekil 14, KPCA tekniği sürecinin bir özetini göstermektedir.

$$\Sigma = \frac{1}{n} \sum_{i=1}^n \phi(S^{(i)}) \phi(S^{(i)})^T \quad (23)$$

$$K = \phi(S) \phi(S)^T \quad (24)$$

$$\kappa(S^{(i)}, S^{(j)}) = \phi(S^{(i)})^T \phi(S^{(j)}) \quad (25)$$

$$K' = K - 1_n K - K 1_n + 1_n K 1_n \quad (26)$$



Şekil 14. KPCA tekniği akış şeması gösterimi döndürün

4.6.2. Manifold Öğrenme

Manifold öğrenimi, verilerdeki doğrusal olmayan bir düzenlemeye duyarlı doğrusal çerçevelerin geliştirilmesi olarak anlaşılabilecek bir başka doğrusal olmayan boyut azaltma yaklaşımıdır. Manifold öğrenme algoritmaları, önceden belirlenmiş sınıflar olmaksızın geometrik özellikleri kullanarak verinin kendisinden (sıfırdan öğrenme) veri setlerinin yüksek boyutlu düzenlemesini öğrenmeye çalışır ve böylece fazla uydurmayı veya boyutu azaltmada algoritmaları daha verimli hale getirir [90-93]. Bu nedenle, bu araştırmada, Boyutsallık azaltma teknikleri olarak Yerel Doğrusal Gömme (Locally Linear Embedding – LLE) ve İzometrik Özellik (Isomap) gözden geçirilmiş ve önerilmiştir.

4.6.2.1. Yerel Doğrusal Gömme

Manifold öğrenme algoritmaları, matematiksel bir fonksiyon onları modellemediği için veri sınıflarının boyut küçültme işlemi sırasında herhangi bir müdahalede bulunmadığı,


bu nedenle veri yapısının genelleştirilmesine dayalı olduğu, eğitimsiz boyutluluğun azaltılmasında kullanılan bir algoritma türüdür. Böylelikle, LLE algoritması, yansıtılan öğelerin yerel komşulukları içindeki orijinal uzamlarından azaltılmış bir alana olan mesafelerin korunmasına dayanmaktadır [65, 93, 94]. Bazı durumlarda, bu algoritma, doğrusal gömmenin en iyi öğelerini seçmek için küresel sonuçlarla karşılaştırıldığında yerel komşuların öğelerine PCA algoritmasının uygulanması olarak yorumlanır [91]. Bu araştırmada algoritma uygulaması, çıkarılan özniteliklerden, üç fazlı gerilim ve akımlardan ve bunların sıfır dizi bileşenlerinden arıza verilerinin içsel geometrik düzenlemesini öğrenmeye dayanmaktadır. Ardından, hata tanımlama ve sınıflandırma için ML algoritmaları uygulanmadan önce doğrusal olmayan gömülü manifold özellikleri yüksek boyutlu bir uzamdan düşük boyutlu bir uzama yansıtılır. Bu yöntem aşağıdaki gibi üç aşamadan oluşabilir:

1. En yakın komşuların seçimi: oluşturulan mahallelerin LLE için bilgi içerdiği ve yeniden yapılandırma sonuçlarını etkileyebileceği Öklid mesafesi ile tanımlanabilirler. Bu parametreler, sonraki bölümlerde açıklanan hiperparametre seçiminin başlangıcında belirlenir, komşuların miktarını seçmek için uygulanan yöntemler, komşu olarak KNN veya örneklerden sabit yarı çaptır.
2. Numuneleri doğrusal bir komşu kombinasyonu ile yeniden oluşturulur: bu adımda, denklem (27)'de temsil edilen maliyet fonksiyonunu en aza indirmek için ağırlık matrisini W hesaplamak gerekir. Burada w_{ij} , her bir girdinin en iyi yeniden yapılandırma ağırlıklarını temsil eder.

$$E(W) = \sum_i \left\| S_i - \sum_j w_{ij} S_j \right\|^2 \quad (27)$$

3. Kısmi özdeğer ayrılması: Bu, denklem (28)'de temsil edilen düşük boyutlu uzamda orijinal yüksek boyutu hesaplamaktan başka bir şey değildir.

$$\Phi(Y) = \left\| y_i - \sum_{j=1}^n w_{ij} y_j \right\|^2 \quad (28)$$



Şekil 15. LLE tekniği akış şeması gösterimi

4.6.2.2. İzometrik Haritalama Algoritması

LLE'nin yanı sıra, İzometrik haritalama veya Isomap, doğrusal olmayan, eğitimsiz bir boyutsal algoritmadır. Bir dereceye kadar, bu çalışmada uygulanan çok boyutlu ölçekleme ve çekirdek PCA'nın bir uzantısı, verilerin yüksek boyutlu bir uzamdan düşük boyutlu bir alana izdüşümü gerçekleştirmek için orijinal veri alanından Öklid mesafesi yerine eğri veya Jeodezik mesafeleri koruyarak. Floyd algoritması tarafından hesaplanan komşu grafiğindeki en kısa yol ile temsil edilir [65, 93, 95, 96]. Isomap algoritmasıyla ilgili daha fazla matematiksel ayrıntı için [95]'e bakın. Bu algoritma, şebeke üzerinden arıza tespiti, toprak arıza tespiti ve arıza sınıflandırması yapmak için üç fazlı gerilim ve akımlardan ve sıfır dizi katsayılarından çıkarılan özelliklerin boyutsallık indirgemesi için uygulanmıştır, algoritma uygulamasının akış şeması Şekil 16'te sunulmuştur. Isomap algoritması adımları aşağıdaki gibi özetlenmiştir:

1. Manifold mesafesi uygulanarak ve sabit bir yarıçaptaki konumları birleştirerek, komşu noktalar belirlenir.
2. Noktalar arasındaki jeodezik mesafe bir önceki adıma göre hesaplanır.
3. Son olarak, geometriyi korumak için mesafe grafiğinde Çok Boyutlu Ölçekleme uygulanır; bu nedenle, noktaların konumları optimize edilmiştir.



Şekil 16. Isomap tekniği akış şeması gösterimi

4.6.3. Diğer Yöntemler

Daha önce boyutları küçültmek için uygulanan teknikler, veri kümelerindeki doğrusal veya geometrik sıralamaya dayanıyordu. Bununla birlikte, Sözlük Öğrenme (Dictionary Learning – DL) ve Bağımsız Bileşen Analizi (Independent Component Analysis – ICA) gibi herhangi bir geometri veya mesafe metriği ile ilgili olması gerekmeyen boyutları azaltmak için bazı yöntemler uygulanabilir.

4.6.3.1. Sözlük Öğrenme

Bu algoritma seyrek kodlama olarak bilinir ve orijinal verinin seyrek gösterimini öğrenmeyi amaçlar. Algoritma, içerdiği tüm $y \in \mathbb{R}^n$ vektörlerinin atom olarak bilinen ikili vektörler olduğu, sözlük olarak bilinen bir $D \in \mathbb{R}^{n \times m}$ matrisinin bir oluşumudur. Bu atomların ağırlıklı toplamı, bir $S \in \mathbb{R}^m$; sinyalinin yeniden yapılandırılmış sürecini yapabilir; orijinal veri setindeki özelliklerin sayısı ile sözlük matrisindeki atomların sayısı arasında bir ilişki varsayarak, burada matris eksik veya fazla tamamlanmış olabilir [65, 97]. Bu araştırmada, scikit-learn kütüphanesinde bulunan DL tekniğinin mini toplu versiyonu uygulanmıştır. Bu sürüm, karmaşık hesaplamayı azaltarak tahmin süreçlerini daha hızlı hale getirir, ancak doğrulukla ilgili bir dezavantaj performansını etkileyebilir; bu sürüm, büyük veri kümelerine daha iyi uyması için önerilmiştir. DL tekniğinin bu versiyonunun özelliklerinden biri, verileri mini kümelere ayırmasıdır, burada mini küme üzerinde bir döngü sayısı yinelemeler geliştirilir [65, 97].

DL algoritması, mini küme versiyonu için bir sözlük D ve karşılık gelen bir katsayı matrisi Y , denklem (29) ve (30) ile ilgili dahili bileşenlere göre bir optimizasyon problemi olarak temsil edilebilir, burada S , eğitim veri matrisini temsil eder. vektörler, sözlük matrisi D 'yi hesaplamak için sütunlar halinde toplanır, optimizasyon probleminden temsil edilen hata $R = S - DY$ 'dir, γ bir düzenleme parametresidir ve p , etkin bir şekilde uygulanan

algoritmanın türünü (yani, ORMP veya LARS) temsil ede, $\mathbf{y}$ katsayılarını açgözlü bir şekilde çözer [65, 97, 98].

$$\{D_{opt}, Y_{opt}\} = \underset{D, Y}{\operatorname{argmin}} \sum_{l=1}^L \|y_l\|_p + \gamma \|S - DY\|^2 \text{ ve } \|d_i\|^2 = 1 \quad (29)$$

$$\{D_{opt}, Y_{opt}\} = \underset{D, Y}{\operatorname{argmin}} \frac{1}{2} \|S - DY\|_2^2 + \gamma \|D\|_1, \quad (30)$$

tüm $0 \leq i < n$ bileşenleri için $\|Y_i\|_2 = 1$ ile



Şekil 17. DL tekniği akış şeması gösterimi


4.6.3.2. Bağımsız Bileşen Analizi

Bağımsız bileşen analizi, altta yatan bileşenlerinde çok değişkenli sinyallerin kodunu çözmek veya ayırmak için bir teknik olarak tanımlanmıştır; bu bileşenler, bileşenleri arasında istatistiksel bağımlılığın en aza indirilmesini sağlar, yani bağımsızlık [99-105]. Birkaç çalışma, bu algoritmanın, sohbeti tanımlamayı amaçladığı “kokteyl partisi sorunu” sorununu çözmek için bir teknik olarak ilk kez uygulandığından bahsetmiştir odadaki ses bozukluklarına rağmen iki kişi arasında ICA, alt kümelerin bağımsızlığını en üst düzeye çıkarmak için bir dizi S_1 ve S_2 sinyalini dönüştürebildi [99-105]. Girdi kümesine ait örnek sayısının çıktı kümesindeki örnek sayısına eşit olduğuna dikkat etmek önemlidir [105]. Bileşenleriyle ilgili bağımsızlık temsilleri, veri analizi veya sıkıştırma, ses tanıma, görüntü restorasyonu ve tıbbi sinyal işleme gibi faydalı uygulamaları göstermektedir [105]. ICA algoritmasının temel bir temsili denklem (31)’de sunulmaktadır.

$$S = Ws = \sum_{i=1}^N W_i s_i \quad (31)$$

$S \in \mathbb{R}^{n \times N}$ n-boyutların veya karışımların bir vektör uzamı olduğunda, s bağımsız bileşen vektörüdür ve W bir karışım matrisidir [105]. ICA algoritması hakkında daha fazla ayrıntı için bkz. [99, 100, 104, 105]. ICA algoritması adımlarının bir özeti aşağıdaki şekilde sunulmuştur [101] ve Şekil 18, ICA algoritma adımlarını özetleyen bir akış şemasını göstermektedir:

1. Tekil değerlerini ortalamak için ortalama değer çıkarılır.
2. Beyazlatma: Bu süreçte, analiz sinyali, öğeleri arasındaki doğal korelasyonların kaldırılması ve her bir öğenin varyansının 1'e eşdeğer olması için dönüştürün.
3. D-karıştırma matrisi için başlangıç değerini rastgele hesaplayın.
4. Matrisini güncelleyin ve normalleştirin.
5. Algoritmanın yakınsadığını doğrulayın, aksi takdirde 4. adımı tekrarlayın.
6. Bağımsız bileşeni elde etmek için denklem (31)'de ifade edilen nokta çarpımını gerçekleştirin.



Şekil 18. ICA tekniği akış şeması gösterimi

Önceki araştırmalar, ICA algoritmasına PCA algoritmasının bir uzantısı olarak atıfta bulunmuştu; burada tek fark, PCA'nın korelasyonsuz bileşenleri bulma veri kovaryans matrisini optimize etmeye dayanmasıdır. Ayrıca, ICA verilerin Kurtosis'ini optimize eder ve Gauss olmayanı en üst düzeye çıkararak ve öğeler arasındaki karşılıklı bilgiyi en aza indirgeyerek bağımsız bileşenlere odaklanır [108]. Bu araştırmada, scikit-learn kitaplığında [99, 100, 104, 105] bulunan, hızlı bir hesaplama için bilgileri manipüle etmek için bir teknik olarak ICA algoritmasının bir versiyonu olan negentropi FastICA'nın bir yaklaşımı

uygulanmaktadır. Yeni özellikler, bileşenlerinin istatistiksel bağımlılıkları arasındaki boyutları azaltmak ve daha iyi performans sunmak için orijinal özelliklerden (özellik çıkarma) hesaplanır. Üç fazlı gerilimler ve akımlardan hesaplanan öznitelikler dizisi ve bunların sıfır dizi bileşenleri göz önünde bulundurulur. Farklı istatistiksel özelliklerden oluşan sistemlerde bir bozulmanın meydana gelmesi sırasında geçici durum bilgilerini içerebilir. “kokteyl partisi sorununa” benzer şekilde [99-105]: amaç, bunlar meydana geldiğinde geçişlerin tanımlanmasını destekleyen analiz altındaki sinyalin orijinal bileşenlerini bulmaktır; ancak sadece bileşenlerin karışımlarını gözlemlemek mümkündür. Bu nedenle, ICA algoritması uygulanarak, incelenen sinyaldeki geçici aktivite hakkında heyecan verici bilgiler, bağımsız bileşenlerine erişim verilirken ifşa edilebilir.

4.7. Eğitimli Makine Öğrenimi Algoritmalarına Genel Bakış

Önceki bölümlerde, sağlam ML modelleri oluşturmak için gerekli olan verilerin ön işleme, özellik hesaplama ve çıkarma ve boyutsallık azaltma ile ilgili temel konular tartışılmıştır [64]. Şimdi, bu araştırma, tahminlerden önce ayarlanması gereken en alakalı bilgileri, uygulamaları ve parametreleri gözden geçirmek için eğitimli öğrenme algoritmalarına dönüyor. Eğitimli öğrenme, sınıflandırma ve regresyon olmak üzere iki ana problem tipine ayrılır [65]. Bu araştırma, bir elektrik sisteminden toplanan girdi verilerinin, arıza olarak tanımlanan bir veya daha fazla sınıfa durumları doğru bir şekilde sınıflandırması gereken kategorik problemlere dayanmaktadır. Bu araştırmanın amacına uyarlanmış en yaygın eğitimli algoritmalarından bazıları bu bölümün geri kalanında sunulmaktadır.

4.7.1.1. Lojistik Regresyon Algoritması

Lojistik Regresyon algoritması genellikle bir örneğin farklı bir sınıfa veya kategoriye ait olma olasılığını belirlemek için uygulanır (örneğin, sistemde bir hata olma olasılığı nedir?) [86]. Bu çalışmada, sistemde bir arıza olup olmadığı, hangi arızalardan hangisinin bir toprak arızası ile ilgili olduğu veya hangi arızanın hangi arıza ile ilgili olduğu şeklinde kategorize edilebilecek örneklerin doğru tahminini yapabilmek için boyut küçültme teknikleri ile birlikte LR algoritması uygulanmıştır ve besleyici bir hata olmuştur. Algoritmanın uygulanması, tahmin edilen olasılığa dayanmaktadır; örneğin, beklenen

olasılık %50'den yüksekse, LR algoritması örneğin pozitif sınıf olarak da adlandırılan “1” etiketini alacak olan o kategoriye ait olduğunu tahmin eder. Aksi takdirde, örneklenen tahmin “0” ile etiketlenmiş negatif bir sınıfa verilecektir. Bu, algoritmanın tahmin edilen örneklerin olasılık toplamına dayalı olarak ikili bir sınıflandırma gerçekleştireceği anlamına gelir. Denklem (32) lojistik regresyon algoritması kullanılarak tahmin edilen olasılığın vektörleştirilmiş bir biçimini sunar; burada $\vartheta(\cdot)$, 0 ve 1 sıralamasında bir sayı veren bir sigmoid fonksiyondur, denklem (33) [86, 106].

$$\hat{p} = h_{\theta}(S) = \vartheta(S^T \theta) \quad (32)$$

$$\vartheta(Z) = \frac{1}{1 + e^{-Z}} \quad (33)$$

Boyut azaltma performansından sonra modeli eğitmenin amacı, modelin pozitif durumlar için yüksek olasılıkları ($y = 1$) ve negatif durumlar için düşük olasılıkları ($y = 0$) tahmin etmesi için parametre vektörünü θ ayarlamaktır [86]. Denklem (34)'te gösterilen maliyet fonksiyonunda tek bir eğitim örneği için bir temsil sunulur. Tüm eğitim setindeki maliyet fonksiyonu, tüm eğitim örneklerindeki ortalama maliyettir. Denklem (35)'te gösterilen log kaybı adlı tekil bir ifadeyle yazılabilir [86]. Maliyet fonksiyonunu azaltmak veya en aza indirmek için Gradient Descent (GD) uygulaması ile bu modellerin indirgenmesi yapılmıştır, denklem (36) maliyet fonksiyonunu en aza indirmek için GD'nin her parametreye uygulanmasını göstermektedir $J(\theta)$ [86, 106].

$$c(\theta) = \begin{cases} -\log \hat{p} & \text{if } y = 1 \\ -\log(1 - \hat{p}) & \text{if } y = 0 \end{cases} \quad (34)$$

$$J(\theta) = -\frac{1}{\tilde{n}} \sum_{i=1}^{\tilde{n}} [y^i \log(\hat{p}^i) + (1 - y^i) \log(1 - \hat{p}^i)] \quad (35)$$

$$\theta_j = \theta_j - \alpha \frac{\partial}{\partial \theta_j} J(\theta) \quad (36)$$

4.7.1.2. Destek Vektör Makine Algoritması

Önceki araştırmalar, SVM'yi makine öğrenimi algoritmasında en ünlü algoritma olarak tanımlamıştı. Bu nedenle, SVM, verileri örnekler ve ayırıcı hiperdüzlem (destek vektörleri) arasındaki mesafe sınırları boyunca bölen uzamda bir dizi hiperdüzlem uygulayan, doğrusal veya doğrusal olmayan sınıflandırma, regresyon ve hatta aykırı değer ifşası elde edebilen sağlam ve çok yönlü bir algoritmadır sınırlar, doğrusal veya doğrusal olmayan çekirdekler aracılığıyla yapılabilir [64, 65, 86]. Bu algoritmanın özelliklerinden biri, özellik ölçeklerine duyarlı olmasıdır [86]; farklı özellik ölçekleriyle çalışıldığında kötü performansa ulaşılabilir; bu nedenle veriler SVM'ye girmeden önce tekil bir ölçekte ön işleme tabi tutulmalıdır.

Bir diskriminant algoritması olarak SVM uygulaması aracılığıyla bu araştırmanın amacı, N-boyutlu uzamda bir hiperdüzlem belirlemektir, örnekleri toplanan verilerden açıkça ayırt eden özneliklerin sayısını göz önünde bulundurarak, sınıflar arasındaki marjı maksimize etmektir [107]. Destek vektörleri tarafından marj mesafesinin maksimize edilmesi, yansıtılan veri örneklerinin daha yüksek çözünürlükle ilişkilendirilebileceği takviyeye katkıda bulunur. Destek vektörleri, hiperdüzleme daha yakın örneklerdir ve hiperdüzlemin konumunu ve yönünü etkileyebilir; dolayısıyla, marj mesafelerini maksimize etmek için kullanılabilirler [107, 108]. Doğrusal fonksiyonun çıktısını alıp almadığının değerlendirilmesi durumunda SVM aşağıdaki gibi çalışır. SVM kullanan doğrulama sıraları, çıktıların değerlendirildiği ve çıktı sonuçlarına bağlı olarak bir sınıfa atandığı $[-1,1]$ 'e dayanmaktadır [108]. Daha fazla matematiksel ayrıntı için [36, 84, 86, 107, 108] referanslarına bakınız. Sağlam bir SVM modeli oluşturmak için en alakalı parametrelerden bazıları aşağıda sunulmuştur:

- a. Kernels: Doğrusal bir çekirdek, örneklerin doğrusal yöntemler kullanarak kolayca ayrılmasını sağlar. Ancak, veriler bazı durumlarda doğrusal olarak ayrılamaz; bu nedenle, onları “Kernel Trick” kullanarak ayırmak için doğrusal olmayan bir yöntem uygulanmalıdır [107]. Bu araştırma boyunca hiperparametreler olarak kullanılan çekirdeklerin bir özeti Tablo 3'te sunulmuştur.
- b. Düzenleştirme: Bu parametreye genellikle “C” denir ve eğitim süreci boyunca kaç örneğin yanlış sınıflandırmayı önlediğini SVM optimizasyonuna gösterir [107]. Küçük “C” değerlerinin, optimize edicinin modeli yetersiz kılmak için daha

büyük marjlı bir ayırıcı hiperdüzlem aramasına neden olacağına dikkat edin. Öte yandan, yüksek “C” değerleri, sistemin aşırı takılmasını etkileyebilir.

- c. Gama: Bu parametre, örneklerin sınır alanına yakınlığına bağlıdır. Düşük gama ile, istenen karar çizgisini hesaplamak için varsayılan karar çizgisinden uzakta bulunan noktalar dikkate alınır. Aksi takdirde, hesaplamalar için yüksek gama, en yakın noktalar kullanılır [107].

Tablo 3. Ortak çekirdekler

Çekirdekler	Fonksiyon
Linear	$K(\mathbf{a}, \mathbf{b}) = \mathbf{a}^T \mathbf{b}$ (37)
Polynomial	$K(\mathbf{a}, \mathbf{b}) = (\gamma \mathbf{a}^T \mathbf{b} + r)^d$ (38)
Gaussian RBF	$K(\mathbf{a}, \mathbf{b}) = e^{(-\gamma \ \mathbf{a} - \mathbf{b}\ ^2)}$ (39)
Sigmoid	$K(\mathbf{a}, \mathbf{b}) = \tanh(\gamma \mathbf{a}^T \mathbf{b} + r)$ (40)

4.7.1.3. Karar Ağaçları Algoritması

Karar Ağaçları algoritması, SVM kadar çok yönlü ve parametrik olmayan bir başka ML algoritmasıdır; sınıflandırma ve regresyon problemlerinde kolaylıkla uygulanabilir [86, 109]. Veri kümesi boyutuna [109] bağlı olarak düğümler ve dallar olarak iki ögenin inşası olarak tanımlanabilir, burada tüm dahili numuneler, bir veri kümesini incelemeye dayalı kararlar vererek farklı katmanlara veya segmentasyonlara (sınıflar veya tahmin edilen değerler aralığı) ayrılır özelliklerden bir dizi açıklama veya nitelik [64, 65, 86, 109]. Kök düğüm, verileri en iyi şekilde bölen tüm özellikleri temsil eder (boyutsallık indirgemesinden önceden işlenmiş); Karar düğümlerinde numuneler değerlendirilir ve dallar aracılığıyla yaprak düğümler olarak da adlandırılan karşılık gelen tahmin edilen düğüme gönderilir [109]. Bu araştırmanın amaçlarıyla ilişkilendirmek için önceki tanımın bir uyarlaması yapılmıştır.

Özellik çıkarma tekniklerinin uygulanmasından elde edilen önceden işlenmiş eğitim veri kümesine dayanarak, karar ağacı algoritması, örneklerin kategori hedef etiketlerini

çıkarmak için bir nitelikler veya kurallar listesi öğrenir. Bu algoritma iki adımda oluşturulabilir: tümevarım ve budama. Burada tümevarım, işlemin ağaç kökünde başladığını ve örnekleri en önemli Bilgi Kazanımı (IG) ile sonuçlanan özellikler üzerine böldüğünü ima eder [64, 109]. Daha sonra, yinelemeli bir süreçte yapraklar saf olana kadar her küçük düğümde bölme modunu yeniden üretebilir; başka bir deyişle, her bir düğümdeki örneklerin tümü karşılık gelen tek gruba aittir [64]. Ayrıca budama, önerilen modelin gereksiz öğelerinde hata ayıklamak, ağacın maksimum derinliği için bir sınır oluşturarak karmaşıklığı azaltmak ve fazla uydurmayı önlemek anlamına gelir [64]. Bilgi kazancı, düğümlerin en uygun şekilde bölünmesine dayanan tüm entropi oranlarının bir ortalamasını temsil eder [64, 109]. Denklem (41) DT algoritması aracılığıyla optimize edilecek işlevi gösterir; bu fonksiyon, her bölmede IG'yi maksimize etmeyi amaçlar [71]. f_α , bölmeyi yapmak için uygulanan özelliği temsil ettiğinde, D_x ve D_h , orijin ve h_{th} minör düğümünün kümeleridir, I , bu araştırma yoluyla uygulanan safsızlık ölçüsüdür, N_x , başlangıç düğümündeki toplam örnek sayısıdır ve N_h , h_{th} minör düğümündeki örneklerin sayısı [64].

$$IG(D_x, f_\alpha) = I(D_x) - \sum_{h=1}^m \frac{N_h}{N_x} I(D_h) \quad (41)$$

(41) nolu denklemden, bilgi kazancı, orijin düğümünün safsızlığı ile küçük düğüm safsızlıklarının toplamı arasındaki ortak bir tutarsızlık olarak tanımlanabilir [64]. Denklem (41) basit versiyonda, orijin düğümünün D_{right} ve D_{left} olmak üzere iki küçük düğüme ayrıldığı denklem (42) olarak yeniden yazılabilir [64].

$$IG(D_x, f_\alpha) = I(D_x) - \frac{N_{left}}{N_x} I(D_{left}) - \frac{N_{right}}{N_x} I(D_{right}) \quad (42)$$

4.7.1.4. Rassal Orman Algoritması

RF algoritması, sağlam sınıflandırma yürütmesi, uygulanabilirliği ve ölçeklenebilirlik avantajları nedeniyle bir karar ağaçları topluluğu olarak tanımlanmıştır [64, 65, 110]. Başka bir deyişle, her bir DT'nin paralel tahmin ediciler olarak kullandığı torbalama yöntemiyle

oluşturulmuş çoklu karar ağaçlarının bir kombinasyonudur [121]. Bu algoritmayı uygulamanın arkasındaki fikir, daha az korelasyonlu (yani, önyükleme ve özellik rastgeleliği uygulayarak) ağaçlar üretmek için yüksek varyanstan muzdarip birden fazla DT aracılığıyla değerlendirmek ve sonuçlarının ortalama değerini alarak daha iyi genelleme zorlaması ile sağlam modeller oluşturmaya katkıda bulunmaktadır ve fazla takmaya karşı daha az duyarlılık [64, 121]. Ek olarak, RF algoritması ağaçların yayılması sırasında ek rastgelelik önerir; bir düğümü bölerken en yararlı özelliği aramak yerine, rastgele bir özellik alt kümesi arasındaki en iyi özelliği arar. Algoritma, daha belirgin bir ağaç çeşitliliği ile sonuçlanır, sapma varyansını değiştirir ve sıklıkla genel olarak daha güvenilir bir model döndürür.

Bu araştırmanın amaçları doğrultusunda sınıflandırma problemlerini çözmek için RF algoritması uygulanmıştır. Ana fikir, neredeyse ilişkisiz birçok ağacın, her bir karar ağacında her bir bölünme için önceden işlenmiş eğitim verilerinden rastgele birkaç gözlem örneği alarak, herhangi bir belirli kurucu modeli aşacak bir komite olarak işlev görecektir; bölme, tahmin edicilerin toplam sayısının karekökü kullanılarak hesaplanabilen rastgele bir tahmin edici örneği kullanılarak yapılacaktır [65, 112]. Bu önerinin arkasındaki fikir, ağaçların kendilerini bağımsız hatalarından koruyacaklarıdır. Başka bir deyişle, bazı ağaçlar yanlış olabilirken, diğer birçok ağaç doğru olacaktır, böylece ağaçlar grup olarak doğru yönde hareket edebilir [122]. Dolayısıyla algoritma dört kolay adımda özetlenebilir [64, 110]:

1. Eğitim veri setinden x boyutunun rastgele bir önyükleme gösterimi seçin.
2. Önyükleme temsilinden bir karar ağacı büyütün. Her düğümde:
 1. Değiştirmeden rastgele s özelliklerini seçin.
 2. Amaç fonksiyonuna göre en kullanışlı bölmeyi veren özelliği uygulayarak düğümü bölün, örneğin bilgi kazancını maksimize edin.
3. Adımları 1-2 e kez tekrarlayın.
4. Toplama etiketine oy çokluğu ile izin vermek için tahmini her bir ağaca göre atayın.

4.7.1.5. K-En Yakın Komşu Algoritması

KNN algoritması, “eğitim verilerinde” benzerlikleri bulmaya ve yeni gözlemleri komşularının benzerliklerine göre sınıflandırmaya dayanan karakteristik öğrenme yöntemi

nedeniyle makine öğrenimindeki en dost algoritmalar olarak tanımlanmıştır [113, 114]. Ayrıca, araştırmacılar bu algoritmayı örnek tabanlı öğrenme veya parametrik olmayan yöntemlerle ilişkili tembel bir öğrenici olarak önermişlerdir [64, 65]. Bu varsayım, eğitim verilerinden düzenleyici bir işlev öğrenmeyen ancak eğitim veri setinin ezberlenmesine dayanan öğrenme süreci sırasındaki basitliğine dayalı olarak yapılmıştır [64].

Araştırmanın amaçlarına uygun olarak, geçici sinyaller sırasında şebeke üzerinden arızaların doğru tanımlanması ve sınıflandırılması için KNN algoritması uyarlanmıştır. İlk olarak, boyutsallık indirgeme ön işlemlerinden veriler elde edildi. En alakalı özellikler, algoritmayı eğitmek için özellik çıkarma tekniklerinden çıkarıldı ve $\mathbf{O} \times \mathbf{A}$ matrisine yerleştirildi; burada $\mathbf{O}$, veri setindeki her bir örneği temsil eder ve $\mathbf{A}$, en alakalı özelliklerin uzunluğunu temsil eder. Ayrıca, verileri sınıflandırmak için en yakın noktayı işlemek için bir mesafe metrik işlevi uygulanır.

Bu adımda algoritma, sınıflandırma altındaki hedef değerlere en iyi uyum sağlayan δ örneklerini bulmaya çalışır. Bu, çoğunluk oyu, yeni veri noktasının δ en yakın komşuları arasındaki sınıf etiketini belirlediğinden anlaşılabilir. Doğru δ değerlerini bulmak, modele fazla uydurma ve eksik uydurma arasındaki dengeyle ilgili bir zorluğu temsil eder; bu parametre, Grid Search algoritması ve K-Katlamalı Çapraz Doğrulama (K-Fold Cross-Validation) uygulanarak seçilmiştir. Bu çalışmada, bir uzaklık metrik fonksiyonu olarak Minkowski mesafesi, scikit-learn kütüphanelerinden denklem (43)'te temsil edilerek uygulanmıştır, burada değerinin ayarlanması Manhattan mesafesini ($p = 1$) ve Öklid mesafesini ($p = 2$) elde edebilir mesafe metrik fonksiyonunu [64, 65] gerçekleştirmek için aşağıdaki adımlar KNN algoritmasını özetleyebilir [64]:

1. Bir mesafe ölçüsü ve δ sayısını belirleyin.
2. Sınıflandırma altındaki örneklerden δ -en yakın komşuları alın.
3. Sınıf etiketini tanımlayacak çoğunluk oyu uygulayın.

$$d(y^{(i)}, y^{(j)}) = \sqrt[p]{\sum_{\delta} |y_{\delta}^{(i)} - y_{\delta}^{(j)}|^p} \quad (43)$$

4.8. Hiperparametre Seçimi

Hiper parametreler, performansları optimize etmek için değiştirilebilen veya ayarlanabilen algoritmaların ayarları olarak tanımlanır [115]. Önceki bölümlerde, bu araştırma aracılığıyla uygulanan temel ML algoritmaları ve bu algoritmalara beslenmeden önce ham verilerin kalıplara nasıl işleneceği anlatılmıştır. Bu bölüm, en iyi ayarlama algoritmaları için uygulanan bir model sunar ve önerilen algoritmalarındaki fazla ve eksik uyumu dengeler.

Hiper parametre seçimi, her modelin performansını değerlendirmek için en iyi sonuçları arayan bir dizi parametrenin ayarlandığı ve farklı kombinasyonlar aracılığıyla birkaç kez eğitildiği deneysel bir sonuçtur. Önceki araştırmalar, Grid Search algoritmasının hiperparametre optimizasyonu araması için etkili bir yöntem olduğunu öne sürmüştü [64, 115, 116]. Bu nedenle, hiperparametre koşullarının optimal sırasını belirleyerek modellerin performansını artırmaya yardımcı olan hiperparametre ayarlaması için modelleri değerlendirmek ve eğitmek için bu araştırma yoluyla Grid Search algoritması seçilmiştir. Ek olarak, Grid Search algoritması, uygulanan algoritmalarından farklı hiperparametreler için farklı değerlerin bir listesinin belirtildiği bir kaba kuvvet kapsamlı keşif modeli olarak tanımlanabilir [64]. Burada bilgisayar, bu listelerden değerlerin en uygun sırasını elde edene kadar her bir kombinasyon üzerinden model performansını değerlendirmek için birkaç kez çalışacaktır. Hiperparametre aramasını gerçekleştirmek için scikit-learn kitaplığından “GridSearchCV” uygulandı. Bu kitaplığı kullanmanın avantajlarından biri, algoritmaların hiper parametre değerlerini değiştirerek performansının ince ayarını yapmak için yararlı bir yöntem olan k-katlamalı çapraz doğrulama adlı yuvalanmış bir araç içermesidir [64, 115, 116].

Uygulanan bu araç, algoritmaların aşırı veya eksik takılmasını önlemek için kıvrımlar olarak adlandırılan K alt kümelerinde eğitim elemanı kümesinin yayılmasına dayanmaktadır [115]. Daha sonra, yinelemeli bir döngü boyunca, model K değerine dayalı olarak ayarlanır, verileri her seferinde kıvrımların (eğitim) $K - 1$ 'i üzerinde eğitir ve doğrulama verileri olarak da bilinen K . kat (test) üzerinde değerlendirir [115]. Alt kümelerin her bir katının işlenmesinden sonra, model için nihai doğrulama metriklerini bulmak için her yinelemedeki performansların ortalaması belirlenir [115]. Veri ölçekleme için standardizasyon, veri sıkıştırma için boyutsallık azaltma veya parametre ayarlamaları gibi çeşitli eşzamansız ön işleme yöntemlerinin uygulanması, modellerin uydurma, ölçekleme ve belki de eğitim

verilerini yeni bir ayrı test veri kümesi için sıkıştırma yoluyla elde edilen parametreleri yeniden işlemesi gereken karmaşık bir adımdır. Bu süreci kolaylaştırmak için, bu araştırma boyunca İşlem Hatları (“Pipelines”) scikit-learn kütüphanesi kullanılmıştır [64, 85]. İşlem hatları, yönetilmesi gereken çok veri ve uygulanması gereken birkaç veri dönüşümü olduğundan ML yöntemlerinde özellikle popülerdir [85]. İşlem hatları kullanmanın en dikkat çekici yararı, bir modelin isteğe bağlı sayıda dönüşüm seviyesi içermesine ve süreçlerin sırasını izleyerek yeni verileri tahmin etmek için uygulamasına olanak sağlamasıdır [64, 85].

4.9. Sınıflandırma Metrikleri

Önceki bölümlerde dalgacık seçimi, veri ölçekleme, özellik çıkarımı ve ML algoritması uygulaması dahil olmak üzere hata analizi ve sınıflandırması için önerilen modelin ana yapısı sunulmuştur. Bu bölüm, Tablo 4 ve Tablo 5’te özetlenen modellerin performanslarını değerlendirmek için kullanılan değerlendirme metriklerini sunar. Doğruluk metriği, genel olarak ML algoritmalarının performansını ölçmek için uygulanır. Ayrıca, modellerin alaka düzeyini değerlendirmek için kesinlik, duyarlılık ve F1-skoru gibi birkaç başka metrik aracı kullanılır. Ek olarak, Karışıklık Matrisi (CM), eğitmenli bir öğrenme algoritmasının performansının görselleştirilmesini sağlayan bir hata matrisi olarak uygulanır; burada TN, TP, FP ve FN katsayıları sırasıyla gerçek negatif, doğru pozitif, yanlış pozitif ve yanlış negatif anlamına gelir. Ayrıca, algoritmanın performansını görselleştirmek için Eğri Altında Kalan Alan (AUC) yüzdesi uygulanmıştır. Çok sınıflı etiketler için ağırlıklı ortalama uygulanmıştır; bkz. [64, 65].

Tablo 4. Ana metrikler

Metrik	Denklemler
Karışıklık Matrisi	$CM = \begin{bmatrix} TN & FP \\ FN & TP \end{bmatrix}$ (44)
Doğruluk	$Acc = \frac{TP + TN}{TP + TN + FP + FN}$ (45)
Kesinlik	$PRE = \frac{TP}{TP + FP}$ (46)
Duyarlılık	$REC = \frac{TP}{TP + FN}$ (47)
F1-skoru	$F1 = 2 \times \frac{PRE \times REC}{PRE + REC}$ (48)
Log-loss	$logloss = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M y_{i,j} \log(y_{i,j})$ (49)
Ortalama Mutlak Hata	$MAE = \frac{1}{N} \sum_i S_i - \hat{S}_i $ (50)

Tablo 5. Python kitaplıkları uygulandı

Uygulama	Python Kitaplığı	Fonksiyon
Veri Ölçeklendirme	sklearn.preprocessing	StandardScaler
Hiperparametre arama	sklearn.model_selection	GridSearchCV
Kara kutu süreçleri	sklearn.pipeline	Make_pipeline
Boyutsal küçültme	sklearn.decomposition	PCA KernelPCA FastICA MiniBatchDictionaryLearning
	sklearn.manifold	LocallyLinearEmbedding Isomap
ML algoritmaları	sklearn.svm	SVC
	sklearn.tree	DecisionTreeClassifier
	sklearn.ensemble	RandomForestClassifier
	sklearn.linear_model	LogisticRegression
	sklearn.neighbors	KNeighborsClassifier
Metrikler	sklearn.metrics	precision_score recall_score f1_score confusion_matrix mean_absolute_error log_loss auc

5. BULGULAR VE TARTIŞMA


Bu bölüm, değiştirilmiş IEEE-34 baralı test besleyicisinden önerilen hata algılama ve sınıflandırma çerçevesi sonuçlarını sunar. Bu bölüm dörde ayrılmıştır. Birinci bölümde, deneyim verileri ve kullanılan Python kütüphaneleri kısaca tanıtılmaktadır. Dalgacık ailesi seçim sonuçları, ön işleme aşamasında geliştirilen yöntemlerin üstünlüğünü göstermek için ikinci bölümde gösterilmiştir. Özellikler arasındaki karşılaştırma üçüncü bölümde sunulmuştur. Bu bölümün son kısmı, arıza tespit çerçevesi, toprak arıza tespit çerçevesi ve arıza sınıflandırma çerçevesi için test veri setinin ana hatlarını vermektedir.

5.1. Veri İşlemi

Bölüm 4.3'te bahsedildiği gibi, referans olarak alınan model, Arizona, ABD'de bulunan gerçek bir besleyiciye, bir IEEE 34 baralı test sistemine dayanmaktadır. Daha önceki araştırmalara dayalı olarak bazı düzeltmeler yapılmıştır (bkz. bölüm 4.3 ve bu bölümde bahsedilen referanslar). Simülasyonlar, DIgSILENT PowerFactory 2019 sürüm x64 bit yazılımı ve DPL programlama dili kullanılarak gerçekleştirilmiştir. Ağ üzerinden rastgele on tip arıza simüle edildi; simüle edilen arızaların bir özeti Şekil 19'da ve simülasyon detayları Tablo 1'te sunulmaktadır. Sıfır bileşen gerilim ve akım bileşenleri, üç fazlı gerilimler ve akımlardan denklem (6) kullanılarak hesaplanmıştır. % 100 DGs katkılı bir A-G arıza simülasyonu örneği Tablo 6'dan Tablo 8'e sunulmuştur. Arıza, 852-854 bölümünde, hattın toplam uzunluğunun %50'sinde $0+j0$ arıza empedansı ile gerçekleştirildi. Arıza, sinyaller üzerindeki değişimi doğrulamak ve karşılaştırmak için dört farklı noktadan rastgele ölçüldü. Simülasyondan üç fazlı gerilimler ve akımlar toplandı, sıfır sıralı voltaj ve akım denklem (1) ile hesaplandı. Tanımlama ve sınıflandırma aşamaları Jupyter Notebook, Python 3 yazılımında, yazılımda bulunan Numpy, Skicit-learn, Pandas kütüphaneleri kullanılarak gerçekleştirilir. Python, veri bilimi analizinde en son moda kelime haline geldi. Ayrıca, kullanıcıların sistemlerini hızlı ve verimli bir şekilde entegre etmelerini sağlayan geniş bir açık kaynak topluluğu, standart kütüphane işlevleri ve etkileşimli geliştirme ortamı özellikleri ile güçlü bir nesne yönelimli programlama dilidir. Bu nedenle, veri analizi çevresi aracılığıyla gerçekleştirilmiştir. Veri analizi için uygulanan Python yazılım kitaplıkları Tablo 5'te özetlenmiştir. Simülasyonlar bir Intel (R) Core (TM) i5-6400 CPU @2.70GHz, RAM 8GB, X64 bit, Windows 10 Enterprise bilgisayarda yapılmıştır.

Bununla birlikte, veriler nadiren bir öğrenme algoritmasının optimal performansı için gereken yapı veya biçimde görünür. Bu nedenle, veri ön işleme, herhangi bir ML uygulamasındaki en kritik adımlardan biridir. Veri ön işleme için DWT uygulandıktan sonra, doğru dalgacık ailesini ve minimum ayrışma seviyesini seçmek için giriş sinyallerinden çeşitli istatistiksel özellikler hesaplandı, ayrıca arıza oluşum tespiti, toprak arıza tespiti ve arıza sınıflandırma çerçevesi ile arızalı fider tespiti. Bununla birlikte, bu özelliklerden bazıları yüksek oranda ilişkili olabilir ve sonuç olarak belirli bir noktayla ilgisiz olabilir. Bu gibi durumlarda, özellikleri daha düşük boyutlu bir alt uzama sıkıştırmak için boyutluluk azaltma teknikleri uygulanmıştır. Boyutluluğu azaltmanın avantajı, daha küçük depolama alanına ihtiyaç duyulmasıdır ve öğrenme algoritması çok daha hızlı çalışabilir. Bazı durumlarda, boyutsallık azaltma, gürültüyü veya alakasız özellikleri kaldırarak veya bastırarak tahmin performansını da geliştirebilir. Öte yandan, birkaç ML algoritması, optimum yürütme için seçilen özelliklerin aynı ölçekte olmasını bekler; bu nedenle, bu araştırmada sıfır ortalamalı ve birim varyanslı standart bir normal dağılım uygulanmıştır [71], bkz. Denklem (18).

Algoritmaların eğitim ve yeni veri kümelerinde doğru çalışıp çalışmadığını belirlemek için veriler rastgele iki alt kümeye ayrılarak eğitim ve test alt kümeleri geliştirilmiştir. Eğitim seti, hiper parametre ayarı için k-katlamalı çapraz doğrulama ve Grid Search algoritmasını uygulayarak ML algoritmalarını eğitmek ve optimize etmek için kullanıldı. Aynı zamanda, nihai modeli değerlendirmek için test seti sonuna kadar tutuldu.



Şekil 19. Simetrik ve asimetrik arıza simülasyonları

Tablo 6. Arıza AG sonuçları; üç fazlı gerilim ve akım simülasyonu I

	800-802 [22.653 km]						828-830 [12.002 km]					
	VA	VB	VC	IA	IB	IC	VA	VB	VC	IA	IB	IC
Arızasız	.	.	.	.	.	.	.	.	.	.	.	.
	0.53	-1.00	0.46	-0.05	0.05	-0.01	0.47	-1.00	0.46	0.01	-0.01	0.00
	0.57	-1.00	0.43	-0.06	0.05	-0.01	0.50	-1.00	0.43	0.01	-0.01	0.00
	0.60	-0.99	0.40	-0.06	0.05	0.00	0.53	-1.00	0.40	0.01	-0.01	0.00
	0.63	-0.99	0.36	-0.07	0.05	0.00	0.56	-0.99	0.36	0.01	-0.01	0.00
	0.65	-0.98	0.33	-0.07	0.05	0.00	0.59	-0.99	0.33	0.01	-0.01	0.00
	0.68	-0.97	0.29	-0.08	0.05	0.00	0.62	-0.98	0.29	0.01	-0.01	0.00
	0.71	-0.96	0.25	-0.08	0.05	0.00	0.64	-0.97	0.26	0.01	-0.01	0.00
	0.74	-0.95	0.22	-0.08	0.04	0.01	0.67	-0.96	0.22	0.01	-0.01	0.00
	0.76	-0.94	0.18	-0.09	0.04	0.01	0.69	-0.95	0.19	0.01	-0.01	0.00
	0.78	-0.93	0.14	-0.09	0.04	0.01	0.71	-0.94	0.15	0.01	-0.01	0.00
Arıza	0.81	-0.91	0.10	-0.10	0.04	0.01	0.74	-0.92	0.11	0.01	-0.01	0.00
	0.82	-0.91	0.09	-0.10	0.04	0.02	0.48	-1.03	0.00	0.04	-0.01	-0.01
	0.82	-0.90	0.06	-0.12	0.04	0.02	0.13	-1.25	-0.25	0.09	-0.01	-0.01
	0.83	-0.89	0.01	-0.18	0.03	0.01	-0.12	-1.50	-0.56	0.12	-0.01	0.00
	0.84	-0.88	-0.04	-0.27	0.01	-0.02	-0.02	-1.42	-0.54	0.09	0.00	0.01
	0.87	-0.85	-0.06	-0.33	-0.02	-0.04	0.09	-1.13	-0.28	0.07	0.01	0.01
	0.90	-0.81	-0.08	-0.38	-0.01	-0.02	0.23	-0.88	-0.05	0.14	0.00	0.00
	0.91	-0.79	-0.12	-0.43	0.03	0.03	0.36	-0.77	0.00	0.21	0.00	0.00
	0.91	-0.78	-0.17	-0.48	0.04	0.05	0.17	-0.93	-0.22	0.25	-0.01	-0.01
	0.92	-0.76	-0.21	-0.54	0.03	0.04	-0.14	-1.16	-0.51	0.26	-0.01	-0.01
	0.93	-0.73	-0.24	-0.63	0.02	0.05	-0.05	-1.15	-0.56	0.24	0.00	0.00
	0.95	-0.70	-0.28	-0.70	0.02	0.05	0.24	-0.90	-0.37	0.24	0.00	0.00
	0.97	-0.67	-0.31	-0.72	0.02	0.06	0.30	-0.76	-0.30	0.30	-0.01	-0.01
	0.97	-0.64	-0.34	-0.73	0.03	0.07	0.25	-0.87	-0.51	0.37	-0.01	-0.02
	0.96	-0.62	-0.39	-0.78	0.03	0.08	0.10	-1.04	-0.77	0.39	0.00	-0.01
	0.97	-0.60	-0.44	-0.84	0.01	0.05	-0.04	-1.10	-0.93	0.37	0.00	-0.01
	0.97	-0.56	-0.46	-0.87	-0.02	0.02	0.04	-0.98	-0.89	0.37	0.00	-0.01
	0.98	-0.51	-0.48	-0.92	-0.02	0.02	0.24	-0.72	-0.71	0.39	0.01	0.00
	0.99	-0.48	-0.52	-0.94	0.01	0.03	0.34	-0.52	-0.57	0.43	0.01	0.00
	0.98	-0.46	-0.56	-0.95	0.01	0.03	0.19	-0.54	-0.67	0.49	-0.01	-0.01
Arızasız	.	.	.	.	.	.	.	.	.	.	.	.
	-0.57	1.00	-0.41	-0.11	-0.05	0.04	-0.07	1.21	-0.23	0.09	0.01	-0.01
	-0.60	1.00	-0.37	-0.06	-0.05	0.03	-0.07	1.21	-0.20	0.06	0.01	-0.01
	-0.63	0.99	-0.34	-0.01	-0.05	0.03	-0.08	1.21	-0.16	0.04	0.01	0.00
	-0.66	0.98	-0.30	0.05	-0.05	0.03	-0.08	1.21	-0.12	0.02	0.01	0.00
	-0.68	0.97	-0.27	0.10	-0.05	0.03	-0.08	1.20	-0.08	-0.01	0.01	0.00
	-0.69	0.97	-0.26	0.11	-0.05	0.04	-0.09	1.20	-0.07	-0.01	0.01	-0.01
	-0.70	0.97	-0.24	0.13	-0.05	0.04	-0.12	1.19	-0.07	-0.02	0.01	-0.01
	-0.72	0.96	-0.22	0.16	-0.05	0.04	-0.21	1.14	-0.08	-0.03	0.01	-0.01
	-0.75	0.95	-0.18	0.20	-0.05	0.05	-0.38	1.02	-0.15	-0.03	0.01	-0.01
	-0.78	0.93	-0.15	0.23	-0.05	0.05	-0.59	0.88	-0.23	-0.03	0.01	-0.01
	-0.81	0.91	-0.12	0.24	-0.06	0.06	-0.80	0.77	-0.29	-0.04	0.01	-0.01
	-0.83	0.89	-0.08	0.23	-0.07	0.06	-0.99	0.69	-0.30	-0.03	0.01	-0.01
	-0.85	0.88	-0.04	0.21	-0.07	0.06	-1.08	0.68	-0.24	-0.03	0.01	-0.01
	-0.87	0.86	0.00	0.18	-0.07	0.05	-1.08	0.74	-0.12	-0.02	0.01	-0.01

Tablo 6'nın devamı

Arızasız	-0.89	0.84	0.04	0.15	-0.07	0.05	-1.02	0.84	0.05	-0.02	0.01	-0.01
	-0.90	0.83	0.08	0.13	-0.06	0.05	-0.92	0.94	0.22	-0.01	0.01	-0.01
	-0.91	0.81	0.12	0.12	-0.04	0.06	-0.81	1.00	0.34	-0.01	0.01	-0.01
	-0.93	0.79	0.16	0.12	-0.03	0.06	-0.72	1.01	0.41	-0.01	0.00	-0.01
	-0.94	0.76	0.19	0.13	-0.02	0.06	-0.68	0.96	0.40	-0.01	0.00	-0.01
	.	.	.	.	.	.	.	.	.	.	.	.

Tablo 7. Arıza AG sonuçları; üç fazlı gerilim ve akım simülasyonu II

		836-840 [10.581 km]						846-848 [10.654 km]					
		VA	VB	VC	IA	IB	IC	VA	VB	VC	IA	IB	IC
Arızasız	.	.	.	.	.	.	.	.	.	.	.	.	.
	0.47	-1.00	0.46	-0.02	0.04	-0.02	0.47	-1.00	0.46	0.06	-0.06	0.00	0.00
	0.50	-1.00	0.43	-0.02	0.04	-0.02	0.50	-1.00	0.43	0.06	-0.06	0.00	0.00
	0.53	-1.00	0.40	-0.02	0.04	-0.02	0.52	-0.99	0.40	0.06	-0.06	0.00	0.00
	0.56	-0.99	0.36	-0.02	0.04	-0.02	0.55	-0.99	0.36	0.06	-0.06	0.00	0.00
	0.58	-0.99	0.33	-0.02	0.04	-0.02	0.58	-0.98	0.33	0.06	-0.05	-0.01	-0.01
	0.61	-0.98	0.29	-0.02	0.04	-0.01	0.61	-0.98	0.30	0.07	-0.05	-0.01	-0.01
	0.64	-0.97	0.26	-0.03	0.04	-0.01	0.63	-0.97	0.26	0.07	-0.05	-0.01	-0.01
	0.66	-0.96	0.22	-0.03	0.04	-0.01	0.66	-0.96	0.22	0.07	-0.05	-0.02	-0.02
	0.69	-0.95	0.19	-0.03	0.04	-0.01	0.68	-0.95	0.19	0.07	-0.05	-0.02	-0.02
	0.71	-0.94	0.15	-0.03	0.04	-0.01	0.71	-0.93	0.15	0.07	-0.05	-0.02	-0.02
Arıza	0.73	-0.92	0.11	-0.03	0.03	-0.01	0.73	-0.92	0.12	0.07	-0.04	-0.02	-0.02
	0.53	-1.06	-0.04	-0.03	0.03	-0.01	0.55	-1.07	-0.05	0.04	-0.03	-0.01	-0.01
	0.20	-1.28	-0.29	-0.03	0.04	-0.01	0.22	-1.29	-0.30	0.00	-0.01	0.01	0.01
	-0.15	-1.48	-0.53	-0.03	0.04	-0.01	-0.16	-1.47	-0.53	-0.01	0.00	0.02	0.02
	-0.16	-1.39	-0.49	-0.03	0.04	-0.01	-0.18	-1.38	-0.47	0.05	-0.03	-0.02	-0.02
	0.07	-1.15	-0.29	-0.04	0.04	-0.01	0.07	-1.15	-0.28	0.09	-0.05	-0.04	-0.04
	0.34	-0.89	-0.07	-0.04	0.05	-0.01	0.36	-0.90	-0.08	0.05	-0.03	-0.02	-0.02
	0.36	-0.80	-0.03	-0.04	0.05	-0.01	0.37	-0.81	-0.04	0.01	0.00	0.00	0.00
	0.11	-0.94	-0.21	-0.04	0.05	-0.01	0.10	-0.93	-0.20	0.00	0.00	0.00	0.00
	-0.15	-1.12	-0.44	-0.04	0.05	-0.01	-0.17	-1.12	-0.44	0.04	-0.01	-0.02	-0.02
	-0.15	-1.15	-0.53	-0.05	0.05	-0.01	-0.16	-1.14	-0.52	0.08	-0.03	-0.05	-0.05
	0.19	-0.92	-0.38	-0.05	0.05	0.00	0.19	-0.92	-0.37	0.11	-0.04	-0.07	-0.07
	0.42	-0.77	-0.31	-0.05	0.05	0.00	0.44	-0.78	-0.32	0.08	-0.02	-0.05	-0.05
	0.27	-0.91	-0.54	-0.05	0.04	0.01	0.28	-0.91	-0.54	0.02	0.01	-0.03	-0.03
	0.04	-1.06	-0.78	-0.05	0.04	0.01	0.03	-1.06	-0.78	0.02	0.02	-0.03	-0.03

Tablo 7'nin devamı

Arıza	-0.05	-1.06	-0.88	-0.05	0.04	0.02	-0.06	-1.06	-0.87	0.04	0.01	-0.05
	0.01	-0.97	-0.89	-0.06	0.04	0.02	0.01	-0.97	-0.88	0.06	0.00	-0.06
	0.23	-0.76	-0.76	-0.06	0.03	0.03	0.23	-0.76	-0.76	0.06	0.00	-0.06
	0.40	-0.52	-0.60	-0.06	0.03	0.03	0.42	-0.53	-0.61	0.03	0.02	-0.04
	0.25	-0.55	-0.69	-0.06	0.02	0.03	0.25	-0.55	-0.69	-0.02	0.04	-0.02
Arızasız	.	.	.	.	.	.	.	.	.	.	.	.
	-0.06	1.21	-0.23	0.01	-0.03	0.00	-0.05	1.21	-0.23	-0.04	0.05	-0.04
	-0.06	1.21	-0.19	0.01	-0.03	0.01	-0.06	1.21	-0.20	-0.04	0.05	-0.04
	-0.07	1.21	-0.16	0.01	-0.03	0.01	-0.06	1.21	-0.16	-0.04	0.05	-0.04
	-0.07	1.21	-0.12	0.02	-0.03	0.01	-0.07	1.21	-0.12	-0.04	0.05	-0.04
	-0.07	1.21	-0.08	0.02	-0.03	0.01	-0.07	1.20	-0.08	-0.04	0.04	-0.05
	-0.08	1.21	-0.07	0.02	-0.03	0.01	-0.07	1.20	-0.08	-0.04	0.04	-0.05
	-0.10	1.18	-0.07	0.02	-0.04	0.01	-0.10	1.18	-0.07	-0.04	0.04	-0.05
	-0.18	1.13	-0.10	0.02	-0.04	0.02	-0.17	1.13	-0.10	-0.05	0.05	-0.05
	-0.35	1.01	-0.16	0.02	-0.04	0.02	-0.34	1.01	-0.17	-0.07	0.05	-0.05
	-0.57	0.88	-0.24	0.02	-0.04	0.02	-0.57	0.88	-0.24	-0.08	0.05	-0.06
	-0.79	0.76	-0.30	0.02	-0.03	0.02	-0.79	0.76	-0.30	-0.09	0.05	-0.06
	-0.97	0.68	-0.31	0.02	-0.03	0.02	-0.97	0.68	-0.31	-0.09	0.05	-0.06
	-1.07	0.68	-0.25	0.02	-0.03	0.02	-1.07	0.68	-0.25	-0.10	0.05	-0.06
	-1.09	0.74	-0.12	0.02	-0.03	0.02	-1.09	0.74	-0.12	-0.09	0.04	-0.06
	-1.03	0.84	0.06	0.02	-0.02	0.03	-1.03	0.84	0.06	-0.08	0.04	-0.06
	-0.93	0.94	0.22	0.02	-0.02	0.03	-0.93	0.94	0.22	-0.07	0.03	-0.06
	-0.82	1.00	0.35	0.02	-0.02	0.03	-0.82	1.00	0.35	-0.06	0.02	-0.06
	-0.72	1.02	0.42	0.02	-0.02	0.03	-0.73	1.02	0.43	-0.04	0.01	-0.07
	-0.69	0.96	0.41	0.02	-0.02	0.03	-0.69	0.96	0.41	-0.04	0.01	-0.07
	.	.	.	.	.	.	.	.	.	.	.	.

Tablo 8. Arıza AG sonuçları; sıfır sıralı gerilim ve akım

	800-802		828-830		836-840		846-848	
	V0	I0	V0	I0	V0	I0	V0	I0
Arızasız	.	.	.	.	.	.	.	.
	-5.82E-04	-4.28E-03	-2.19E-02	4.31E-04	-2.25E-02	-1.42E-06	-2.25E-02	2.48E-04
	-5.93E-04	-5.28E-03	-2.24E-02	4.37E-04	-2.30E-02	-1.42E-06	-2.30E-02	3.62E-04
	-6.04E-04	-6.27E-03	-2.28E-02	4.42E-04	-2.34E-02	-1.41E-06	-2.34E-02	4.75E-04
	-6.13E-04	-7.25E-03	-2.32E-02	4.46E-04	-2.38E-02	-1.39E-06	-2.38E-02	5.88E-04

Tablo 8'in devamı

	-6.22E-04	-8.22E-03	-2.35E-02	4.50E-04	-2.42E-02	-1.38E-06	-2.42E-02	7.00E-04
	-6.30E-04	-9.18E-03	-2.39E-02	4.53E-04	-2.45E-02	-1.36E-06	-2.45E-02	8.11E-04
	-6.37E-04	-1.01E-02	-2.41E-02	4.56E-04	-2.48E-02	-1.34E-06	-2.48E-02	9.21E-04
	-6.43E-04	-1.11E-02	-2.44E-02	4.57E-04	-2.51E-02	-1.32E-06	-2.51E-02	1.03E-03
	-6.48E-04	-1.20E-02	-2.46E-02	4.59E-04	-2.53E-02	-1.30E-06	-2.53E-02	1.14E-03
	-6.53E-04	-1.29E-02	-2.48E-02	4.59E-04	-2.55E-02	-1.27E-06	-2.55E-02	1.24E-03
Arıza	-6.56E-04	-1.38E-02	-2.49E-02	4.59E-04	-2.56E-02	-1.25E-06	-2.57E-02	1.35E-03
	-1.87E-03	-1.54E-02	-1.80E-01	8.47E-03	-1.89E-01	-3.54E-04	-1.90E-01	1.15E-03
	-6.94E-03	-2.25E-02	-4.55E-01	2.30E-02	-4.59E-01	-4.67E-04	-4.58E-01	1.07E-03
	-1.98E-02	-4.80E-02	-7.27E-01	3.75E-02	-7.20E-01	-1.07E-04	-7.19E-01	1.19E-03
	-2.78E-02	-9.32E-02	-6.59E-01	3.32E-02	-6.77E-01	1.98E-04	-6.77E-01	1.24E-03
	-1.38E-02	-1.31E-01	-4.42E-01	3.02E-02	-4.53E-01	2.89E-04	-4.53E-01	1.20E-03
	6.16E-03	-1.34E-01	-2.31E-01	4.85E-02	-2.06E-01	2.50E-04	-2.07E-01	1.15E-03
	1.60E-03	-1.23E-01	-1.36E-01	7.03E-02	-1.58E-01	-1.41E-04	-1.59E-01	9.42E-04
	-1.44E-02	-1.32E-01	-3.29E-01	7.74E-02	-3.47E-01	-2.70E-04	-3.46E-01	8.43E-04
	-1.69E-02	-1.59E-01	-6.05E-01	7.80E-02	-5.73E-01	-2.28E-04	-5.74E-01	7.85E-04
	-1.51E-02	-1.85E-01	-5.87E-01	7.88E-02	-6.09E-01	1.43E-04	-6.08E-01	8.97E-04
	-1.22E-02	-2.06E-01	-3.42E-01	8.05E-02	-3.66E-01	3.81E-04	-3.67E-01	9.80E-04
	-1.73E-03	-2.14E-01	-2.53E-01	9.34E-02	-2.19E-01	-5.91E-05	-2.20E-01	7.47E-04
	-1.40E-03	-2.11E-01	-3.77E-01	1.15E-01	-3.90E-01	-3.16E-04	-3.90E-01	6.23E-04
	-1.68E-02	-2.23E-01	-5.70E-01	1.25E-01	-6.01E-01	-1.50E-04	-6.01E-01	7.11E-04
	-2.59E-02	-2.58E-01	-6.89E-01	1.22E-01	-6.62E-01	1.29E-05	-6.62E-01	7.42E-04
	-1.71E-02	-2.93E-01	-6.12E-01	1.23E-01	-6.15E-01	8.55E-05	-6.15E-01	7.28E-04
	-3.46E-03	-3.05E-01	-3.97E-01	1.33E-01	-4.28E-01	3.18E-04	-4.27E-01	8.50E-04
	-2.86E-03	-3.02E-01	-2.51E-01	1.47E-01	-2.38E-01	9.92E-05	-2.39E-01	7.55E-04
	-1.01E-02	-3.06E-01	-3.41E-01	1.59E-01	-3.30E-01	-2.98E-04	-3.30E-01	5.54E-04
Arızasız	7.69E-03	-4.51E-02	3.03E-01	3.04E-02	3.07E-01	1.35E-05	3.07E-01	1.66E-05
	7.96E-03	-2.87E-02	3.15E-01	2.24E-02	3.18E-01	1.31E-05	3.18E-01	-4.00E-08
	8.22E-03	-1.21E-02	3.26E-01	1.44E-02	3.29E-01	1.27E-05	3.29E-01	-1.67E-05
	8.47E-03	4.44E-03	3.36E-01	6.39E-03	3.40E-01	1.23E-05	3.40E-01	-3.34E-05
	8.71E-03	2.10E-02	3.46E-01	-1.66E-03	3.50E-01	1.18E-05	3.50E-01	-5.01E-05
	8.74E-03	2.33E-02	3.48E-01	-2.80E-03	3.52E-01	1.18E-05	3.52E-01	-5.25E-05
	8.71E-03	3.16E-02	3.33E-01	-5.85E-03	3.36E-01	-3.31E-05	3.36E-01	-9.20E-05
	8.04E-03	4.16E-02	2.82E-01	-8.24E-03	2.84E-01	-9.95E-05	2.84E-01	-1.58E-04
	5.26E-03	5.34E-02	1.64E-01	-9.57E-03	1.67E-01	-1.54E-04	1.67E-01	-2.56E-04
	2.61E-04	5.71E-02	2.21E-02	-9.76E-03	2.33E-02	-1.56E-04	2.34E-02	-3.71E-04


Tablo 8'in devamı

Arızasız	-4.06E-03	5.16E-02	-1.09E-01	-9.49E-03	-1.11E-01	-1.34E-04	-1.11E-01	-5.23E-04
	-5.42E-03	4.08E-02	-2.01E-01	-6.75E-03	-1.99E-01	-5.63E-05	-1.99E-01	-6.84E-04
	-5.47E-03	2.90E-02	-2.16E-01	-2.11E-03	-2.15E-01	2.55E-05	-2.15E-01	-8.66E-04
	-5.03E-03	1.79E-02	-1.55E-01	1.18E-03	-1.58E-01	1.03E-04	-1.57E-01	-1.05E-03
	-1.95E-03	1.06E-02	-4.62E-02	2.04E-03	-4.30E-02	1.51E-04	-4.30E-02	-1.23E-03
	2.73E-03	1.12E-02	7.59E-02	2.10E-03	7.83E-02	1.17E-04	7.82E-02	-1.42E-03
	5.51E-03	1.90E-02	1.78E-01	1.52E-03	1.77E-01	1.01E-04	1.77E-01	-1.56E-03
	6.08E-03	2.99E-02	2.36E-01	-1.15E-03	2.40E-01	3.93E-05	2.40E-01	-1.69E-03
	5.88E-03	4.07E-02	2.26E-01	-4.78E-03	2.28E-01	-6.54E-05	2.28E-01	-1.82E-03
	.	.	.	.	.	.	.	.


5.2. Dalgacık Ailesi Seçim Sonuçları

Bu bölümde, dalgacık ailesi seçiminden elde edilen sonuçlar sunulmaktadır. Test sonuçları, (1) ile hesaplanan sıfır bileşenli gerilim bileşeninin (Z_v) uygulanmasıyla gerçekleştirilmiştir. Bu adımdaki Z_v uygulaması, literatürde tartışılan varsayımlara dayanıyordu [118]. Gerçekleştirilen simülasyonlarda, olası arıza olayının farklı çalışma koşulları ve konumları göz önünde bulundurulmuştur; simülasyon detayları için Tablo 1'e bakınız. Z_v sinyalinin normal koşul ve arıza mevcudiyeti altındaki temsilleri Şekil 20 ve Şekil 21'de sunulmuştur. Literatürden yola çıkarak, ortaya çıkan sinyallerin, sinyalin yükselmesi veya azalmasıyla kendini gösterebilecek geçici olaylar varlığında bozulmalar sunacağı öğrenilmiştir. Normal koşullarda, arıza veya bozulma olmadan, ortaya çıkan sinyalin değeri yaklaşık olarak sıfırdır. Toplam örneklerden 600 örnek boyutuna sahip "WTselection" adlı bir alt küme, sinyali kullanılarak en iyi dalgacık ailesi dönüşümü ve ayrıştırma seviyelerini işlemek için rastgele seçildi. Sinyal analizi için en uygun dalgacık ve ayrıştırma düzeyini bulmak için referanslar arasından en popüler Ortogonal Dalgacık aileleri, yani Haar, db3, db4, db6, Sym4 ve Coif2 dalgacıkları seçilmiştir. İlk olarak, numuneler arasında daha sonra maksimum ayrışma parametresi olarak kullanılacak olan minimum seviyeyi bulmak için tüm numunelerden minimum entropi ayrışması hesaplandı ve karşılaştırıldı. Daha sonra, "WTselection" alt kümesi 70:30 oranında dağıtıldı ve her iki alt kümeden on iki özellik hesaplandı (bkz. Tablo 2). Hiper parametre ayarı için Grid Search algoritması ve K-katlamalı çapraz doğrulama kullanılarak ML modelini ayarlamak için verilerin %70'i eğitim verisi olarak kullanılırken, hesaplama süresini azaltmak için **K** beşe


yerleştirildi ve SVM algoritması kullanıldı diskriminant algoritması. Minimum entropi ayrışım hesaplamaları ve bunların karşılaştırmalarından, dokuzun minimum ayrışma düzeyi olduğu elde edilmiştir. Bu nedenle, WT'lerin seçimine ilişkin karar vermede maksimum ayrıştırma düzeyi olarak kullanılmıştır. 1. seviyeden 9. seviyeye kadar, “WTselection” setindeki tüm numuneler için doğruluk ve hesaplama süresi sonuçları hesaplanır. Şekil 22 ve Şekil 23'te sunulan değerlendirme sonuçları, test alt kümesinden alınan doğruluk ve hesaplamalı zaman ölçümleridir. Simülasyon sonuçları, db3 dalgacık ailesinin, ayrıntı bileşenlerinin 7. ayrıştırma düzeyinde %96.85 değeri ve toplam 1.23sn hesaplama süresi ile en iyi doğruluk sonuçlarını sunduğunu göstermiştir. Bu nedenle, ayrıştırma seviyesi ve dalgacık ailesi, sinyal ön işleme için yedi ve db3'e ayarlanmıştır. Şekil 24, sinyal ön işleme işlevi olarak db3 kullanan dokuz ayrıştırma seviyesinin bir temsilini göstermektedir.




Şekil 20. (a) Normal koşullar altında, (b) Arızalı koşullar altında




Şekil 21. Dört farklı hata türü ve normal koşullar altında Z_v 'nin gösterimi



Şekil 22. Dalgacık ailesi seçimi için sıfır bileşen gerilim bileşeni doğruluğu sonuçları




Şekil 23. Sıfır bileşen gerilim bileşeni hesaplama süresi sonuçları




Şekil 24. Detay ve yaklaşım katsayıları gösteriminin dokuz ayrıştırma seviyesi

5.3. Özellik Önem Analizi


Giriş sinyallerine DWT uygulandıktan sonra, her giriş sinyali için on iki özellik hesaplanmıştır (bkz. Tablo 2). Giriş özelliği, J 'nin sinyalin uzunluğunu temsil ettiği ve E 'nin bu sinyalden hesaplanan on iki özelliği temsil ettiği bir $J \times E$ matrisinde alt bölümlere ayrılmıştır. Özelliklerin önemi şu şekilde sunulmuştur: Şekil 25, sıfır bileşen gerilimi uygulayarak arıza tanımlama işlemi sırasındaki sonuçları göstermektedir. Şekil 26, sıfır bileşen akımı tarafından toprak arıza tespiti sırasında bir genel bakış sunar. Şekil 27, üç fazlı gerilimler ve akımlardan arıza sınıflandırma işlemi sırasındaki bir özetini göstermektedir.



Şekil 25. Arıza tespiti için özellik önemine genel bakış




Şekil 26. Toprak arıza tespiti için özellik önemine genel bakış



Şekil 27. Arıza sınıflandırması için özellik önemine genel bakış

Şekil 25'ten Şekil 27'e kadar olan sonuçlar, [119]'da bahsedildiği gibi Python kullanılarak algoritmaların değerlendirme sonuçlarına dayalı olarak hesaplanmıştır. LR ve SVM için, tahminin girdi örneklerinin ağırlıklı miktarı olduğu her yerde Doğrusal algoritmaların bir kalıba uyduğu katsayı kavramı uygulanarak özellik sonuçları elde edildi; bu nedenle, bu katsayılar, scikit-learn kitaplığı modellerinden “coef_” özniteliği kullanılarak özellik önem puanının kaba bir karakteri olarak doğrudan uygulanabilir. Öte yandan, DT'ler ve RF modeli, her bir ağaçtaki safsızlık azalmasının hesaplanan ortalama ve standart sapmasına dayalı olarak her bir girdi özelliği için karşılık gelen önem oranlarını kurtarmak üzere ulaşılabilen bir “feature_importances_” özniteliği ile donatılmıştır. Son olarak, KNN özniteliğinin önemi, KNN algoritması doğal olarak öznitelik seçimini desteklemediğinden, scikit-learn kitaplığından “permutation_importance()” işlevi aracılığıyla permütasyonlar uygulanarak hesaplanmıştır; süreci şu şekilde sunar: ilk olarak, model veri kümesine uyar; daha sonra, veri kümesindeki bir özelliğin örnekleri karıştırılmış olsa bile, bir veri kümesi üzerinde tahmin yapmak için birkaç kez uygulanır ve tekrarlanır; sonuç, her bir girdi özelliği için bir ortalama önem puanıdır.

Bir özelliğin etkisini incelemek için, tüm özelliklerini kullanan beş ML algoritmasından doğruluklar hesaplandı. İlk olarak, toplanan veriler 65:35 oranında bölündü, burada %65'i makine öğrenimi modellerini ayarlamak için eğitim verileri olarak kullanıldı. Kalan %35, modelin doğru bir şekilde ayarlandığını doğrulamak ve daha önce hiç görülmemiş veriler üzerinde tahminler yapmak için test verileri olarak uygulandı. Veri ölçeklendirme işlemi işlem hatları düzenlemeleri ile gerçekleştirilmiştir; Şekil 28 ve denklem (18)'de sunulmuştur. Eğitim alt kümesi, makine öğrenimi yapılandırmalarını ayarlamak için kullanıldı; bu aşamada, beş ML modeli için hiperparametreyi ayarlamak için “GridSearchCV” kitaplığı kullanıldı (bkz. bölüm 4.7). Uygulanan hiperparametrenin sıralaması, önceki literatüre dayalıdır ve bu araştırmadaki gereksinimlere göre ayarlanmıştır. Modellerin eksik ve fazla takılmasını dengelemek için k-katlamalı çapraz doğrulama kullanıldı. Eğitim verileri üzerinde K-katlamalı çapraz doğrulama işlevini gerçekleştirmek için K=5 değeri yerleştirildi (bkz. bölüm 4.8).



Şekil 28. Basit bir ML modelleri için işlem hattı akış şeması

Performansları ölçmek için kullanılan fonksiyon, Tablo 2’de ayrıntıları verilen denklem (45) ile doğruluktur. ML modellerini uygulayarak, Bölüm 4.7’ye ve Şekil 28’de sunulan akış şemasına atıfta bulunarak, elde edilen sonuçlar Tablo 9’da özetlenmiştir.

Tablo 9. Basit bir ML modeli için doğruluk sonuçları

Metrik: Doğruluk %	LR		SVM		DT		RF		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
Arıza tespiti	88.94	91.42	97.45	96.90	98.09	98.06	98.23	98.13	97.63	98.40
Toprak arıza tespiti	87.46	88.10	88.08	88.62	87.82	90.15	88.38	89.10	90.07	91.04
Arıza sınıflandırması	91.54	91.34	94.51	95.04	94.59	96.68	96.76	97.13	95.55	96.98

Elde edilen sonuçlara rağmen, bu araştırma, yüksek boyuttan düşük boyutlu uzama geçişi sağlayan öznitelik çıkarma tekniklerinin uygulamalarına odaklanmaktadır; diğer bir deyişle, ağdaki elektrik arızalarının analizi için önerilen algoritmaların performansını etkileyebilecek gereksiz veya alakasız özelliklerin miktarını azaltın. Bu nedenle ML modellerini artırabilecek tekniklerin uygulanması gerekmektedir. Şekil 25’ten Şekil 27’e kadar olan sonuçlardan, bazı özelliklerin doğruluk sonuçlarında gösterilen ML modelleriyle alakasız veya gereksiz olduğu yorumlanabilir. [119]’da tanıtilen bir terminoloji, öznitelik

mühendisliği sürecini uygulayarak özniteliklerin önemini etkisini vurgular. Bu, bir özneteliğin değerli bir hedef değişkeni tahmin etmede olduğu temel alınarak girdi özniteliklerine bir F faktörünün yüklenmesinden bahseder. Dolayısıyla, bir modelin karmaşıklığı, kullanılan özniteliklerin sayısı ile doğrusal olarak ilişkilidir; dolayısıyla modeller, verilerdeki varyans nedeniyle hatalara karşı daha duyarlı hale gelebilir.


5.4. Boyutsal Küçültme ve Makine Öğrenimi Algoritmaları Sonuçları

Bölüm 4.6’da bahsedildiği gibi, veriler ML analizinin omurgası olarak kabul edilir. Bu nedenle, modellerin bunlara uyması ve daha önce hiç görülmemiş veriler üzerinde tahminler yapması için en alakalı ve yedekli olmayan özelliklerle eğitilmesi gerekir. Unsurları düşürmenin basit bir yöntemi, bir modelle ilgili değerlerini ifade etmek, yetersiz özellikleri ortadan kaldırmak veya bir öncekinden yeni özelliklere projeksiyon yapmak ve performansı ve etkinliğini artırmak için modeli yeniden değerlendirmektir. Bu yöntemi takip etmek için öznetelik çıkarma tekniklerinin yani, boyutsallık azaltma; ML modellerini eğitmeden önce önceden işlenmiş verilere uygulanmıştır. Boru hattı düzenleme modeli; [64]’ten esinlenerek; Bu araştırma boyunca uygulanan Şekil 29’da gösterilmiştir. Uygulanan tam modelle ilgili daha fazla ayrıntı için bkz. Bölüm 4.2.

Toplanan veriler, sırasıyla 65:35 eğitim ve test veri kümesi oranında bölünmüştür. Tüm veri setlerini işlemek için bir işlem hatları düzenleme modeli uygulandı. Altı farklı eğitimsiz boyut azaltma tekniği ve beş eğitimli ML modeli için hiperparametreyi ayarlamak için “GridSearchCV” kitaplığı kullanıldı (sırasıyla Bölüm 4.6 ve 4.7’ye bakın). Uygulanan hiperparametre dizisi, önceki literatüre dayanıyordu ve “GridSearchCV” kitaplığı tarafından ayarlandı. K-katlamalı çapraz doğrulama için, eğitim verileri üzerinde gerçekleştirmek için $K=5$ değeri belirlenmiştir (bkz. Bölüm 4.8).

ML algoritmasının performansından elde edilen karmaşık sonuçları değerlendirmek ve iletmek için, sonuçları yorumlamak için çeşitli sezgisel işlevler uygulanmıştır (bkz. Bölüm 4.9). ML algoritmasının hata oranı, Doğruluk, Log-loss ve MAE uygulanarak, eğitim örneklerinden öğrenilerek sabitlenecektir. Öte yandan, tahmin edilen modellerden doğru ve yanlış sonuçları özetlemek için Karışıklık Matrisi kullanılmıştır. Kesinlik ve Duyarlılık metrikleri, modelin elektrik sistemi üzerindeki ne kadar arıza veya arızayı yakaladığını ölçmek için kullanılmıştır. Başka bir deyişle, Kesinlik puanları, modelin öngördüğü tüm örneklere bölünerek doğru şekilde tahmin edilen hataların sayısını temsil eder. Ayrıca,

Duyarlılık puanları, doğru tahmin edilen hataların sayısının tahmin edilen tüm doğru hatalara bölünmesiyle elde edilir. Bu metrikler sonuçlar sırasında zıt oranlarda, yani yüksek ve düşük oranlarda sunulabilir. Sistem yüksek bir Kesinlik puanı, ancak düşük bir Duyarlılık puanı sunduğunda, çok az sayıda hata tespit edildi, ancak bunların çoğu doğru bir şekilde tahmin edildi. Yine de, tahminlerin Kesinlik puanı düşük, ancak Duyarlılık puanı yüksek olsun, birçok durum hata olarak işaretlendi ve sonuç olarak birçok hata sonucunu geride bıraktı. Ancak, işaretlenen örneklerin çoğu bir hata olmayacaktır. Bu eşitsizliği gidermek için, sonuçlardan ödün vermek ve her iki puanlama metriğine aynı önemi vermek için Kesinlik - Duyarlılık sonuçlarından harmonik ortalama olarak tanımlanan F1-skoru metriği uygulanmıştır.




Şekil 29. Önerilen modelden boru hattı akış şeması özeti

5.4.1. Arıza Tespit Sonuçları


Bu bölümde, modelin ilk adımı olarak arıza tespit sonuçları, Şekil 30'dan Şekil 34'e ve Tablo 10'dan Tablo 14'e kadar sunulmaktadır. Sıfır bileşen gerilim katsayısı değişiklikleri, sinyal üzerindeki geçici olayların varlığını tespit etmek için kullanılır. DWT

aracılığıyla sinyallerin on iki özelliği ve dönüşümü yapılmış ve tespit amaçları için kullanılmıştır. Şekil 29'da özetlenen öğrenme modeli, sinyaldeki her değişiklik veya bozulma göstergesi için hata olasılığını üretecektir. Hata olasılıkları uygun etiketlere ne kadar yakınsa (yani hata için bir veya hata değil için sıfır), log kaybı ve MAE fonksiyonunun değeri o kadar düşük olur ve ayrıca yüksek doğruluk modelleri sunacaktır. Sonuçlar, hata tespit adımında ML modellerinin performansını artırmak için boyutluluk azaltma tekniklerinin kullanılmasının mümkün olduğu sonucuna varmıştır.


1. LR modellerinde elde edilen en iyi sonuçlar K-PCA, %99,29 Doğruluk, %99,61 F1, 0,03 Log-loss, 0,007 MAE ve %99,78 AUC uygulanarak elde edilmiştir. En düşük sonuçlar, DL, %94,51 Doğruluk, %96,94 F1, %0,163 Log-loss, 0,075 MAE ve %94,21 AUC uygulanarak elde edildi.
2. SVM modellerinde elde edilen en iyi sonuçlar ICA, %99,85 Doğruluk, %99,92 F-1, 0,008 Log-loss, 0,001 MAE ve %99,99 AUC uygulanarak elde edilmiştir. En düşük sonuçlar DL, %94,51 Doğruluk, %96,94 F1, %0,119 Log-loss, 0,055 MAE ve %97,42 AUC kullanılarak elde edildi.
3. DT modellerinde elde edilen en iyi sonuçlar ICA, %99,51 Doğruluk, %99,73 F-1, 0,037 Log-loss, 0,005 MAE ve %99,93 AUC uygulanarak elde edilmiştir. En düşük sonuçlar DL, %96.53 Doğruluk, %98.09 F1, 0.190 Log-loss, 0.035 MAE ve %98.89 AUC kullanılarak elde edildi.
4. RF modellerinde elde edilen en iyi sonuçlar ICA, %99,85 doğruluk, %99,92 F-1, 0,018 Log-loss, 0,001 MAE ve %99,92 AUC uygulanarak elde edilmiştir. En düşük sonuçlar DL, %98,54 Doğruluk, %99,24 F1, %0,248 Log-loss, 0,015 MAE ve %98,42 AUC kullanılarak elde edildi.
5. KNN modellerinde elde edilen en iyi sonuçlar, PCA ve KPCA, %99.93 Doğruluk, %99.96 F-1, 0.026 Log-loss, 0.007 MAE ve %99.96 AUC uygulanarak elde edilmiştir. En düşük sonuçlar DL, %98.43 Doğruluk, %99.13 F1, 0.048 Log-loss, 0.016 MAE ve %99.86 AUC kullanılarak elde edildi.




Şekil 30. Arıza tespiti için LR model sonuçları




Şekil 31. Arıza tespiti için SVM modeli sonuçları



Şekil 32. Arıza tespiti için DT model sonuçları



Şekil 33. Arıza tespiti için RF model sonuçları



Şekil 34. Arıza tespiti için KNN model sonuçları

Tablo 10. Arıza tespiti için LR hatası ve CM modeli sonuçları

	LR	LR+PCA	LR+KPCA	LR+LLE	LR+Isomap	LR+DL	LR+ICA
Logloss	0.147	0.043	0.030	0.080	0.089	0.163	0.045
MAE	0.085	0.012	0.007	0.034	0.043	0.075	0.009
TP	2439	2415	2422	2397	2361	2349	2415
TN	11	234	239	191	204	130	241
FP	230	7	2	50	37	111	0
FN	0	24	7	42	78	90	24

Tablo 11. Arıza tespiti için SVM hatası ve CM modeli sonuçları

	SVM	SVM+PCA	SVM+KPCA	SVM+LLE	SVM+Isomap	SVM+DL	SVM+ICA
Logloss	0.062	0.019	0.026	0.029	0.033	0.119	0.008
MAE	0.031	0.004	0.007	0.005	0.007	0.055	0.001
TP	2363	2427	2424	2434	2425	2330	2435
TN	234	241	237	232	235	203	241
FP	7	0	4	9	6	38	0
FN	76	12	15	5	14	109	4

Tablo 12. Arıza tespiti için DT hatası ve CM modeli sonuçları

	DT	DT+PCA	DT+KPCA	DT+LLE	DT+Isomap	DT+DL	DT+ICA
Logloss	0.050	0.038	0.042	0.142	0.067	0.190	0.037
MAE	0.019	0.006	0.007	0.016	0.014	0.035	0.005
TP	2411	2430	2428	2406	2417	2389	2432
TN	217	234	233	232	226	198	235
FP	24	7	8	9	15	43	6
FN	28	9	11	33	22	50	7

Tablo 13. Arıza tespiti için RF hatası ve CM modeli sonuçları

	RF	RF+PCA	RF+KPCA	RF+LLE	RF+Isomap	RF+DL	RF+ICA
Logloss	0.044	0.026	0.033	0.024	0.029	0.248	0.018
MAE	0.019	0.005	0.005	0.005	0.004	0.015	0.001
TP	2435	2434	2436	2431	2434	2409	2435
TN	195	232	231	236	234	232	241
FP	46	9	10	5	7	9	0
FN	4	5	3	8	5	30	4

Tablo 14. Arıza tespiti için KNN hatası ve CM model sonuçları

	KNN	KNN+PCA	KNN+KPCA	KNN+LLE	KNN+Isomap	KNN+DL	KNN+ICA
Logloss	0.051	0.026	0.026	0.090	0.041	0.048	0.016
MAB	0.016	0.007	0.007	0.003	0.002	0.016	0.002
TP	2396	2437	2437	2435	2433	2402	2434
TN	241	241	241	238	241	236	241
FP	0	0	0	3	0	5	0
FN	43	2	2	4	6	37	5


5.4.2. Toprak Arıza Tespit Sonuçları

Bu bölümde, modelin ikinci adımı olarak toprak arızası tespit sonuçları sunulmuştur. Şekil 35'ten Şekil 39'a ve Tablo 15'ten Tablo 19'a kadar, test veri seti sonuçlarını gösterir. Sıfır bileşen akım katsayısı, sinyal üzerindeki geçişlerin varlığını tespit etmek için kullanılır. Bölüm 5.4.1'de tartışılan aynı kavramı takip ederek, arıza olasılıklarının uygun etiketlere ne kadar yakın olduğunu vurgulayarak hesaplamalar yapılmıştır (yani, toprak arızası için bir veya başka bir arıza veya arıza türü için sıfır). Sonuçlar, toprak arızası tespit adımı ML modellerinin performansını iyileştirmek için boyutsallık azaltma tekniklerinin uygulanmasının mümkün olduğu sonucuna varmıştır.


1. LR modellerinde elde edilen en iyi sonuçlar PCA ve K-PCA, %89,18 Doğruluk, %90,92 F1, 0,263 Log-loss, 0,108 MAE ve %95,93 AUC uygulanarak elde edilmiştir.

En düşük sonuçlar, DL, %87.20 Doğruluk, %89.04 F1, %0.323 Log-loss, 0.128 MAE ve %91.02 AUC uygulanarak elde edildi.


2. SVM modellerinde elde edilen en iyi sonuçlar KPCA, %95,75 Doğruluk, %96,59 F-1, 0,123 Log-loss, 0,043 MAE ve %99,16 AUC uygulanarak elde edilmiştir. En düşük sonuçlar DL, %91,27 Doğruluk, %92,96 F1, 0,295 Log-loss, 0,087 MAE ve %94,61 AUC kullanılarak elde edildi.
3. DT modellerinde elde edilen en iyi sonuçlar PCA, %97,09 Doğruluk, %97,69 F-1, 0,481 Log-loss, 0,029 MAE ve %98,41 AUC uygulanarak elde edilmiştir. En düşük sonuçlara DL, %91.08 Doğruluk, %92.87 F1, %0.383 Log-loss, 0.089 MAE ve %97.19 AUC kullanılarak ulaşıldı.
4. RF modellerinde elde edilen en iyi sonuçlar KPCA, %97,13 Doğruluk, %97,71 F-1, 0,105 Log-loss, 0,029 MAE ve %99,57 AUC uygulanarak elde edilmiştir. En düşük sonuçlara DL, %91.46 Doğruluk, %93.23 F1, %0.333 Log-loss, 0.085 MAE ve %96.72 AUC kullanılarak ulaşıldı.
5. KNN modellerinde elde edilen en iyi sonuçlar, PCA, %99,03 Doğruluk, %99,23 F-1, 0,248 Log-loss, 0,009 MAE ve %99,31 AUC uygulanarak elde edilmiştir. En düşük sonuçlara DL, %90.67 Doğruluk, %92.53 F1, %0.299 Log-loss, 0.093 MAE ve %96.74 AUC kullanılarak ulaşıldı.




Şekil 35. Toprak arıza tespiti için LR model sonuçları




Şekil 36. Toprak arıza tespiti için SVM modeli sonuçları



Şekil 37. Toprak arıza tespiti için DT model sonuçları



Şekil 38. Toprak arıza tespiti için RF model sonuçları



Şekil 39. Toprak arıza tespiti için KNN model sonuçları

Tablo 15. Toprak arıza tespiti için LR hatası ve CM model sonuçları

	LR	LR+PCA	LR+KPCA	LR+LLE	LR+Isomap	LR+DL	LR+ICA
Logloss	0.300	0.263	0.263	0.257	0.290	0.323	0.261
MAE	0.119	0.108	0.108	0.116	0.130	0.128	0.113
TP	1454	1450	1450	1511	1417	1444	1444
TN	907	940	940	858	914	893	933
FP	81	48	48	130	74	95	55
FN	238	242	242	181	275	248	248

Tablo 16. Toprak arıza tespiti için SVM hatası ve CM modeli sonuçları

	SVM	SVM+PCA	SVM+KPCA	SVM+LLE	SVM+Isomap	SVM+DL	SVM+ICA
Logloss	0.281	0.159	0.123	0.264	0.144	0.295	0.148
MAE	0.114	0.047	0.043	0.075	0.039	0.087	0.043
TP	1447	1606	1613	1577	1656	1545	1629
TN	928	949	953	901	920	901	937
FP	60	39	35	87	68	87	51
FN	245	86	79	115	36	147	63

Tablo 17. Toprak arıza tespiti için DT hatası ve CM modeli sonuçları

	DT	DT+PCA	DT+KPCA	DT+LLE	DT+Isomap	DT+DL	DT+ICA
Logloss	0.258	0.481	0.434	0.529	0.668	0.383	0.786
MAE	0.099	0.029	0.049	0.041	0.050	0.089	0.037
TP	1580	1651	1614	1638	1635	1557	1647
TN	836	951	936	932	912	884	934
FP	152	37	52	56	76	135	54
FN	112	41	78	54	57	104	45

Tablo 18. Toprak arıza tespiti için RF hatası ve CM model sonuçları

	RF	RF+PCA	RF+KPCA	RF+LLE	RF+Isomap	RF+DL	RF+ICA
Logloss	0.238	0.481	0.105	0.173	0.127	0.333	0.126
MAE	0.109	0.029	0.029	0.046	0.041	0.085	0.028
TP	1540	1642	1643	1646	1644	1577	1650
TN	848	959	960	918	926	874	956
FP	140	29	28	70	62	114	32
FN	152	50	49	52	48	115	42

Tablo 19. Toprak arıza tespiti için KNN hatası ve CM model sonuçları


	KNN	KNN+PCA	KNN+KPCA	KNN+LLE	KNN+Isomap	KNN+DL	KNN+ICA
Logloss	0.236	0.248	0.361	0.631	0.452	0.299	0.378
MAE	0.090	0.009	0.010	0.023	0.042	0.093	0.013
TP	1598	1679	1677	1657	1634	1548	1681
TN	842	975	975	961	934	882	964
FP	146	13	13	27	54	106	24
FN	94	13	15	35	58	144	11

5.4.3. Arıza Sınıflandırma Sonuçları


Bu bölüm, sınıfları özelliklerine göre tahmin ederek, test veri setinden hata sınıflandırma sonuçlarını sunar. On tip arıza analiz edildi (arıza simülasyonları veri seti ile ilgili daha fazla ayrıntı için Şekil 19'a bakınız). Model, önceki adımlardan farklı olarak ikiden fazla sınıf arasında ayrım yaptığı için çok sınıflı bir sınıflandırıcı haline gelmiştir. LR ve SVM gibi algoritmalar için, Bire Karşı Geri Kalan (One-vs-the rest - OvR) stratejisi, bu algoritmalar kesinlikle ikili sınıflandırıcılar olduğundan, bir yerleşim özneteliği olarak uygulanmıştır; Birden çok sınıfı yerel olarak yönetebilen DT'ler, RF ve KNN'den farklı olarak. Bu adımın hesaplanması için, üç fazlı gerilim ve akım özellikleri uygulanmış, ön işleme tabi tutulmuş ve ML tarafından önerilen modeller aracılığıyla değerlendirilmiştir. Analizden elde edilen sonuçlar, Şekil 40'ten Şekil 44'e ve Tablo 20'den ila Tablo 25'e kadar gösterilmektedir.

1. LR modellerinde elde edilen en iyi sonuçlar, PCA, %99.81 Doğruluk, %99.81 F1, 0.053 Log-loss, 0.007 MAE uygulanarak elde edilmiştir. En düşük sonuçlar DL, %96.46 Doğruluk, %96.46 F1, 0.148 Log-loss, 0.112 MAE uygulanarak elde edildi.
2. SVM modellerinde elde edilen en iyi sonuçlar ICA, %99.85 Doğruluk, %99.85 F-1, 0.023 Log-loss, 0.006 MAE uygulanarak elde edilmiştir. En düşük sonuçlar LLE, %95.60 Doğruluk, %95.53 F1, 0.090 Log-loss, 0.116 MAE kullanılarak elde edildi.


3. DT modellerinde elde edilen en iyi sonuçlar KPCA, %98.84 Doğruluk, %98.84 F-1, 0.400 Log-loss, 0.053 MAE uygulanarak elde edilmiştir. En düşük sonuçlar DL, %97.65 Doğruluk, %97.65 F1, 0.812 Log-loss, 0.096 MAE kullanılarak elde edildi.
4. RF modellerinde elde edilen en iyi sonuçlar ICA, %99.51 Doğruluk, %99.52 F-1, 0.136 Log-loss, 0.022 MAE uygulanarak elde edilmiştir. En düşük sonuçlar DL, %97.35 Doğruluk, %97.35 F1, 0.265 Log-loss, 0.097 MAE kullanılarak elde edildi.
5. K-NN modellerinde elde edilen en iyi sonuçlar PCA ve KPCA, %99.66 Doğruluk, %99.66 F-1, 0.116 Log-loss, 0.015 MAE uygulanarak elde edilmiştir. En düşük sonuçlara DL, %97.39 Doğruluk, %97.39 F1, 0.290 Log-loss, 0.097 MAE ve %99.86 AUC kullanılarak ulaşıldı.




Şekil 40. Arıza sınıflandırması için LR model sonuçları




Şekil 41. Arıza sınıflandırması için SVM modeli sonuçları



Şekil 42. Arıza sınıflandırması için DT model sonuçları



Şekil 43. Arıza sınıflandırması için RF model sonuçları



Şekil 44. Arıza sınıflandırması için KNN model sonuçları

Tablo 20. Arıza sınıflandırma modeli için LR hata sonuçları

	LR	LR+PCA	LR+KPCA	LR+LLE	LR+Isomap	LR+DL	LR+ICA
Logloss	0.666	0.053	0.125	0.117	0.155	0.148	0.067
MAE	0.293	0.007	0.054	0.094	0.109	0.112	0.015

Tablo 21. Arıza sınıflandırma modeli için SVM hata sonuçları

	SVM	SVM+PCA	SVM+KPCA	SVM+LLE	SVM+Isomap	SVM+DL	SVM+ICA
Logloss	0.115	0.091	0.753	0.090	0.077	0.036	0.023
MAE	0.159	0.094	0.055	0.116	0.081	0.024	0.006

Tablo 22. Arıza sınıflandırma modeli için DT hata sonuçları

	DT	DT+PCA	DT+KPCA	DT+LLE	DT+Isomap	DT+DL	DT+ICA
Logloss	0.211	0.863	0.400	0.451	0.619	0.812	0.554
MAE	0.128	0.100	0.053	0.043	0.066	0.096	0.056

Tablo 23. Arıza sınıflandırma modeli için RF hata sonuçları

	RF	RF+PCA	RF+KPCA	RF+LLE	RF+Isomap	RF+DL	RF+ICA
Logloss	0.203	0.230	0.200	0.104	0.096	0.265	0.136
MAE	0.088	0.116	0.071	0.073	0.023	0.097	0.022

Tablo 24. Arıza sınıflandırma modeli için KNN hata sonuçları

	KNN	KNN+PCA	KNN+KPCA	KNN+LLE	KNN+Isomap	KNN+DL	KNN+ICA
Logloss	0.176	0.116	0.116	0.239	0.153	0.290	0.112
MAE	0.104	0.015	0.015	0.045	0.043	0.097	0.032

Tablo 25. Arıza türüne göre arıza sınıflandırma modeli sonuçları

		ABC	AB	BC	CA	ABG	BCG	CAG	AG	BG	CG
LR	Kesinlik %	100	97	91	68	95	90	90	97	100	90
	Duyarlılık %	89	80	69	71	100	98	79	99	95	100
	F1 – Skoru %	94	88	79	69	97	94	84	98	97	95
LR+PCA	Kesinlik %	100	100	100	99	100	100	100	100	100	99
	Duyarlılık %	99	100	99	100	100	100	100	100	100	100
	F1 – Skoru %	99	100	100	100	100	100	100	100	100	100
LR+KPCA	Kesinlik %	100	96	96	84	100	99	99	99	100	99
	Duyarlılık %	94	98	99	94	99	99	95	100	100	100
	F1 – Skoru %	97	97	98	89	100	99	97	100	100	100
LR+LLE	Kesinlik %	99	95	95	91	96	97	92	100	100	99
	Duyarlılık %	99	93	92	86	97	99	95	100	100	100
	F1 – Skoru %	99	94	93	88	97	98	94	100	100	100

Tablo 25'in devamı

LR+Isomap	Kesinlik %	99	96	92	87	96	98	94	100	100	99
	Duyarlılık %	99	91	94	91	98	97	92	100	99	99
	F1 – Skoru %	99	94	93	89	97	97	93	100	100	99
LR+DL	Kesinlik %	99	92	87	92	97	97	94	100	98	99
	Duyarlılık %	99	95	89	90	95	96	96	100	97	100
	F1 – Skoru %	99	94	88	91	96	96	95	100	97	100
LR+ICA	Kesinlik %	100	100	97	99	100	100	99	100	100	99
	Duyarlılık %	98	100	100	100	100	99	100	100	100	100
	F1 – Skoru %	99	100	99	100	100	100	99	100	100	100
SVM	Kesinlik %	100	100	89	80	96	91	92	98	100	98
	Duyarlılık %	94	91	74	83	100	97	89	100	99	100
	F1 – Skoru %	97	95	81	82	98	94	91	99	100	99
SVM+PCA	Kesinlik %	85	100	100	99	99	100	100	100	100	99
	Duyarlılık %	99	95	97	99	100	97	99	100	93	97
	F1 – Skoru %	91	97	99	99	99	98	99	100	97	98
SVM+KPCA	Kesinlik %	100	100	99	99	92	100	100	100	100	99
	Duyarlılık %	95	96	99	98	100	98	100	100	96	98
	F1 – Skoru %	97	98	99	99	96	99	100	100	98	99
SVM+LLE	Kesinlik %	100	99	96	93	90	98	94	100	82	99
	Duyarlılık %	99	74	93	90	96	99	96	100	99	100
	F1 – Skoru %	99	85	94	92	93	98	95	100	89	100
SVM+Isomap	Kesinlik %	100	95	97	95	95	97	97	100	100	99
	Duyarlılık %	99	89	90	95	98	99	97	100	99	100
	F1 – Skoru %	99	92	93	95	96	98	97	100	99	100
SVM+DL	Kesinlik %	100	99	97	99	100	100	99	100	100	97
	Duyarlılık %	99	100	100	99	99	98	100	100	100	99
	F1 – Skoru %	99	100	99	99	100	99	100	100	100	98
SVM+ICA	Kesinlik %	100	100	100	99	100	100	100	100	100	99
	Duyarlılık %	99	100	100	100	100	100	100	100	100	100
	F1 – Skoru %	99	100	100	100	100	100	100	100	100	100
DT	Kesinlik %	98	95	94	94	98	93	96	100	97	98
	Duyarlılık %	96	95	90	91	98	97	98	97	97	99
	F1 – Skoru %	97	95	92	92	98	95	97	99	97	99
DT+PCA	Kesinlik %	99	97	95	95	97	99	95	99	96	98
	Duyarlılık %	96	96	97	93	99	98	97	99	93	99
	F1 – Skoru %	97	97	96	94	98	99	96	99	94	99

Tablo 25'in devamı

DT+KPCA	Kesinlik %	98	99	98	98	99	99	99	99	100	98
	Duyarlılık %	97	100	100	98	98	99	99	100	98	98
	F1 – Skoru %	97	99	99	98	99	99	99	100	99	98
DT+LLE	Kesinlik %	98	98	92	98	98	100	99	100	100	99
	Duyarlılık %	99	97	99	98	99	97	98	100	100	100
	F1 – Skoru %	99	97	96	98	99	99	99	100	100	100
DT+Isomap	Kesinlik %	98	96	94	96	98	99	97	100	100	99
	Duyarlılık %	97	97	99	97	98	98	98	99	99	98
	F1 – Skoru %	97	97	96	96	98	99	98	100	99	99
DT+DL	Kesinlik %	97	95	98	96	98	99	97	100	99	97
	Duyarlılık %	98	95	99	94	99	96	98	99	97	97
	F1 – Skoru %	98	95	99	95	98	97	98	100	98	97
DT+ICA	Kesinlik %	98	98	97	97	98	99	97	100	98	98
	Duyarlılık %	94	97	100	97	99	99	99	100	99	99
	F1 – Skoru %	96	98	99	97	99	99	98	100	99	99
RF	Kesinlik %	100	100	100	99	93	94	93	100	100	99
	Duyarlılık %	99	85	81	88	100	100	100	100	100	100
	F1 – Skoru %	99	92	89	94	96	97	96	100	100	100
RF+PCA	Kesinlik %	100	99	100	99	100	99	99	100	100	99
	Duyarlılık %	99	99	96	99	100	100	100	100	99	100
	F1 – Skoru %	99	99	98	99	100	99	99	100	100	100
RF+KPCA	Kesinlik %	100	95	96	94	96	98	98	100	100	99
	Duyarlılık %	95	93	96	97	98	99	99	100	99	100
	F1 – Skoru %	97	94	96	96	97	99	98	100	99	99
RF+LLE	Kesinlik %	99	92	96	99	94	100	97	100	100	99
	Duyarlılık %	99	89	100	95	96	99	100	100	100	99
	F1 – Skoru %	99	90	98	97	95	99	98	100	100	99
RF+Isomap	Kesinlik %	99	100	97	99	99	100	99	100	100	99
	Duyarlılık %	99	99	100	98	100	99	100	100	100	99
	F1 – Skoru %	99	99	99	99	99	100	99	100	100	99
RF+DL	Kesinlik %	95	96	94	96	97	97	98	98	100	99
	Duyarlılık %	95	95	99	95	97	97	98	99	96	99
	F1 – Skoru %	95	96	96	96	97	97	98	99	98	99
RF+ICA	Kesinlik %	97	100	100	99	100	100	100	100	100	99
	Duyarlılık %	99	100	100	100	98	100	100	100	100	99
	F1 – Skoru %	98	100	100	100	99	100	100	100	100	99

Tablo 25'in devamı

RF+ICA	Kesinlik %	97	100	100	99	100	100	100	100	100	99
	Duyarlılık %	99	100	100	100	98	100	100	100	100	99
	F1 – Skoru %	98	100	100	100	99	100	100	100	100	99
KNN	Kesinlik %	98	99	100	93	96	93	97	100	100	98
	Duyarlılık %	94	93	81	95	100	99	97	100	96	100
	F1 – Skoru %	96	96	89	94	98	96	97	100	98	99
KNN+PCA	Kesinlik %	99	100	99	99	100	100	100	100	100	99
	Duyarlılık %	99	100	100	100	100	100	100	100	100	99
	F1 – Skoru %	99	100	100	100	100	100	100	100	100	99
KNN+KPCA	Kesinlik %	99	100	99	99	100	100	100	100	100	99
	Duyarlılık %	99	100	100	100	100	100	100	100	100	99
	F1 – Skoru %	99	100	100	100	100	100	100	100	100	99
KNN+LLE	Kesinlik %	98	100	92	99	100	99	99	100	100	99
	Duyarlılık %	99	99	100	99	100	97	99	100	100	98
	F1 – Skoru %	98	99	96	99	100	98	99	100	100	99
KNN+Isomap	Kesinlik %	99	96	97	99	98	100	98	100	100	99
	Duyarlılık %	98	97	99	99	98	99	100	100	99	99
	F1 – Skoru %	98	97	98	99	98	99	99	100	100	99
KNN+DL	Kesinlik %	98	94	95	97	96	99	97	99	98	98
	Duyarlılık %	96	94	96	97	97	97	98	99	96	98
	F1 – Skoru %	97	94	96	97	97	98	98	99	97	98
KNN+ICA	Kesinlik %	99	98	98	99	100	100	99	100	100	98
	Duyarlılık %	98	100	100	99	99	99	100	100	99	99
	F1 – Skoru %	99	99	99	99	99	99	99	100	100	99

6. SONUÇLAR

6.1. Sonuç Bölümü

Bu araştırmanın I. Bölümü'nde, ML modellerinin uygulanmasına ve konuya katkılarına dayanarak yapılan önceki çalışmalar incelenmiştir. Bölüm II'de, elektrik şebekesi sistemlerinin ve bileşenlerinin bir özetini sunulmuştur. Ayrıca, elektrik şebeke sistemlerindeki arızaların önemine ilişkin büyük bir tablo ortaya konulmuştur. Bunlara ek olarak, bu hataların ülkelerin ekonomilerini ve insan yaşamını nasıl etkileyebileceği tartışılmıştır. Bölüm III'te bu araştırmanın ana konusu olan Makine Öğrenimi sunulmuştur; ilk resim ve modeller hakkında önemli teoriler tartışılmıştır. Eğitmenli öğrenme ve modellerin kullanılışı hakkında kısa bir giriş yapılmıştır. Ayrıca, bu bölümde, etiketlenmemiş veri kümelerindeki kalıpları keşfetmek ve bir ön işleme adımıyla özelliği sıkılaştırmak için bu tekniklerin uygulanabileceğine dair bir kavramsallaştırma sunan eğitmensiz öğrenmenin bir incelemesi sunulmuştur. Son olarak, Python ortamı ve veri analizi için bazı kütüphaneleri sunulmuştur.

Bölüm IV'te bu araştırma ile uygulanan metodolojiyi sunulmuştur. İlk olarak, çalışma durumu ve simülasyonların ayrıntıları (yazılım, bilgisayar ayrıntıları ve simülasyon veri yapılandırılmaları gibi) sunulmuştur. Daha sonra, Wavelet dönüşümü ve ayrışma düzeyleri gibi sinyal ön işleme yöntemleri incelenmiştir. Ek olarak, doğrusal ve doğrusal olmayan sorunlarla başa çıkmak için kullanılan beş ML algoritması incelenmiştir. Sunulan ilk model, tekil bir vaka olasılığını tahmin etmeyi sağlayan Lojistik Regresyon algoritmasıdır. İkinci olarak, Destek Vektör Makinesi algoritması incelenmiştir. Bu güçlü doğrusal model, "Kernel Trick" aracılığıyla doğrusal olmayan durumlara genişletilebilir. İncelenen üçüncü model, verilerin yapısı üzerinden nasıl yorumlandığının özelliği ile karakterize edilen Karar Ağaçları algoritmasıdır. Ardından, bir topluluk modeli sunulmuştur; Rassal Orman algoritması, yapılandırma parametreleriyle iddialı olduğunu ve DT'ler gibi bilgileri aşırı öğrenmediğini belirtmiştir. Son olarak, K-Nearest Neighbors algoritması sunulmuştur. Bu model, hesaplama karmaşıklığının bir dezavantajı ile herhangi bir model eğitimi olmadan tahmine izin veren tembel bir öğrenme yöntemi uygulanarak karakterize edilmiştir. Ayrıca, birincil model aracılığıyla uygulanan, işlem hatları modelleri gibi, eğitim işlemi sırasında veri kümelerinin çeşitli işlemlerine veya dönüşümlerine izin verme ve ML algoritmalarını daha verimli bir şekilde değerlendirme gibi bazı teknikler getirilmiştir. Grid Search

algoritması ve K-katlamalı çapraz doğrulama, hiper parametre seçimi ve veri kümelerinin aşırı ve öğrenme ve eksik öğrenme gibi problemlerle başa çıkmak için scikit-learn kitaplığı tarafından işlem hatları modeli aracılığıyla kullanılmıştır. Bununla birlikte, eğitim veri kümesindeki kullanılabilir veriler, uygun bir öğrenme algoritması seçmekten daha önemlidir. Hiçbir algoritma, ilgili ve ayırt edilebilen kalıplar olmadan yararlı tahminlerde bulunamazmıştır. Bu nedenle, dalgacık dönüşümü seçimi kullanılarak boyutsallık azaltma ve veri ön işleme için faydalı bir yöntem sunulmuştur. Boyutsallık azaltma yöntemi, daha yüksek boyutlu bir uzaydan daha düşük boyutlu bir özellikler alt uzayına projeksiyonlar yapmak veya sıkıştırmak için etiketler olmadan temel alınan verilerin düzenlemesini öğrenir. Bu araştırma, PCA ve doğrusal olmayan varyasyonu KPCA gibi doğrusal yöntemlerle başlayarak altı boyutlu azaltma tekniklerini gözden geçirmiştir. Daha sonra, doğrusal olmayan modeller Jeodezik veya Öklid mesafelerine göre sunulmuştur; bu yöntemler Isomap, LLE gibi manifold öğrenme olarak bilinir. Ayrıca, DL ve ICA gibi mesafe tabanlı olmayan modeller gözden incelenmiştir. Bu bölüm, ML algoritmaları performans sonuçlarını ölçmek için uygulanan performans metriklerinin sunulmasıyla sonlandırılmıştır. Bölüm V, önerilen modellerin sonuçlarını sunmuştur.

6.2. Başlıca Sonuç

Bu araştırma, en uygun dalgacık ailesini ve veri ön işleme için en iyi ayrıştırma düzeyini seçerek ve eğitmenli makine öğrenimi algoritmalarının performanslarını iyileştirmek için eğitmenli makine öğrenimi algoritmalarının performanslarını iyileştirmek için eğitmensiz boyutsallık azaltma tekniklerini bir özellik çıkarma modeli olarak uygulayarak bir hata tanımlama ve sınıflandırma sistemi önermektedir. Önceki literatürle karşılaştırıldığında ve hata tanımlama ve sınıflandırma için ML modelinin uygulanmasına özel bir ilgi vardır. Sistem, birincil giriş olarak oluşturulan DIgSILENT PowerFactory 2019 yazılım verilerini kullanır. Burada üç fazlı gerilim ve akım özellikleri toplandı. Daha sonra sıfır sıralı bileşenler hesaplandı. Mevcut çalışmalarla karşılaştırıldığında, tez aşağıdaki hususlara katkıda bulunmayı amaçlamaktadır:

1. Denetimli ML algoritmalarını kullanarak hataları tahmin etmek ve sınıflandırmak için geçmiş elektrik verilerini kalıplara dönüştürün.

2. Sinyal işleme için dalgacık dönüşümlerini ve ayrışma seviyelerini seçmek için yorumlayıcı, otonom ve uygulanabilir bir model geliştirin.
3. Veri analizi için kullanılan algoritmaların performansını etkileyebilecek boyutsallık lanetini çözerek eğitimsiz boyutsallık azaltma teknikleri uygulayın.

Teorik açıdan:

1. Wavelet ön işleme: Sinyal ayrışması için DWT uygulanarak, maksimum ayrışma seviyesini hesaplamak için minimum entropi ayrışmasının uygulandığı bir dalgacık ailesi seçim modeli geliştirilmiştir. Daha sonra, uygun dalgacık ailesini ve bir değerler kümesinden en iyi ayrışma düzeyini seçmek için SVM kullanılmıştır. Sonuçlar, uygun dalgacık ailesinin ve ayrışma düzeyinin seçilmesinin özellik vektörlerinin boyutunu güçlü bir şekilde etkileyebileceğini doğrular; böylece analizden farklı sonuçlar elde edilebilir.
2. Eğitim süreci: Makine öğrenimi eğitim modelleri sırasında orijinal özellik setinde en dikkat çekici özellikleri bulmak için eğitimsiz boyutsallık azaltma teknikleri uygulanmıştır. Uygulamalar, önceden bilgi sahibi olmadan veri kümesindeki ayırt edici kalıpları tanımlayarak makine öğrenimi algoritmalarının karmaşıklığını azaltmayı amaçlamıştır.
3. Sonuçlar, özellik ayıklama tekniklerinin ve dalgacık seçim modelinin uygulanmasının, daha az ilgili özellikleri dikkate alarak ve makine öğrenimi modellerinin veri kümelerini aşırı veya eksik öğrenmesini önleyerek algoritmaların hata tanımlama ve sınıflandırma sırasında performansını etkili bir şekilde artırabileceğini doğrular.

7. ÖNERİLER

Bu araştırmada, arıza tanımlama ve sınıflandırma için uyarlanabilir, etkili ve esnek bir modele sahip makine öğrenme algoritmaları ele alınmıştır. Bu konudan, aşağıda verildiği gibi takip edilebilecek birçok araştırma konusu vardır:

1. Hiper parametre ayarlama için Grid Search algoritmasının güçlü performansına rağmen, bu modelin bir dezavantajı, birkaç parametrenin çözülmesi gereken hesaplama süresidir. Bu nedenle, bu, nesnel işlev için olasılıksal bir modele dayanan Halving Grid Search veya Bayesian algoritması gibi başka bir arama algoritmasını denemek için bir kılavuz olarak kullanılabilir; örneğin hiper parametrelerin ayarlanması için.
2. Otomatik kodlayıcılar gibi eğitmensiz boyutsallık azaltma teknikleri, ağ üzerindeki hata yerini belirlemek için genişletilebilir. Ayrıca, Python uygulamaları ve SCADA sistemleri aracılığıyla elektrik ağı gerçek zamanlı verilerini kullanarak gerçek zamanlı izleme için birleşik bir yöntem kullanılabilir. Hata meydana geldiğinde, hata türünü ve mesafesini ağ üzerinden hemen iletmek için sistemden bir uyarı ayarlanabilir.
3. Önerilen yaklaşımın etkinliği simüle edilmiş veriler içinde ve algılama ve sınıflandırma çerçevesinde birkaç eğitmensiz boyutsallık azaltma tekniği ve denetimli öğrenme modelleri kullanarak doğrulanmıştır. Gelecekteki çalışmalar, gerçek zamanlı simülasyon verilerini uygulayarak sunulan yöntemin doğrulanmasını inceleyecektir.
4. SCADA verilerinin arıza tespitinde olası uygulamaları gerçekleştirilebilir. Ne yazık ki, akademik araştırma yapmak için performans verileri sağlayacak açık kaynaklar yoktur. Ayrıca, sınırlı kullanılabilir veri kümeleri için etiket verileri daha sıradışı ve erişimle ilgilidir, bu da yüksek verimlilik elde etmek için denetimli öğrenme yapmayı zorlaştırır. Sonuç olarak, veri kümelerine sınırlı erişimle yeterli algılama sonuçları elde etmek, iş amaçlı senaryolar için önemli bir konu olmuştur. Bu nedenle, transfer öğrenimi, bazı öncü araştırmaların araştırdığı yukarıdaki sorunu cevaplayabilir.

8. KAYNAKLAR

1. Karagiannis, G. M., Chondrogiannis, S., Zehra, E. K. ve Turksezer, I., Power Grid Recovery after Natural Hazard Impact, Joint Research Center: European Union, 2017. <https://publications.jrc.ec.europa.eu/repository/handle/JRC108842>, 10 Ocak 2020.
2. Sridhar, S., Hahn, A. ve Govindarasu, M., Cyber-Physical System Security for the Electric Power Grid, in Proceedings of the IEEE, 100, 1 (2012) 210-224.
3. Mo, Y., vd., Cyber-Physical Security of a Smart Grid Infrastructure, in Proceedings of the IEEE, 100, 1 (2012) 195-209.
4. Feng, Z. ve Hu, G., Distributed fault identification and fault-tolerant control for multi-agent systems, Proceedings of the 33rd Chinese Control Conference, July 2014, Nanjing, China, 1476-1481.
5. McParland, C., Peisert, S. ve Scaglione, A., Monitoring Security of Networked Control Systems: It's the Physics, in IEEE Security & Privacy, 2, 6 (2014) 32-39.
6. Harley, R. G. ve Liang, J., Computational Intelligence in Smart Grids, IEEE Symp. Ser. Comput. Intell., 1 (2011) 1-8.
7. Rudin C., vd., Machine Learning for the New York City Power Grid, in IEEE Transactions on Pattern Analysis and Machine Intelligence, 34, 2 (2012) 328-345.
8. Paoli, A. Fault Detection ve Fault Tolerant Control for Distributed Systems: a general framework, Doctoral dissertation, University of Bologna, Bologna, Italy, 2004.
9. Chen, K., Huang, C. ve He, J., Fault detection, classification and location for transmission lines and distribution systems: a review on the methods, in High Voltage, 1, 1 (2016) 25-33.
10. Ai-min, L., Xin, L. ve Xiang-dong, L., Fault Diagnosis Method of High Voltage Circuit Breaker based on (RBF) Artificial Neural Network, 2005 IEEE/PES Transmission & Distribution Conference & Exposition: Asia and Pacific, 2005, Dalian, China, 1-4.
11. Swarup, K. S. ve Chandrasekharaiah, H. S., Fault detection and diagnosis of power systems using artificial neural networks, Proceedings of the First International Forum on Applications of Neural Networks to Power Systems, 1991 July, Seattle, WA, USA, 102-106.
12. Valtierra-Rodriguez, M., Romero-Troncoso, R. de Jesus, Osornio-Rios, R. A. ve Garcia-Perez, A., Detection and Classification of Single and Combined Power Quality Disturbances Using Neural Networks, in IEEE Transactions on Industrial Electronics, 61, 5 (2014) 2473-2482.
13. Hood, C. S., ve Ji, C., Proactive network-fault detection [telecommunications], in IEEE Transactions on Reliability, 46, 3 (1997) 333-341.

14. Hood, C. S., ve Ji, C., Proactive network-fault detection [telecommunications], in IEEE Transactions on Reliability, 46, 3 (1997) 333-341.
15. Tokel, H. A., Alirezai, G., ve Mathar, R., Integrated network design for measurement and communication infrastructures in smart grids, 2016 26th International Telecommunication Networks and Applications Conference (ITNAC), December 2016, Dunedin, New Zealand, 258-264.
16. Thukaram, D., Khincha, H. P. ve Vijaynarasimha, H. P., Artificial Neural Network and Support Vector Machine Approach for Locating Faults in Radial Distribution Systems, IEEE. Trans. Power Del., 20, 2 (2005) 710-721.
17. Wang, Z. ve Balog, R. S., Arc fault and flash detection in DC photovoltaic arrays using wavelets, 2013 IEEE 39th Photovoltaic Specialists Conference (PVSC), June 2013, Tampa, FL, USA, 1619-1624.
18. Chen, L., Li, S. ve Wang, X., Quickest Fault Detection in Photovoltaic Systems, in IEEE Transactions on Smart Grid, 9, 3 (2018) 1835-1847.
19. Guo-fang, Z. ve Yu-ping, L., A fault location algorithm for urban distribution network with DG, 2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, April 2008, Nanjing, China, 2615-2619.
20. Al Karim, M., Currie, J. ve Lie, T., Dynamic Event Detection Using a Distributed Feature Selection Based Machine Learning Approach in a Self-Healing Microgrid, in IEEE Transactions on Power Systems, 33, 5 (2018) 4706-4718.
21. Georgilakis, P. S. ve Hatziargyriou, N. D., Optimal Distributed Generation Placement in Power Distribution Networks: Models, Methods, and Future Research, in IEEE Transactions on Power Systems, 28, 3 (2013) 3420-3428.
22. Rezaei, N., Javadian, S. A. M., Khalesi, N. ve Haghifam, M. -, Diagnosis of impedance fault in distribution system with distributed generations using radial basis function neural network, 2011 IEEE International Conference on Smart Measurements of Future Grids (SMFG) Proceedings, November 2011, Bologna, Italy, 79-83.
23. Altaf, S., Al-Anbuky, A. ve GholamHosseini, H., Fault diagnosis in a distributed motor network using Artificial Neural Network, 2014 International Symposium on Power Electronics, Electrical Drives, Automation and Motion, June 2014, Ischia, Italy, 190-197.
24. Chen, P., Yang, S. ve McCann, J. A., Distributed Real-Time Anomaly Detection in Networked Industrial Sensing Systems, in IEEE Transactions on Industrial Electronics, 62, 6 (2015) 3832-3842.
25. Chen, P., Malbasa, V., Dong, Y. ve Kezunovic, M., Sensitivity Analysis of Voltage Sag Based Fault Location with Distributed Generation, in IEEE Transactions on Smart Grid, 6, 4 (2015) 2098-2106.

26. Margossian, H., Deconinck, G. ve Sachau, J., Distribution network protection considering grid code requirements for distributed generation, in IET Generation, Transmission & Distribution, 9, 12 (2015) 1377-1381.
27. Stergiopoulos, K., Pipe, A. G., ve Nouri, H., Intelligent control architectures for fault diagnosis in electrical power distribution networks, Proceedings of the 2003 IEEE International Symposium on Intelligent Control, October 2003, Houston, TX, USA, 569-573.
28. El-Khattam, W., Hegazy, Y., G. and Salama M., M., A., An integrated distributed generation optimization model for distribution system planning, in IEEE Transactions on Power Systems, 20, 2 (2005), 1158-1165.
29. Liang, G., Liyuan, P., Ruihuan, L., Fen, Z. ve Xin, W., Fault location in distribution network with distributed generation based on neural network, 2014 China International Conference on Electricity Distribution (CICED), September 2014, Shenzhen, China, 209-212.
30. Chen, Y., Tan, Y. ve Deka, D., Is Machine Learning in Power Systems Vulnerable?, 2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm), October 2018, Aalborg, Denmark, 1-6.
31. Voumvoulakis, E. M., Gavoyiannis, A. E. ve Hatziargyriou, N. D., Application of Machine Learning on Power System Dynamic Security Assessment, 2007 International Conference on Intelligent Systems Applications to Power Systems, November 2007, Kaohsiung, Taiwan, 1-6.
32. Aleem, S., Shahid, N., ve Naqvi, I., Methodologies in power systems fault detection and diagnosis, Energy Systems, 6, 1 (2014) 85-108.
33. Andresen, C. A., Torsæter, B. N., Haugdal, H. ve Uhlen, K., Fault Detection and Prediction in Smart Grids, 2018 IEEE 9th International Workshop on Applied Measurements for Power Systems (AMPS), September 2018, Bologna, Italy, 1-6.
34. Wehenkel, L., Machine learning approaches to power-system security assessment, in IEEE Expert, 12, 5 (1997) 60-72.
35. Borges Hink, R. C., vd., Machine learning for power system disturbance and cyber-attack discrimination, 2014 7th International Symposium on Resilient Control Systems (ISRCS), August 2014, Denver, CO, USA, 1-8.
36. Chen, Y. Q., Fink, O. ve Sansavini, G., Combined Fault Location and Classification for Power Transmission Lines Fault Diagnosis with Integrated Feature Extraction, in IEEE Transactions on Industrial Electronics, 65, 1 (2018) 561-569.

37. Tomin, N., Kurbatsky, V., Sidorov D. ve Zhukov, A., Machine Learning Techniques for Power System Security Assessment, This work was supported by the Russian Scientific Foundation under Grant No. 14-19-00054 and the 2015 Endeavour Scholarship and Fellowship program., IFAC-PapersOnLine, 49, 27 (2016) 445-450.
38. Chen, X., Dong, Z. Y., Meng, K., Xu, Y., Wong, K. P. ve Ngan, H. W., Electricity Price Forecasting with Extreme Learning Machine and Bootstrapping, in IEEE Transactions on Power Systems, 27, 4 (2012) 2055-2062.
39. Zheng, J. ve Dagnino, A., An initial study of predictive machine learning analytics on large volumes of historical data for power system applications, 2014 IEEE International Conference on Big Data (Big Data), October 2014, Washington, DC, USA, 952-959.
40. Tayeb, E. B. M. ve Rhim, O. A. A. A., Transmission line faults detection, classification and location using artificial neural network, 2011 International Conference & Utility Exhibition on Power and Energy Systems: Issues and Prospects for Asia (ICUE), September 2011, Pattaya, Thailand, 1-5.
41. Masa, A. V., Werben, S. ve Maun, J.C., Incorporation of data-mining in protection technology for high impedance fault detection, 2012 IEEE Power and Energy Society General Meeting, July 2012, San Diego, CA, USA, 1-8.
42. Telford, R. D., Galloway, S., Stephen, B. ve Elders, I., Diagnosis of Series DC Arc Faults—A Machine Learning Approach, in IEEE Transactions on Industrial Informatics, 13, 4 (2017) 1598-1609.
43. Tokel, H. A., Halaseh, R. A., Alirezaei, G. ve Mathar, R., A new approach for machine learning-based fault detection and classification in power systems, 2018 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT), February 2018, Washington, DC, USA, 1-5.
44. Mesbah Maruf, H. M., Müller, F., Hassan, M. S. ve Chowdhury, B., Locating Faults in Distribution Systems in the Presence of Distributed Generation using Machine Learning Techniques, 2018 9th IEEE International Symposium on Power Electronics for Distributed Generation Systems (PEDG), June 2018, Charlotte, NC, USA, 1-6.
45. Guo, M., Zeng, X., Chen, D. ve Yang, N., Deep-Learning-Based Earth Fault Detection Using Continuous Wavelet Transform and Convolutional Neural Network in Resonant Grounding Distribution Systems, in IEEE Sensors Journal, 18, 3 (2018) 1291-1300.
46. Samantaray, S., Mishra, D., ve Joos, G., A Combined Wavelet and Data-Mining Based Intelligent Protection Scheme for Microgrid, 2018 IEEE Power & Energy Society General Meeting (PESGM), August 2018, Portland, OR, USA, 1-1.
47. Toma R, N., J-M. K., Bearing Fault Classification of Induction Motors Using Discrete Wavelet Transform and Ensemble Machine Learning Algorithms. Applied Sciences. 2020; 10 (2015) 5251.

48. Gao, J., vd., Fault line detection based on cross correlation coefficient for distribution network with DG, 2016 China International Conference on Electricity Distribution (CICED), August 2016, Xi'an, China, 1-5.
49. H., Okumuş ve F., M., Nuroğlu, Power System Event Classification Based on Machine Learning, 3rd International Conference on Computer Science and Engineering (UBMK), September 2018, Sarajevo, Bosnia And Herzegovina, 402-405.
50. Mair, A. J., vd., Machine learning techniques for diagnosing and locating faults through the automated monitoring of power electronic components in shipboard power systems, 2009 IEEE Electric Ship Technologies Symposium, April 2009, Baltimore, MD, USA, 469-476.
51. Murthy, P. S. R., Power System Analysis, Second Edition, Butterworth-Heinemann, Oxford, 2017.
52. Saadat, H., Power System Analysis, Second Edition, McGraw-Hill Book Co, New York, 2004.
53. Strauss, C., Practical electrical network automation and communication systems, First Edition, Newnes, Oxford, 2003.
54. <https://setis.ec.europa.eu/related-jrc-activities/jrc-setis-reports/smart-electricity-grids>, 01 Mart 2020.
55. Siemens, Planning of Electric Power Distribution - Technical Principles. <https://electrical-engineering-portal.com/download-center/books-and-guides/electrical-engineering/planning-power-distribution>, 10 Mart 2020.
56. <https://www.electrical-easy.com/2018/02/radial-parallel-ring-main-interconnected-distribution.html>, 18 Mayıs 2020.
57. <https://electrical-engineering-portal.com/4-main-types-distribution-feeder-systems>, 18 Mayıs 2020.
58. Zhang, W., Fault Detection, 71, IntechOpen, 2010.
59. SACE A., Electrical installation handbook: Protection, control and electrical devices, ABB SACE, 2008.
60. <https://circuitglobe.com/single-line-to-ground-fault.html>, 30 Mayıs 2020.
61. <https://voltage-disturbance.com/power-engineering/double-line-to-ground-fault-waveform/>, 30 Mayıs 2020.
62. <https://youtu.be/I7NrVwm3apg>, 30 Mayıs 2020.
63. Chollet, F., Deep Learning with Python, First Edition, Simon and Schuster, New York, 2017.

64. Raschka, S. ve Mirjalili, V., Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow, Second Edition, Packt Publishing Ltd. Birmingham, 2017.
65. Patel, A. A., Hands-On Unsupervised Learning Using Python: How to Build Applied Machine Learning Solutions from Unlabeled Data, O'Reilly Media, CA, 2019.
66. <https://www.python.org/>, 7 Ocak 2020.
67. <https://numpy.org>, 10 Mayıs 2021.
68. <https://en.wikipedia.org/wiki/SciPy>, 10 Mayıs 2021.
69. <https://scipy.org/index.html>, 10 Mayıs 2021.
70. <https://pandas.pydata.org>, 10 Mayıs 2021.
71. <https://scikit-learn.org/stable/>, 10 Mayıs 2021.
72. <https://matplotlib.org>, 10 Mayıs 2021.
73. Venkatesh V., Fault Classification and Location Identification on Electrical Transmission Network Based on Machine Learning Methods, Masters Thesis, Virginia Commonwealth University, Richmond, Virginia, USA, 2018.
74. Abdelgayed, T. S., Morsi, W. G., ve Sidhu, T. S., Fault Detection and Classification Based on Co-training of Semisupervised Machine Learning, in IEEE Transactions on Industrial Electronics, 65, 2 (2018) 1595-1605.
75. IEEE Distribution System Analysis Subcommittee, IEEE 34 Node Test Feeder, <https://site.ieee.org/pes-testfeeders/resources/>, 10 Ocak 2020.
76. Dugan, R. C., ve Kersting, W. H., Induction machine test case for the 34-bus test feeder -description, 2006 IEEE Power Engineering Society General Meeting, June 2006, Montreal, QC, Canada, 4.
77. Davoudi, M., Cecchi, V. ve Agüero, J. R., Effects of stiffness factor on bus voltage variations in the presence of intermittent distributed generation, 2015 North American Power Symposium (NAPS), October 2015, Charlotte, NC, USA, 1-6.
78. Hwan Kim, C. ve Aggarwal, R., Wavelet transforms in power systems. II. Examples of application to actual power system transients, in Power Engineering Journal, 15, 4 (2001) 193-202.
79. Hwan Kim, C., ve Aggarwal, R., Wavelet transforms in power systems. I. General introduction to the wavelet transforms, in Power Engineering Journal, 14, 2 (2000) 81-87.

80. Kumar Verma, Dr. A., Introduction to Wavelet Theory and its Applications. https://youtu.be/F_QvT_8kOfc, 12 Mayıs 2021.
81. Kumar Verma, Dr. A., How to Choose a Right Wavelet and Wavelet Transform? (Understanding Wavelet Properties), https://youtu.be/_b3c21iFlkA, 12 Mayıs 2021.
82. https://www.mathworks.com/help/wavelet/ug/waveletpackets.html?searchHighlight=shannon%20entropy&s_tid=srchtitle, 13 Mayıs 2021.
83. <https://www.mathworks.com/help/predmaint/ug/signal-features.html#:~:text=Crest%20Factor%20%20Peak%20value%20divided,faults%20when%20they%20first%20develop>, 14 Mayıs 2021.
84. S hahid, N., Aleem, S. A., Naqvi, I. H. ve Zaffar, N., Support Vector Machine based fault detection & classification in smart grids, 2012 IEEE Globecom Workshops, December 2012, Anaheim, CA, USA, 1526-1531.
85. Ray, P., Panigrahi, B.K. ve Senroy, N., Hybrid methodology for fault distance estimation in series compensated transmission line. IET Generation, Transmission & Distribution, 7, 5 (2013) 431-439.
86. Géron, A., Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, Second Edition, O'Reilly Media, Inc., CA, 2019.
87. Seif, G., Principal Component Analysis: Your Tutorial Code. <https://towardsdatascience.com/principal-component-analysis-your-tutorial-and-code-9719d3d3f376>, 15 Mayıs 2021.
88. Li, L., Principal Component Analysis for Dimensionality Reduction. <https://towardsdatascience.com/principal-component-analysis-for-dimensionality-reduction-115a3d157bad>, 15 Mayıs 2021.
89. Duk Seo, J., Kernel PCA vs PCA vs ICA in Tensorflow/sklearn. <https://towardsdatascience.com/kernel-pca-vs-pca-vs-ica-in-tensorflow-sklearn-60e17eb15a64>, 16 Mayıs 2021.
90. Palaniappan, V., Manifold Learning: The Theory behind it. <https://towardsdatascience.com/manifold-learning-the-theory-behind-it-c34299748fec>, 17 Mayıs 2021.
91. Ye, A., Manifold Learning [t-SNE, LLE, Isomap, +] Made Easy. <https://towardsdatascience.com/manifold-learning-t-sne-lle-isomap-made-easy-42cfd61f5183>, 17 Mayıs 2021.
92. Yin, K., Step-by-step Signal Processing with Machine Learning: Manifold Learning. <https://towardsdatascience.com/step-by-step-signal-processing-with-machine-learning-manifold-learning-8e1bb192461c>, 17 Mayıs 2021.
93. <https://scikit-learn.org/stable/modules/manifold.html#manifold>, 17 Mayıs 2021.

94. Wang, X., Zheng, Y., Zhao, Z. ve Wang, J., Bearing Fault Diagnosis Based on Statistical Locally Linear Embedding, Sensors (Basel), (2015) 16225-47.
95. Yang, Huan ve Haiming, L., Implementation of Manifold Learning Algorithm Isometric Mapping. Journal of Computer and Communications, 7, (2019) 11-19.
96. Sharma, V., Decomposing Non-linearity with ISOMAP. <https://towardsdatascience.com/decomposing-non-linearity-with-isomap-32cf1e95a483>, 17 Mayıs 2021.
97. Mairal, J., Bach, F., Ponce, J. ve Sapiro, G., Online dictionary learning for sparse coding, In Proceedings of the 26th Annual International Conference on Machine Learning (ICML'09). Association for Computing Machinery, June 2009, Montreal, Quebec, Canada, 689-696.
98. Skretting, K., Dictionary Learning Tools for Matlab, University of Stavanger. <https://www.uis.no/~karlsk/dle/>, 18 Mayıs 2021.
99. Tharwat, A., Independent component analysis: An introduction, Applied Computing and Informatics, 17, 2 (2021) 222-249.
100. Hyvärinen, A., ve Oja, E., Independent component analysis: algorithms and applications, Neural Networks, 13, 4-5 (2000) 411-30.
101. Maklin, C., Independent Component Analysis (ICA) In Python. <https://towardsdatascience.com/independent-component-analysis-ica-in-python-a0ef0db0955e>, 19 Mayıs 2021.
102. Talebi, S., Independent Component Analysis (ICA). <https://towardsdatascience.com/independent-component-analysis-ica-a3eba0ccec35>, 19 Mayıs 2021.
103. Klein, C., Separating mixed signal with Independent Component Analysis. <https://towardsdatascience.com/separating-mixed-signals-with-independent-component-analysis-38205188f2f4>, 19 Mayıs 2021.
104. Kwak, N., Choi, ve CH., Choi, J. Y., Feature Extraction Using ICA, In International Conference on Artificial Neural Networks, August 2001, Heidelberg, Berlin, 568-573.
105. Hu, M., Wang, S., Wang, A. ve Wang, L., Feature Extraction Based on the Independent Component Analysis for Text Classification, 2008 Fifth International Conference on Fuzzy Systems and Knowledge Discovery, October 2008, Jinan, China, 296-300.
106. Pant, A., Introduction to Logistic Regression. <https://towardsdatascience.com/introduction-to-logistic-regression-66248243c148>, 22 Mayıs 2021.
107. Gandhi, R., Support Vector Machine - Introduction to Machine Learning Algorithms. <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>, 22 Mayıs 2021.

108. Patel, S., Chapter 2: SVM (Support Vector Machine)-Theory. <https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72>, 22 May 2021.
109. Radečić, D., Master Machine Learning: Decision Trees from Scratch With Python. <https://towardsdatascience.com/master-machine-learning-decision-trees-from-scratch-with-python-de75b0494bcd>, 23 May 2021.
110. Parmar, H., Bhandari, S. ve Shah, G., Sentiment Mining of Movie Reviews using Random Forest with Tuned Hyperparameters, International Conference on Information Science, July 2014, Kerala, India, 271-276.
111. Yıldırım, S., Decision Trees and Random Forests – Explained. <https://towardsdatascience.com/decision-tree-and-random-forest-explained-8d20ddabc9dd>, 23 May 2021.
112. Yiu, T., Understanding Random Forest. <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>, 24 May 2021.
113. Subramanian, D., A Simple Introduction to K-Nearest Neighbors Algorithm. <https://towardsdatascience.com/a-simple-introduction-to-k-nearest-neighbors-algorithm-b3519ed98e>, 24 May 2021.
114. Soni, D., Introduction to K-Nearest-Neighbors. <https://towardsdatascience.com/introduction-to-k-nearest-neighbors-3b534bb11d26>, 24 May 2021.
115. Koehrsen, W., Hyperparameter Tuning the Random Forest in Python. <https://towardsdatascience.com/hyperparameter-tuning-the-random-forest-in-python-using-scikit-learn-28d2aa77dd74>, 24 May 2021.
116. Koehrsen, W., A Complete Machine Learning Walk-Through in Python: Part Two. <https://towardsdatascience.com/a-complete-machine-learning-project-walk-through-in-python-part-two-300f1f8147e2>, 24 May 2021.
117. Tracyrenee, How to read and interpret sklearn's confusion_matrix() and plot_confusion_matrix() functions. <https://python.plainenglish.io/how-to-read-and-interpret-sklearns-confusion-matrix-nd-plot-confusion-matrix-functions-27b0ab7f00c1>, 24 May 2021.
118. Mujovic, S., Vujosevic, S. ve Vujosevic L., Zero-Sequence Voltage-based Method for Determination and Classification of Unloaded Overhead Line Operating Conditions at the Moment of Energization, Electric Power Components and Systems, 46, 2 (2018) 162-176.
119. Brownlee, J., How to Calculate Feature Importance with Python. <https://machinelearningmastery.com/calculate-feature-importance-with-python/>, 28 May 2021

ÖZGEÇMİŞ

Honduras'ın Universidad Nacional Autónoma de Honduras elektrik-elektronik mühendisliği bölümünden Elektrik Mühendisliği alanında lisans derecesi aldı. Honduras'ta iki yılı aşkın bir süredir özel sektörde Elektrik Mühendisi olarak Proje Yönetimi ve Güç Dağıtım Ağlarında profesyonel iş deneyimi kazandı. Ayrıca, çeşitli liderlik rollerinde bulundu. Halen Karadeniz Teknik Üniversitesi (KTÜ), Trabzon Elektrik-Elektronik Bölümünde Elektrik Mühendisliği M.Sc. derecesinde okumaktadır. Ayrıca, RWTH Aachen Üniversitesi, Institute for Automation of Complex Power Systems'nde Araştırma Görevlisi olarak çalıştı. Yenilenebilir enerji ile güç sistemlerinin ve yapay zeka, IoT ve Makine Öğreniminin akıllı kontrolü üzerinde çalışmaktadır. Araştırma alanları arasında güç sistemleri, mikro şebeke ve akıllı, IoT, Makine Öğrenimi, siber-fiziksel sistemler güvenliği ve güç elektroniği bulunmaktadır. Boş zamanlarında Kültür ve Beşeri Bilimler programlarına katılmayı ve okumayı sever. 2019 yazında Litvanya'nın Klaipeda ders dışı çalışma olarak, Litvanya'nın Klaipeda kentinde, LCC International University'de Litvanya Dili ve Kültürü programına katıldı. Ayrıca, Mısır'ın Şarm El-Şeyh kentinde düzenlenen Dünya Gençlik Forumu 2019'da da bulundu. Hobileri fotoğrafçılık, yürüyüş, yemek pişirme, bilgisayar oyunları, diller ve arkadaşlarıyla vakit geçirmektir.

YAYINLARI

1. Urrea Cabus, J. E. ve Altaş İ. H, Machine Learning Application for Fault Detection in Power Distributed Network, 4th International Conference on Data Science and Applications (ICONDATA'21), June 2021, İstanbul-Bursa (Kabul edildi)