

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

MAKİNE ÖĞRENİMİ ALGORİTMALARI KULLANILARAK KAÇAK
ELEKTRİK TAKİBİ VE KONTROL SİSTEMİNİN GERÇEKLEŞTİRİLMESİ

DOKTORA TEZİ

Önder CİVELEK

EYLÜL 2024

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**MAKİNE ÖĞRENİMİ ALGORİTMALARI KULLANILARAK KAÇAK
ELEKTRİK TAKİBİ VE KONTROL SİSTEMİNİN GERÇEKLEŞTİRİLMESİ**

Önder CİVELEK

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (ELEKTRİK MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 04 / 09 / 2024

Tezin Savunma Tarihi : 30 / 09 / 2024

Tez Danışmanı : Prof. Dr. Halil İbrahim OKUMUŞ

Trabzon 2024

ÖNSÖZ

“Makine Öğrenimi Algoritmaları Kullanılarak Kaçak Elektrik Takibi ve Kontrol Sisteminin Gerçekleştirilmesi” başlıklı bu tez, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Programı’nda hazırlanmıştır. Tez, Nesnelerin İnterneti tabanlı veri toplama sistemlerini gerçek zamanlı makine öğrenimi algoritmalarıyla entegre ederek alçak gerilim şebekelerine kaçak olarak bağlanan yüklerin tespit edilmesi, sınıflandırılması ve yerinin belirlenmesine yönelik yenilikçi bir yaklaşım sunmaktadır. Tez çalışmam süresince her an yanımda olan ve bilim insanı olma yolundaki ilk adımlarımı atarken bana kıymetli bilgileri ve tecrübeleri ile rehberlik eden danışman hocam Sayın Prof. Dr. Halil İbrahim OKUMUŞ’a sonsuz teşekkürlerimi sunarım.

Ayrıca, yapıcı eleştirileri ve önerileri ile tezime büyük katkılarda bulunan kıymetli hocalarım Sayın Doç. Dr. Sedat GÖRMÜŞ’e, Sayın Doç. Dr. Fatih Mehmet NUROĞLU’na, Sayın Dr. Öğr. Üyesi Hakan KAHVECİ’ye, Sayın Dr. Öğr. Üyesi Hatice OKUMUŞ’a, KTÜ Trabzon MYO’daki değerli hocalarım Öğr. Gör. Uğurtan TOYGAR’a, Öğr. Gör. Metin TÜYSÜZ’e ve eğitim-öğretim hayatım boyunca bana katkıda bulunan tüm hocalarıma teşekkür ederim.

Son olarak, manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük pay sahibi olan sevgili annem Nermin CİVELEK’e ve sevgili babam Orhan CİVELEK’e, kardeşlerime, yeğenlerime ve neşesi ve enerjisi ile bu zorlu süreçte bana en büyük motivasyonu sağlayan varlığı ile bu süreçteki en büyük ilham kaynağım olan sevgili kızım Zeynep’e çok teşekkür ederim. Sevgili arkadaşlarım, Turgut ABDİOĞLU, Hatice BAKİ, Barış ENGİN, Elif ENGİN, Dr. Yasemin UZUN’a zor zamanlarda gösterdikleri anlayış ve destek için teşekkür ederim. Ayrıca tüm gönül dostlarıma teşekkürlerimi sunar, minnettarlığımı ifade ederim.

Bu tez çalışmasının, bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Önder CİVELEK

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Makine Öğrenimi Algoritmaları Kullanılarak Kaçak Elektrik Takibi ve Kontrol Sisteminin Gerçekleştirilmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Halil İbrahim OKUMUŞ’un 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. 30/09/2024

Önder CİVELEK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
SEMBOLLER VE KISALTMALAR DİZİNİ	XIV
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.2. Akıllı Şebekeler	4
1.3. Dağıtım Şebekelerinde Elektrik Hırsızlığı	6
1.4. Makine Öğrenmesi Yöntemleri	8
1.4.1. Topluluk (Ensemble) Yöntemleri	10
1.5. Matematiksel ve İstatistiksel Özellikler	17
1.6. Ayrık Dalgacık Dönüşümü.....	19
1.7. The Fast Walsh-Hadamard Dönüşümü (FWHT)	22
1.8. Asenkron Motorun Dinamik Modeli	23
1.8.1. Motor Kalkış Akımı	25
1.9. Literatür Araştırması	27
1.9.1. Motivasyon ve Katkıları	48
2. YAPILAN ÇALIŞMALAR.....	52
2.1. Sistem Mimarisi	52
2.2. Kaçak Tüketimin Tespiti	55
2.3. OBE Algoritması Tabanlı Yük Sınıflandırması	58
2.4. OBE Algoritması Tabanlı Kaçak Yeri Tespiti	60
2.5. Elazığ Örneği ile İlgili Çalışmalar.....	61
2.5.1. Verilerin Elde Edilmesi.....	61
2.5.2. Tek Faz Akım Verisi ile Sınıflandırma ve Lokalizasyon Çalışması	69
2.5.3. Üç Faz Akım Verisi ile Sınıflandırma ve Lokalizasyon Çalışması	72
2.6. Malatya Örneği ile İlgili Çalışmalar.....	74

2.6.1. Verilerin Elde Edilmesi.....	74
2.6.2. Üç Faz Akım Verisi ile Sınıflandırma ve Lokalizasyon Çalışması	79
3. BULGULAR VE TARTIŞMA	81
3.1. Elazığ Örneği ile İlgili Bulgular	81
3.1.1. Tek Faz Akım Verisi ile İlgili Bulgular	81
3.1.2. Üç Faz Akım Verisi ile İlgili Bulgular.....	96
3.1.3. Saha Çalışması	111
3.2. Malatya Örneği ile İlgili Bulgular	116
3.2.1. Üç Faz Akım Verisi ile İlgili Bulgular.....	116
4. SONUÇLAR.....	128
5. ÖNERİLER.....	130
6. KAYNAKLAR	132
ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

MAKİNE ÖĞRENİMİ ALGORİTMALARI KULLANILARAK KAÇAK ELEKTRİK TAKİBİ VE KONTROL SİSTEMİNİN GERÇEKLEŞTİRİLMESİ

Önder CİVELEK

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Halil İbrahim OKUMUŞ
2024, 139 Sayfa

Bu çalışmada, alçak gerilim şebekelerinde kaçak yüklerin tespiti için makine öğrenmesi tabanlı yenilikçi bir sistem önerilmektedir. Hedef, tarımsal sulama uygulamalarında kaçak bağlanan yüklerin belirlenmesi, sınıflandırılması ve yerlerinin tespitiyle elektrik hırsızlığını azaltmaktır. Önerilen sistemin etkinliğini göstermek amacıyla, Elazığ ve Malatya illerindeki iki pilot bölgeye ait alçak gerilim şebekesi gerçek saha parametrelerine dayalı olarak modellenmiştir ve üç faz akım verileri fider başlangıcından kaydedilerek bir veri seti oluşturulmuştur. Bu veriseti kullanılarak iki farklı kaçak tespit yöntemi önerilmiştir. Tek faz ve üç faz akım verilerinden Örüntü Analizi, Ayrık Dalgacık Dönüşümü ve Hızlı Walsh-Hadamard Dönüşümü yöntemleriyle öznitelikler elde edilmiş, ve oluşturulan verisetleri makine öğrenmesi algoritmalarının eğitim ve test aşamalarında kullanılmıştır. Sınıflandırma ve lokalizasyon çalışmalarında bu algoritmaların performansları karşılaştırılmış; topluluk yöntemlerinin özellikle etkili olduğu gözlemlenmiştir. Izgara arama optimizasyonu ile önerilen yöntemin performansı artırılmış ve gerçek saha verileriyle yüksek performans elde edilmiştir. DWT yöntemiyle öznitelikler çıkarıldığında, OBE algoritmasının en iyi sonuçları verdiği doğrulanmıştır.

Anahtar Kelimeler: elektrik hırsızlığı, ayrık dalgacık dönüşümü, makine öğrenmesi, hızlı walsh-hadamard dönüşümü, enerji verimliliği, topluluk yöntemleri

PhD. Thesis

SUMMARY

REALISATION OF ILLEGAL ELECTRICITY TRACKING AND CONTROL SYSTEM USING MACHINE LEARNING ALGORITHMS

Önder CİVELEK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Prof. Dr. Halil İbrahim OKUMUŞ
2024, 139 Pages

In this study, an innovative machine learning-based system is proposed for the detection of illegal loads in low voltage networks. The primary objective is to reduce electricity theft by identifying, classifying, and locating illegally connected loads, specifically in agricultural irrigation applications. To demonstrate the effectiveness of the proposed system, two pilot areas in the provinces of Elazığ and Malatya were modeled based on real field parameters of low voltage networks. A dataset was created by recording three-phase current data at the beginning of the feeder. Using this dataset, two different methods for detecting illegal connections were proposed. Features were extracted from single-phase and three-phase current data using Pattern Analysis, Discrete Wavelet Transform (DWT), and Fast Walsh-Hadamard Transform (FWHT). These extracted features were then used for training and testing machine learning algorithms. The performance of these algorithms was compared in classification and localization tasks, with ensemble methods demonstrating particular effectiveness. The proposed method's performance was further enhanced through grid search optimization, achieving high accuracy with real-world data. When features were extracted using the DWT method, the Optimizable Boosting Ensemble (OBE) algorithm was confirmed to produce the best results.

Key Words: electricity theft, discrete wavelet transform, machine learning, fast walsh-hadamard transform, energy efficiency, ensemble methods

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.	Yüksek akım çeken yüklerin alçak gerilim şebekeleri üzerindeki etkileri.	4
Şekil 2.	SG mimarisi (Ahmed, ve diğerleri, 2022)	5
Şekil 3.	AMI sistem bileşenleri.....	6
Şekil 4.	AGŞ’de yapılan çeşitli elektrik hırsızlıkları	7
Şekil 5.	Makine öğrenmesi yöntemleri	9
Şekil 6.	Torbalama yönteminin işlem adımları.....	11
Şekil 7.	Arttırma yönteminin işlem adımları	12
Şekil 8.	Yığma (Stacking) yönteminin işlem adımları.....	14
Şekil 9.	Üç seviyeli DWT	19
Şekil 10.	Dalgacık ailesinden örnekler (Budu, 2014).	20
Şekil 11.	Db dalgacık ailesine ait örnekler (Gupta, 2014).	21
Şekil 12.	Keyfi bir referans çerçevesinde asenkron motorun eşdeğer devre modeli	24
Şekil 13.	Motor-pompa sisteminin gerçek zamanlı üç faz başlangıç akım grafiği.....	26
Şekil 14.	NLT üzerine yapılan literatür çalışmalarının gruplanması	27
Şekil 15.	Sistem Mimarisi	53
Şekil 16.	Kaçak elektrik tüketiminin tespiti, sınıflandırılması ve lokalizasyonu için kullanılan algoritma	54
Şekil 17.	Kaçak tüketimin tespiti için önerilen 1. tespit algoritması	56
Şekil 18.	Kaçak tüketimin tespiti için önerilen 2. tespit algoritması	58
Şekil 19.	Dağıtım şebekesi topolojisi	62
Şekil 20.	F1 fiderin simülasyon topolojisi.....	63
Şekil 21.	F2 fiderin simülasyon topolojisi.....	64
Şekil 22.	F1 fider çıkış noktasından normal durumda ölçülen akım ve gerilim grafikleri	65
Şekil 23.	F2 fider çıkış noktasından normal durumda ölçülen akım ve gerilim grafikleri	66
Şekil 24.	Fider başlangıcından 1178m uzaklıkta 7,5 kW’lık bir sulama motorunun önileme aşamasından sonraki veri penceresi	66
Şekil 25.	Tek faz ve üç faz akım verisinin farklı öznitelik çıkarım teknikleri kullanılarak elde edilen veriseti boyutları.....	67
Şekil 26.	Farklı lokasyonlardaki 7,5 kW’lık bir sulama motoru için trafo fiderinde ölçülen akımın dalga şekli.	68

Şekil 27.	Farklı tork değerleri altında 7.5kW sulama motoru için trafo fiderinde ölçülen akımın dalga şekli.	68
Şekil 28.	755m'de %75 tork altında farklı nominal güçlere sahip sulama motorları için trafo fiderinde ölçülen akımın dalga şekli.	69
Şekil 29.	Akım veri penceresinden uzman kişi tarafından elle çıkarılan örüntüler	70
Şekil 30.	Pilot dağıtım hattı parametrelerinin ölçülmesi	74
Şekil 31.	Pilot dağıtım hattı fider topolojisi.....	75
Şekil 32.	Üç faz akım verisinden farklı öznitelik çıkarım teknikleri kullanılarak elde edilen veriseti boyutları.....	77
Şekil 33.	Normal şartlar altında trafo fiderinden ölçülen akım ve gerilim değerleri	77
Şekil 34.	188m mesafede 7,5 kW sulama motoru devreye girdiğinde trafo fiderinde ölçülen akım ve gerilim değerleri.....	78
Şekil 35.	511m mesafede 7,5 kW'lık bir sulama motoru devreye girdiğinde trafo fiderinde ölçülen akım ve gerilim değerleri.....	78
Şekil 36.	983m mesafede 7,5 kW'lık bir sulama motoru trafo devreye girdiğinde ölçülen akım ve gerilim değerleri	79
Şekil 37.	Test verisi üzerinde en iyi sınıflandırma sonucu veren topluluk yöntemlerinin (a) Örüntü analizi (b) DWT yöntemi ve (c) FWHT yöntemi ile performansını gösteren karmaşık matrisleri	87
Şekil 38.	Test verisi üzerinde en iyi sınıflandırma sonucu veren topluluk yöntemlerinin (a) Örüntü Analizi (b) DWT Yöntemi c) FWHT Yönteminin sınıflandırma performansını gösteren ROC eğrileri	88
Şekil 39.	Test verisi üzerinde en iyi lokalizasyon sonucu veren topluluk yöntemlerinin (a) Örüntü Analizi (b) DWT Yöntemi c) FWHT Yöntemi sonuçları.....	95
Şekil 40.	Test verisi üzerinde en iyi sınıflandırma sonucu veren topluluk yöntemlerinin (a) Örüntü analizi, (b)DWT yöntemi ve (c) FWHT yöntemi ile performansını gösteren karmaşık matrisleri	101
Şekil 41.	Test verisi üzerinde en iyi sınıflandırma sonucu veren topluluk yöntemlerinin (a) Örüntü Analizi (b) DWT Yöntemi c) FWHT Yönteminin sınıflandırma performansını gösteren ROC eğrileri	102
Şekil 42.	Test verisi üzerinde en iyi lokalizasyon sonucu veren topluluk yöntemlerinin (a) Örüntü Analizi (b) DWT Yöntemi c) FWHT Yöntemi sonuçları.....	111
Şekil 43.	Ölçüm bileşenlerinin ve veri örnekleme devresinin montajı.....	112
Şekil 44.	Veri toplayıcısının montajı	113
Şekil 45.	Farklı zamanlarda devreye giren sulama motorları için gerçek saha ölçümleri.....	113

Şekil 46.	BAT algoritmasının (a) kaçak tüketim yapan yük ve (b) dağıtım sisteminin fider branşı için sınıflandırma performansını gösteren karışıklık matrisleri.....	120
Şekil 47.	BAT algoitmasının performansını gösteren a) kaçak tüketim yapan yük sınıflandırması için (b) fider kolu sınıflandırması için ROC eğrileri	121
Şekil 48.	Model performansını gösteren tahmin edilen ve gerçek grafiği.....	123



TABLÖLAR DİZİNİ

Sayfa No

Tablo 1.	İkili sınıflandırma modeli için Karışıklık Matrisi ve bileşenleri	14
Tablo 2.	Model Denklemlerinde Kullanılan Semboller.....	24
Tablo 3.	Asenkron Motorların Elektriksel Parametreleri.....	25
Tablo 4.	Literatür İncelemesi	46
Tablo 5.	Tez çalışmasının literatür çalışmalar ile kıyaslanması	51
Tablo 6.	Kaçak tespit, sınıflandırma ve lokalizasyon algoritması pseudo kodu	55
Tablo 7.	Sınıflandırma probleminde kullanılan farklı makine öğrenimi modelleri ve bu modellerin hiperparametreleri.....	59
Tablo 8.	Lokalizasyon probleminde kullanılan farklı makine öğrenimi modelleri ve bu modellerin hiperparametreleri.....	61
Tablo 9.	Dağıtım hattı kablo parametreleri	63
Tablo 10.	Simülasyon parametreleri	64
Tablo 11.	Fiderlerde simüle edilen ev yükleri ve fider uzunlukları	65
Tablo 12.	Sınıflandırma için kullanılan motor yüklerin etiket bilgisi	70
Tablo 13.	Sınıflandırma çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri.....	71
Tablo 14.	Lokalizasyon çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri.....	71
Tablo 15.	Sınıflandırma çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri.....	72
Tablo 16.	Lokalizasyon çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri.....	73
Tablo 17.	Modellenen fiderde kullanılan ev yükleri	75
Tablo 18.	Dağıtım hattı kablo parametreleri.....	76
Tablo 19.	Simülasyon parametreleri	76
Tablo 20.	Kaçak yük olarak kullanılan sulama motorlarının etiketleme bilgileri ve motorların devreye girdiği branşlar	79
Tablo 21.	Lokalizasyon çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri.....	80
Tablo 22.	Örüntü analizi yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları.....	82
Tablo 23.	DWT yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları	84
Tablo 24.	FWHT yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları	85
Tablo 25.	Örüntü analizi yöntemi kullanılarak elde edilen lokalizasyon sonuçları.....	89
Tablo 26.	DWT yöntemi kullanılarak elde edilen lokalizasyon sonuçları.....	90

Tablo 27.	DWT tekniğinden elde edilen maksimum hata, ortalama hata ve standart sapma değerleri	92
Tablo 28.	FWHT yöntemi kullanılarak elde edilen lokalizasyon sonuçları	93
Tablo 29.	Kaçak elektrik tüketimi yapan yüklerin lokasyonlarının her üç yöntem için karşılaştırmalı olarak sunulması	94
Tablo 30.	DWT yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları.....	97
Tablo 31.	FWHT yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları	99
Tablo 32.	DWT yöntemi kullanılarak elde edilen lokalizasyon sonuçları.....	103
Tablo 33.	Farklı ana dalgacıklar ve seviye detay katsayıları kullanılarak OBE algoritması ile maksimum hata, ortalama hata ve standart sapma değerlerinin belirlenmesi	105
Tablo 34.	DWT yöntemi kullanılarak farklı güç seviyelerine sahip motorların OBE algoritması ile yapılan lokalizasyon sonuçları.....	106
Tablo 35.	FWHT yöntemi kullanılarak elde edilen lokalizasyon sonuçları	107
Tablo 36.	FWHT yöntemi kullanılarak farklı güç seviyelerine sahip motorların OBE algoritması ile yapılan lokalizasyon sonuçları.....	108
Tablo 37.	Kaçak elektrik tüketimi yapan yüklerin tahmin edilen lokasyonlarının üç farklı yöntem kullanılarak karşılaştırılması	110
Tablo 38.	Farklı ana dalgacıklar ve seviye detay katsayıları kullanılarak OBE algoritması ile maksimum hata, ortalama hata ve standart sapma değerlerinin belirlenmesi	115
Tablo 39.	Saha ölçümleri kullanılarak elde edilen tarımsal sulama amaçlı kaçak elektrik kullanımına ait lokasyon uzunlukları ve hata yüzdeleri	115
Tablo 40.	DWT yöntemi kullanılarak elde edilen sınıflandırma sonuçları	116
Tablo 41.	Dağıtım sistemi fider branşı sınıflandırmasının sonuçları	118
Tablo 42.	DWT yöntemi kullanılarak elde edilen lokalizasyon sonuçları	122
Tablo 43.	DWT yöntemi kullanılarak farklı güç seviyelerine sahip motorların OBE algoritması ile yapılan lokalizasyon sonuçları.....	124
Tablo 44.	Farklı ana dalgacıklar ve seviye detay katsayıları kullanılarak OBE algoritması ile maksimum hata, ortalama hata ve standart sapma değerlerinin belirlenmesi	126
Tablo 45.	Performans Karşılaştırılması	127

SEMBOLLER VE KISALTMALAR DİZİNİ

TL	: Teknik Kayıplar (Technical Losses)
NTL	: Teknik Olmayan Kayıplar (Nontechnical Losses)
SM	: Akıllı Sayaç (Smart meter)
AGŞ	: Alçak Gerilim Şebekesi
SG	: Akıllı Şebeke (Smart Grid)
AMI	: Gelişmiş Sayaç Altyapısı (Advanced Metering Infrastructure)
FT	: İnce Ağaç (Fine Tree)
MT	: Orta Ağaç (Medium Tree)
CT	: Kalın Ağaç (Coarse Tree)
LD	: Doğrusal Ayırt Edici (Linear Discriminant)
ELR	: Etkin Lojistik Regresyon (Efficient Logistic Regression)
ELSVM	: Etkin Doğrusal SVM (Efficient Linear SVM)
GNB	: Gauss Naive Bayes (Gaussian Naive Bayes)
KNB	: Çekirdek Naive Bayes (Kernel Naive Bayes)
LSVM	: Doğrusal SVM (Linear SVM)
QSVM	: İkinci Dereceden SVM (Quadratic SVM)
CSVM	: Kübik SVM (Cubic SVM)
FGSVM	: İnce Gauss SVM (Fine Gaussian SVM)
MGSVM	: Orta Gauss SVM (Medium Gaussian SVM)
CGSVM	: Kalın Gauss SVM (Coarse Gaussian SVM)
FKNN	: İnce KNN (Fine KNN)
MKNN	: Orta KNN (Medium KNN)
CKNN	: Kalın KNN (Coarse KNN)
CoKNN	: Kosinüs KNN (Cosine KNN)
CuKNN	: Kübik KNN (Cubic KNN)
WKNN	: Ağırlıklı KNN (Weighted KNN)
BT	: Güçlendirilmiş Ağaçlar (Boosted Trees)
BAT	: Torbalanmış Ağaçlar (Bagged Trees)
SD	: Altuzay Ayırt Edici (Subspace Discriminant)
SKNN	: Altuzay KNN (Subspace KNN)
RBT	: Gezgin Satıcı Problemi

NNN	: Dar Sinir Ağı (Narrow Neural Network)
MNN	: Orta Sinir Ağı (Medium Neural Network)
WNN	: Geniş Sinir Ağı (Wide Neural Network)
BNN	: İki Katmanlı Sinir Ağı (Bilayered Neural Network)
TNN	: Üç Katmanlı Sinir Ağı (Trilayered Neural Network)
OBE	: Optimize Edilebilir Güçlendirme Topluluğu (Optimizable Boosting Ensemble)
LN	: Doğrusal (Linear)
SEGPR	: Kare Üslü GPR (Squared Exponential GPR)
MGPR	: Matern 5/2 GPR
EGPR	: Exponential GPR (Üstel GPR)
RQGPR	: Rasyonel İkinci Dereceden GPR (Rational Quadratic GPR)
TPR	: Doğru Pozitif Oranı (True Positive Rate)
ACC	: Doğruluk (Accuracy)
FPR	: Yanlış Pozitif Oranı (False Positive Rate)
RMSE	: Kök Ortalama Kare Hatası (Root Mean Squared Error)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
DWT	: Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)
FWHT	: Hızlı Walsh-Hadamard Dönüşümü (Fast Walsh-Hadamard Transform)
FRTU	: Fider Uzaktan Terminal Üniteleri
SMOTE	: Sentetik Azınlık Aşırı Örnekleme Tekniği

1. GENEL BİLGİLER

1.1. Giriş

Elektrik enerjisi, yaşamımızın ayrılmaz bir bileşenidir ve modern toplumların işleyişinde hayati bir rol oynamaktadır. Ancak, bu enerjinin yanlış veya verimsiz kullanımı, enerji santrallerinden tüketiciye ulaşana kadar çeşitli enerji kayıplarına neden olmaktadır. Bu kayıpların iki ana kaynağı vardır; teknik kayıplar (TL) ve teknik olmayan kayıplar (NTL). TL, elektrik enerjisinin iletim ve dağıtım süreçlerinde doğal olarak meydana gelen kayıplardır. Bu kayıplar, enerji iletimi sırasında iletkenlerin direnç göstermesi, transformatörlerde enerji dönüşümleri sırasında oluşan kayıplar ve diğer elektrik ekipmanlarının işletiminden kaynaklanmaktadır. TL, genellikle sabit oranlarda meydana gelmektedir ve tahmin edilebilir olmaktadır. Bu kayıplar, elektrik sisteminin fiziki ve işletme koşullarına bağlı olarak değişiklik gösterebilmektedir. NTL ise teknik olmayan kayıplardır. Ve elektrik hırsızlığı, yanlış faturalama ve idari hatalar gibi faktörlerden kaynaklanmaktadır. NTL, elektrik şebekesinin ticari ve operasyonel verimliliğini ciddi şekilde etkilemektedir. Elektrik şirketlerinin gelir kayıplarına neden olmakta ve bu kayıplar, tüketicilere yansıtılarak daha yüksek enerji maliyetlerine yol açmaktadır. Ayrıca şebeke güvenliğinde tehlikeye atmaktadır. En önemli NTL türü elektrik hırsızlığı olmaktadır. Elektrik hırsızlığı doğrudan dağıtım hattına bağlantı yapılarak ya da Akıllı sayaçlara (SM) müdahale edilerek gerçekleşmektedir. SM saldırıları fiziksel saldırılar, siber saldırılar ve veri düzeyinde saldırıları içermektedir. Fiziksel saldırılarda, dağıtım hattından bağlantı yaparak elektriğin kullanılması, sayaç terminallerinden bağlantı yaparak, nötr bypassı yaparak, sayaç bobinlere müdahale ederek, radyo frekansı dalgaları kullanarak okumaları manipüle etmek, sistemi mekanik şoklara maruz bırakmak ve besleme terminallerini değiştirmek gibi çeşitli yollarla gerçekleşmektedir. Bu çeşitli saldırılar, elektrik faturalarını azaltmak amacıyla SM okumalarını değiştirmeyi hedeflemektedir.

Elektrik hırsızlığı, dünya genelinde önemli bir sorun olmaya devam etmektedir. Ekim 2021'de yayımlanan bir çalışmada, ulusal bir akıllı şebeke danışmanlık firması olan Northeast Group, elektrik hırsızlığı ve teknik olmayan kayıpların, 138 ülkedeki hizmet sağlayıcılar için yıllık 101.2 milyar dolar gelir kaybına neden olduğunu belirtmiştir (URL-1, 2023).

Pakistan, Hindistan, Brezilya ve Rusya, bu olgudan en çok ekonomik olarak etkilenen ülkelerdir. Örneğin, Pakistan, elektrik dağıtım sistemindeki yasadışı kullanım nedeniyle yıllık olarak yaklaşık %13-14 oranında kayıp yaşamaktadır (Babar, Jamil, & Haq, 2022). Brezilya ekonomisi ise, yıllık 3 milyar dolar kayba yol açan elektrik hırsızlığının etkilerinden büyük ölçüde zarar görmektedir (Arif A, 2022).


Ülkemizde, 2015 yılında iletim şebekesi kayıpları %2.1 seviyesinde gerçekleşmiş olup, bu oran gelişmiş ülkeler düzeyindedir. Elektrik dağıtım şebekesi kayıpları ise toplam elektrik tüketiminin %12.1'ini oluşturmuştur. 2015 yılı için kaçak elektrik kullanımının Türkiye'ye maliyeti, toplam kayıp ve kaçak oranı içerisindeki kayıp oranının %5 ile %7 arasında olduğu varsayımı ve 2015 yılı ortalama Piyasa Takas Fiyatı 144 TL/MWh dikkate alındığında 5.8 ila 8.5 milyar TL arasında olmaktadır (Düzgün, 2018).

Tez çalışmasında kullanılan pilot sahaların bulunduğu bölgenin dağıtım firması olan Fırat EDAŞ'ın 2023 yılı gerçekleşen kayıp-kaçak oranı, Enerji Piyasası Düzenleme Kurumu'nun 2023 raporuna göre %10,94 olarak tespit edilmiştir (EPDK, 2023). Örneğin Malatya da seçilen pilot bölgede Mayıs 2021'den Ekim 2021'e kadar geçen sürede, %42 oranında bir kayıp oranı gözlemlenmiştir. Bu tarihler arasındaki dönemde toplam 987.452 kWh dağıtılmış enerji kaydedilmiş, ancak toplam 568.826 kWh faturalandırılmıştır. Bu, 418.626 kWh'lik bir faturalandırılmamış enerji anlamına gelmektedir ve bu, önemli bir tutarsızlığı göstermektedir. Bu yetkisiz enerji kullanımının yaklaşık %90'ının Alçak gerilim şebekesinde (AGŞ) elektrik hırsızlığı nedeniyle olduğu tahmin edilmektedir. Yapılan saha kontrolleri, özellikle tarımsal sulama için yüklerin devreye alınmasının bu yetkisiz kullanımda önemli bir rol oynadığını göstermiştir.

Akıllı şebekelere bilgi ve iletişim teknolojilerinin entegrasyonu, geleneksel elektrik şebekelerine göre daha verimli, güvenli ve sürdürülebilir bir alternatif sunmaktadır. Bu entegrasyon, enerji yönetimini optimize ederek enerji tüketim verilerinin gerçek zamanlı izlenmesini ve analiz edilmesini sağlamaktadır. Böylece, elektrik hırsızlığı gibi yasadışı faaliyetler, enerji arzında kesintilere yol açabilen ve güvenlik açısından ciddi riskler oluşturabilen olaylar daha etkin bir şekilde tespit edilebilir ve önlenir. Özellikle AGŞ'de, akıllı şebeke teknolojileri, sistemin güvenliğini, verimliliğini ve güvenilirliğini tehdit eden elektrik hırsızlığına karşı önemli bir savunma mekanizması sunmaktadır. Elektrik hırsızlığı, şebeke altyapısına zarar verebilir, enerji şirketlerinin gelir kaybına neden olabilir ve tüketicilere daha yüksek maliyetler olarak yansır. Bu durum, NTL kayıplarının hızlı ve doğru bir şekilde tanımlanmasını, enerji kayıplarını önlemek ve güvenliği sağlamak

açısından büyük önem taşımaktadır. Elektrik hırsızlığının erken tespiti, sistemin genel sağlığını koruyarak operasyonel kesintileri en aza indirir ve enerji dağıtımının sürekliliğini sağlar. Akıllı sayaçlar ve gelişmiş veri analizi teknikleri, enerji hırsızlığını ve diğer NTL'leri tespit etmek için kritik araçlar sunmaktadır. Bu tür teknolojilerin entegrasyonu, akıllı şebeke ağlarının operasyonel verimliliğini ve güvenilirliğini artırmak için hayati öneme sahiptir. İleri algoritmaların NTL ve elektrik hırsızlığının tespitinde kullanılması, enerji sistemlerinin dayanıklılığını artırarak şebeke operatörlerinin hızlı ve doğru müdahaleler yapmasına olanak tanımaktadır. Bu da, enerji arz güvenliğinin korunmasını ve şebekenin sürekli olarak verimli bir şekilde çalışmasını sağlar. Akıllı şebekeler, bu tür sorunlarla mücadelede daha etkili ve adaptif çözümler sunarak, enerji yönetiminde devrim niteliğinde gelişmeler sağlamaktadır.

Şekil 1'de yüksek akım çeken yüklerin alçak gerilim şebekeleri üzerindeki etkileri verilmiştir. Bu yüklerin en yaygın etkilerinden biri, şebeke voltajındaki dalgalanmalardır. Ani voltaj düşüşlerinin hassas elektronik cihazlarda yol açtığı hasar önemli bir sorundur. Bilgisayarlar, tıbbi ekipmanlar ve diğer hassas cihazlar, voltaj değişimlerine karşı oldukça duyarlıdır ve bu durum, bu cihazların arızalanmasına neden olarak cihazların işlevselliğini ciddi şekilde etkileyebilir ve önemli operasyonel ve mali kayıplara yol açabilir. Endüstriyel tesislerde, üretim hatlarındaki makineler ani voltaj düşüşlerinden etkilenebilir, bu da üretim kesintilerine ve önemli maliyetlere yol açabilir. Örneğin, bir üretim hattında ani bir voltaj düşüşü makineleri durdurabilir ve üretim süreçlerini aksatarak işletme maliyetlerini artırabilir ve ürün kalitesini düşürebilir. Şebeke kararlılığı, ani ve yüksek akım yüklerinin devreye alınmasıyla tehlikeye girebilir ve bu durum güç kalitesinin bozulmasına neden olabilir. Güç kalitesinin bozulması, elektrik kesintileri ve sistem çökmeleri gibi olumsuz sonuçlara yol açarak şebeke kararlılığını daha da zayıflatır. Zayıf altyapıya sahip bölgelerde, güç kalitesinin düşük olması nedeniyle elektrik kesintileri daha sık meydana gelebilir ve daha uzun sürebilir. Ani ve büyük enerji talepleri, şebekenin genel dengesini bozarak sistem çökmelerine neden olabilir ve bu da geniş çapta elektrik kesintilerine ve önemli ekonomik kayıplara yol açabilir. Ani yüklerin devreye alınması, şebekede ani bir akım artışına yol açar ve bu da şebeke bileşenlerinde termal strese neden olur. Termal stres, transformatörler ve iletim kablolarındaki yüksek akımın neden olduğu aşırı ısınmadan kaynaklanır. Elektrik bileşenlerinin sürekli aşırı ısınması, ömürlerini kısaltabilir. Aşırı ısınmış şebeke bileşenleri, yangınlara yol açarak hem şebeke altyapısı hem de çevresindeki yapılar ve insan hayatı için büyük bir tehlike oluşturabilir. Örneğin, aşırı ısınmış bir transformatör, geniş bir alanı etkileyen bir yangına neden olabilir (Jain & Khan, 2019).



Şekil 1. Yüksek akım çeken yüklerin alçak gerilim şebekeleri üzerindeki etkileri.


1.2. Akıllı Şebekeler

Akıllı şebeke (SG), geleneksel elektrik şebekesine kıyasla daha ileri düzeyde iletişim ve bilgi işlem yeteneklerine sahip modern bir enerji dağıtım sistemidir. Bu sistem, enerji verimliliğini artırmak, maliyetleri düşürmek ve enerji tedarik zincirinin güvenilirliğini ve şeffaflığını sağlamak amacıyla tasarlanmıştır. Geleneksel elektrik enerjisi şebekesi, elektrik enerjisini üretim tesislerinden tüketim noktalarına ileten devasa bir altyapı bağlantısıdır. Şekil 2, SG tarafından kontrol edilen ve bağlanan çeşitli birimleri göstermektedir. SG, enerji tüketiminin gerçek zamanlı olarak izlenmesi ve kontrol edilmesini mümkün kılan gelişmiş sayaç altyapısı (AMI) gibi bileşenlerle donatılmıştır.


Otomatik sayaç okuma, enerji sayaçlarının uzaktan okunmasını sağlayan ve tek yönlü iletişim sistemleriyle donatılmış bir teknolojidir. Otomatik sayaç okuma, enerji tüketim verilerini manuel okumaya gerek kalmadan otomatik olarak toplar, sayaç okuma maliyetlerini azaltır ve insan hatasını minimize eder. Okuma sürecini hızlandırarak operasyonel verimliliği artırır. Ancak, sadece sayaçtan merkezi sisteme veri gönderebilir ve tüketiciye veya diğer sistemlere geri bildirim sağlayamaz. Bu nedenle, gerçek zamanlı veri izleme ve kontrol yetenekleri sınırlıdır. AMI ise, akıllı sayaçlar ve iletişim ağları kullanarak enerji tüketimini gerçek zamanlı olarak izleyen ve kontrol eden daha gelişmiş bir sistemdir. Şekil 3’de AMI sistem bileşenleri verilmiştir. AMI, iki yönlü iletişim sistemlerine sahip olup, veri alışverişinin hem sayaçtan merkezi sisteme hem de merkezi sistemden sayaca

yapılabilmesini sağlar. Bu sayede, enerji tüketimini anlık olarak izleyebilir ve kontrol edebilir, kesintilerin hızlı bir şekilde tespit edilmesini ve yönetilmesini sağlar, enerji tüketimine dayalı dinamik fiyatlandırma ve faturalandırma yapabilir, ağıdaki arızaların hızlı bir şekilde tespit edilmesini ve onarılmasını mümkün kılar ve tüketici taleplerine anında yanıt vererek enerji optimizasyonunu teşvik eder (Souza & Gomes, 2020).

SG, AMI'nin sağladığı ileri düzey iletişim ve bilgi işlem yetenekleri sayesinde enerji dağıtımının daha verimli, güvenilir ve şeffaf bir şekilde yönetilmesini sağlar. Dijital teknolojinin maliyetlerindeki düşüş, yaşanan ilerlemenin bir diğer itici gücüdür. Yeni cihazlar ve sistemler, şebeke elemanlarının ileri düzeyde algılanmasını ve kontrol edilmesini, kapsamlı bilgi paylaşımını ve iletişimi, daha güçlü bilgi işlem yeteneklerini ve daha iyi kontrolü mümkün kılmaktadır. SG geliştikçe, akıllı binalar ve şehirler, ulaşım ve telekomünikasyon gibi diğer altyapıların ortaya çıkması da artış gösterecektir.



Şekil 2. SG mimarisi (Ahmed, ve diğerleri, 2022)



Şekil 3. AMI sistem bileşenleri


1.3. Dağıtım Şebekelerinde Elektrik Hırsızlığı

Elektrik hizmetleri, günümüz dünyasında çeşitli tehditler, sorunlar ve zorluklarla karşı karşıya kalmaktadır. Bu zorluklar arasında elektrik hırsızlığı, önemli bir yer tutar ve yasadışı bir uygulama olarak tanımlanır. Elektrik hırsızlığı, tüketilen enerjinin bedelini ödmeden kullanılması anlamına gelmektedir ve genellikle sayaç manipülasyonu, hat bypasslama ve fatura düzensizlikleri gibi çeşitli yöntemlerle gerçekleştirilir. Hırsızlık ve dolandırıcılık yöntemleri, genellikle teknolojik müdahaleler ve fiziksel manipülasyonlar şeklinde ortaya çıkmaktadır. Teknolojinin hayatın birçok alanını dönüştürmesiyle birlikte, sayaç altyapısı da gelişmiş ve SG kavramı ortaya çıkmıştır. Ancak, bilgi ve iletişim teknolojilerinin uygulanması, elektrik hırsızlığı için siber saldırıları da beraberinde getirmiştir. Bu durum, enerji hırsızlığının daha karmaşık ve tespit edilmesi zor hale gelmesine neden olmuştur.

Literatürde tanımlanan farklı elektrik hırsızlığı türleri sayaç müdahaleleri, elektrik hatlarına müdahale, düşük kalite sayaçların kullanımı, yasadışı abonelikler, ticari ve endüstriyel hırsızlık, yanlış abone kaydı ve fatura oyunları olarak sınıflandırılabilir. Şekil 4'de AGŞ'de gerçekleşen bazı elektrik hırsızlıkları görülmektedir.

Sayaç müdahaleleri, enerji tüketimini ölçmek için kullanılan cihazların manipülasyonunu içerir. Bu tür hırsızlık yöntemleri arasında sayaç verimliliğini bozma, sayaç atlatma, yazılım manipülasyonu, uzaktan müdahale yer almaktadır. Sayaç verimliliğini bozma, yüksek viskoziteli sıvı, güçlü mıknatıs veya benzeri bir şey sayaca sokularak hızının yavaşlatılması anlamına gelmektedir. Böylece sayaç tüm tüketimi

kaydetmemektedir. Sayaca güçlü bir darbe vurmak da disk dönüşünü kalıcı olarak bozabilmektedir. Sayaç atlatma (bypass), sayacın devre dışı bırakılarak veya bypass edilerek enerji tüketiminin yapılmasıdır. Bu yöntem genellikle doğrudan elektrik hattına bağlantı yaparak gerçekleştirilir. Yazılım manipülasyonunda, akıllı sayaçların yazılımlarına müdahale edilerek tüketim bilgileri manipüle edilmektedir. Uzaktan müdahalede, akıllı sayaçlar ve şebeke sistemlerine uzaktan erişim sağlanarak verilerin değiştirilmesi sağlanmaktadır.



Şekil 4. AGŞ’de yapılan çeşitli elektrik hırsızlıkları

Elektrik hatlarına müdahale, doğrudan hatlardan elektrik çekmeyi içermektedir. Doğrudan bağlantıda, elektrik dağıtım hattına doğrudan bağlantı yapılarak enerji tüketilmektedir. Bu yöntem, genellikle sayaçların atlanması veya devre dışı bırakılması ile gerçekleştirilmektedir. Gizli hat çekme, resmi bağlantı hattının dışında gizli bir hat çekilmesi ve buradan enerjinin kullanılmasıdır. Üç fazlı kaynaktan tek faz kullanımı, nötr hattı iletimde koparılmakta ve ayrı bir nötr hat dönüş yolu olarak kullanılmaktadır. Voltaj tüketimi sıfıra inerek sayacın enerji tüketimini kaydetmesi engellenmektedir (Hussain, 2016). Bu tez çalışmasında, tarımsal sulama amacıyla kullanılan sulama motorlarının dağıtım hattına doğrudan bağlanması (çengel atma yöntemi) sonucunda oluşan kaçak elektrik tüketimlerinin analizi yapılacaktır.

Bilinçli olarak düşük kalite ve arızalı sayaçların kullanımı, enerji tüketiminin eksik kaydedilmesine yol açar. Bu sayaçlar, genellikle enerji şirketlerinin kontrolünden kaçarak kullanılmaktadır. Sahte abonelikler, gerçek dışı bilgilerle oluşturulan veya eski aboneliklerin yeniden kullanılmasıyla gerçekleşir. Genellikle kimlik bilgileri çalınarak veya sahte belgeler kullanılarak oluşturulan abonelikler üzerinden elektrik kullanımı sağlanır. Eski aboneliklerin kullanımı, feshedilmiş veya geçici olarak durdurulmuş aboneliklerin yeniden kullanılması genellikle terk edilmiş veya boşta olan mülklerde kullanılmaktadır.

Ticari ve endüstriyel kullanıcılar, enerji tüketimini düşük göstermek veya kaçak elektrik kullanmak için çeşitli yöntemler kullanabilirler; endüstriyel kullanıcılar, talep düzeylerini düşük göstererek daha düşük enerji faturaları ödemek için çeşitli yöntemler kullanabilirler. Bu yöntemler arasında sayaç manipülasyonu ve enerji tüketim profillerinin değişimi yer almaktadır. Ticari işletmeler, gizli hatlar kullanarak veya sayaç manipülasyonu yaparak kaçak elektrik kullanabilmektedirler.

Yanlış abone bilgileri veya fatura kesintileri de dolandırıcılık yöntemleri arasında yer almaktadır. Bilinçli olarak yanlış veya eksik abone bilgileri ile düşük faturalar oluşturmayı kapsamaktadır. Fatura kesintisi, fatura okuma sürecinde eksik veya yanlış bilgi girilerek faturanın düşük gösterilmesidir.


1.4. Makine Öğrenmesi Yöntemleri

Makine öğrenme algoritmaları, bilgisayar sistemlerinin verilerden öğrenmesini sağlayan ve karmaşık problemleri çözmek için kullanılan yöntemlerdir. Bu algoritmalar, büyük miktarda veri üzerinde çalışarak veri seti içindeki yapıları, desenleri ve ilişkileri otomatik olarak tanımlar. Şekil 5’de en çok kullanılan makine öğrenmesi yöntemleri gösterilmektedir. Makine öğrenme algoritmaları denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç gruba ayrılmaktadır;

Denetimli öğrenme algoritmaları, etiketli veri setleri üzerinde çalışır. Bu veri seti, girdi verilerini ve bunlara karşılık gelen hedef çıktıları içerir. Denetimli öğrenmenin amacı, veri setindeki özellikler ile hedef çıktılar arasındaki ilişkiyi öğrenmektir. Sınıflandırma algoritmaları, girdi verilerini belirli sınıflara ayırmak için kullanılırken, regresyon algoritmaları sürekli çıktı tahminleri yapmak için kullanılır. En önemli denetimli öğrenme algoritmaları arasında Topluluk Yöntemleri, Bayes, Karar Ağaçları ve Yapay Sinir Ağları bulunmaktadır.

Buna karşılık, denetimsiz öğrenme algoritmaları etiketlenmemiş veri setlerindeki yapıları ve örüntüleri tanımlamak için kullanılır. Bu algoritmalar, veri seti içindeki benzerlikleri ve gruplamaları tespit etmek için tasarlanmıştır. Kümeleme algoritmaları, veri setini farklı gruplara ayırırken, boyut indirgeme algoritmaları veri setinin boyutunu azaltarak daha anlamlı bir temsil elde etmeyi amaçlar. Denetimsiz öğrenme algoritmalarına örnek olarak K-ortalamlar, Hiyerarşik Kümeleme, Yapay Sinir Ağları ve Temel Bileşen Analizi verilebilir.

Pekiştirmeli öğrenme, bir sistem veya ajanın dinamik bir ortamda nasıl davranacağını öğrenmesini sağlayan bir yöntemdir. Bu öğrenme yaklaşımında, ajan çevresinden aldığı geri bildirimler (ödülleri veya cezalar) aracılığıyla deneme-yanılma yöntemiyle öğrenir. Pekiştirmeli öğrenme, deneme-yanılma süreci ile çalışır. Ajan, çevredeki farklı durumları gözlemleyerek belirli eylemleri gerçekleştirir. Bu eylemler sonucunda ajan, çevreden geri bildirim alır. Bir eylem olumlu bir sonuç doğurursa, yani beklenen bir ödül elde edilirse, ajan bu eylemi benimser ve davranışını güçlendirir. Ancak, olumsuz sonuçlar ve cezalar alındığında ajan, bu eylemden kaçınmayı öğrenir. Pekiştirmeli öğrenme türleri arasında bulunmaktadır.



Şekil 5. Makine öğrenmesi yöntemleri

1.4.1. Topluluk (Ensemble) Yöntemleri


Topluluk yöntemi, birden fazla makine öğrenmesi modelini birleştirerek daha doğru ve güvenilir tahminler elde etmeyi amaçlayan bir tekniktir. Bu yöntemler, farklı modellerin güçlü yönlerini birleştirerek, model önyargısını azaltmakta ve varyansı kontrol altında tutmaktadır. Bu yöntemler, torbalama (bagging), arttırma (boosting) ve yığma (stacking) olmak üzere üç grupta incelenebilir;

Torbalama yöntemi, rastgele orman algoritması gibi bazı popüler algoritmaların temelini oluşturmaktadır. Rastgele orman, birden fazla karar ağacını bir araya getirerek bir topluluk oluşturmaktadır. Karar ağaçları aşırı öğrenme problemlerine eğilimli olabilmektedirler. Bu nedenle, tek bir karar ağacına dayanarak tahmin yapmak yerine, bir topluluk oluşturarak daha düşük varyanslı bir tahmin modeli elde edilebilmektedir. Daha düşük bir varyansa sahip olan bir model daha iyi genelleme yapma eğilimindedir. Yüksek varyanslı bir model, veriyi çok iyi öğrendiğinde eğitim veri setine aşırı uyum sağlayabilmekte ve test verilerinde hatalı tahminlere yol açabilmektedir. Bu durum aşırı uydurma olarak adlandırılmaktadır.

Torbalama yöntemi, model hatalarını azaltmak için iki adımdan oluşmaktadır; örnekleme ve birleştirme. Örneklemede, veri setinden alt kümeler oluşturulmakta ve bu alt kümeler tekrarlı örnekleme kullanarak bootstrap veri setlerini meydana getirmektedir. Her bir bootstrap veri seti, bir modeli eğitmek için kullanılmaktadır. Birleştirmede her bir model, bağımsız olarak tahminler yapmaktadır. Bu tahminler daha sonra birleştirilerek genel tahmin elde edilmektedir. Sınıflandırma problemleri için yaygın bir birleştirme yöntemi maksimum oylama yöntemidir. Her model bir tahmin yapmakta ve en sık rastlanan tahmin genel tahmin olarak seçilmektedir. Şekil 6'da verilen torbalama yönteminin işlem adımlarını aşağıdaki gibi sıralanabilir;

1. n sayıda örneğin bulunduğu bir eğitim verisetinin hazırlanması,
2. Verisetinden m sayıda alt kümelerin seçilmesi ve her bir alt küme için N tane örnek alınması,
3. Modellerin eğitilmesi,
4. Modellerin tahmini,
5. Regresyon problemleri için tahminlerin ortalamasının alınarak genel tahmin değerinin elde edilmesi.

Arttırma yöntemi, yüksek önyargıya sahip modellerin birleştirilmesi için kullanılmaktadır. Bu yöntemde bireysel modellere göre daha düşük bir önyargıya sahip bir model elde etmeyi amaçlamaktadır. Yöntem, modellerin ardışık olarak eğitilmesini içermektedir. Bu yöntemde, her bir sonraki model, önceki modelin hatalarını düzeltmeyi hedeflemektedir. İlk modeli eğitmek için başlangıç veri setinden bir örnek alınmaktadır. Bu örnek, ilk modeli eğitmek için kullanılmaktadır. Örnekler doğru veya yanlış tahmin edilebilir. Yanlış tahmin edilen örnekler, bir sonraki modeli eğitmek için yeniden kullanılmaktadır. Bu şekilde, sonraki modeller önceki modellerin hatalarını geliştirebilmektedir.




Şekil 6. Torbalama yönteminin işlem adımları

Torbalama yönteminin aksine arttırma yöntemi, tahmin sonuçlarını her adımda ağırlıklı ortalama kullanarak birleştirmektedir. Ağırlıklı ortalama, tüm modellere tahmin gücüne bağlı olarak farklı ağırlıklar vermektedir. Başka bir deyişle, en yüksek tahmin

gücüne sahip modele daha fazla ağırlık verilmektedir. Bu, en yüksek tahmin gücüne sahip modelin en önemli olarak kabul edildiği anlamına gelmektedir.

Şekil 7’de Arttırma yönteminin işlem adımları verilmiştir;

1. Eğitim veri kümesinden m sayıda veri alt kümesinin oluşturulması,
2. İlk modelin eğitilmesi,
3. Modelin test edilmesi,
4. Yanlış tahmin edilen verilerin yeni veri alt kümesi ile beraber ikinci modelin eğitiminde kullanılması ve test edilmesi,
5. Veri alt kümesinin toplam sayısına ulaşana kadar işlem adımlarının tekrarlanması.



Şekil 7. Arttırma yönteminin işlem adımları

Optimize edilebilir artırma yöntemi, optimum performansa ulaşmak için hiperparametrelerin ayarının yapıldığı gelişmiş bir artırma türünü temsil eder. Bu süreç tipik çeşitli optimizasyon teknikleri kullanılarak belirli bir hiperparametre aralığı üzerinde sistematik bir aramayı içermektedir. Tez çalışmasında artırma topluluk yönteminin hiperparametrelerini ayarlamak için ızgara arama yöntemi (GSO) kullanılmıştır.

GSO, Bir makine öğrenimi modelinin hiperparametrelerini belirlemek için kullanılan bir yöntemlerden biridir. Hiperparametreler, modelin içinde bilinmeyen genellikle sonsuz sayıda olası değeri alabilen parametrelerdir ancak problem bilgisine dayanarak belirli aralıklarla sınırlandırılabilir. Böylece algoritmanın çalışma zamanı kısaltılabilmektedir. Bu


belirlenen aralıklardan seçilen belirli noktalar üzerinden hiper parametre değer listeleri oluşturulur. Bu algoritma, bu değer listelerinin tüm kombinasyonlarını içeren eğitim süreçlerini gerçekleştirir ve her kombinasyon için elde edilen sonuçları değerlendirerek en iyi hiper parametre kombinasyonunu seçer. GSO, her bir hiperparametre için belirli bir değer aralığı seçilmesini ve bu değerlerin kombinasyonlarından oluşan bir ızgara oluşturulmasını gerektirir. Izgara arama yöntemi, uygulaması kolay olup düşük boyutlu alanlarda etkili sonuçlar vermektedir (Tanyıldızı & Demirtaş, 2019).

Hiperparametreler ve optimize edilen aralıklar aşağıda verilmiştir (URL-2, 2024).

- Topluluk yöntemi , torbalama ve arttırma yöntemleri arasında seçim yapar.
- Minimum yaprak boyutu, gözlem sayısını ifade eden $[1, \max(2, \text{floor}(n/2))]$ aralıktaki logaritmik ölçekli tam sayılar arasında arama yapılır. Minimum yaprak boyutu, verideki daha karmaşık örüntüleri yakalayabilen daha derin ağaçları kullanır.
- Öğrenen sayısı, $[10, 500]$ aralığındaki logaritmik ölçekli tam sayılar arasında arama yapılır. Daha fazla öğrenici eklenmesi, modelin öğrenme kapasitesini artırmaktadır.
- Öğrenme oranı, $[0.001, 1]$ aralığındaki logaritmik ölçekli gerçek değerler arasında arama yapılır . Küçük bir öğrenme oranı, öğrenme sürecini yavaşlatmakta ve aşırı öğrenme riskini azaltarak daha optimal bir çözüm bulunmasına yardımcı olabilmektedir.
- Örneklenecek öngörücü sayısı, $[1, \max(2, p)]$ aralığındaki tam sayılar arasında arama yapar. Burada p , öngörücü değişkenlerin sayısıdır. Daha fazla tahmincinin örneklenmesi, varyansı azaltmakta ve modelin sağlamlığını artırmaktadır.

Stacking, güçlü modellerin tahmin doğruluğunu artırmak için kullanılan bir yöntemdir. Stacking yönteminde farklı modellerin tahminleri birleştirilmektedir. Ayrıca bu tahminler bir meta-model tarafından kullanılarak daha kesin bir tahmin yapılması sağlanmaktadır. Şekil 8’de yığma yönteminin işlem adımları verilmiştir.

1. Eğitim veri setini kullanarak m sayıda modelin eğitilmesi,
2. Her bir modelin tahmin çıktısını kullanarak yeni bir eğitim setinin oluşturulması ve yeni eğitim setinin kullanılarak bir meta-modelin eğitilmesi,
3. Meta-modelin tahmin sonuçlarının kullanılarak final tahmininin yapılması ve sonuçların ağırlıklı ortalama kullanılarak birleştirilmesi.



Şekil 8. Yığma (Stacking) yönteminin işlem adımları

1.4.2. Performans Değerlendirme Kriterleri

Karışıklık Matrisi (Confusion Matrix), sınıflandırma modellerinin performansını değerlendirmek için kullanılan en önemli metriktir. Tahmin edilen sınıf etiketlerini gerçek sınıf etiketleriyle karşılaştırarak her sınıf için doğru ve yanlış sınıflandırmaların sayısını göstermektedir. İkili sınıflandırma modeli için karışıklık matrisi ve bileşenleri Tablo 1’de verilmiştir (McElwee, 2018).

Tablo 1. İkili sınıflandırma modeli için Karışıklık Matrisi ve bileşenleri

	Tahmin Edilen Negatif	Tahmin Edilen Pozitif
Gerçek Negatif	TN	FP
Gerçek Pozitif	FN	TP

Bu değerler, modelin performansını değerlendirmek için kullanılmaktadır. TP: Doğru Pozitif, FP: Yanlış Pozitif, FN: Yanlış Negatif, TN: Doğru Negatif

Doğru Pozitif Oranı (TPR): Duyarlılık olarak da bilinen TPR, doğru pozitif örneklerin tespit edilme oranını temsil eder. Bu oran, Denklem (1)'de gösterildiği gibi hesaplanır;

$$TPR = \frac{TP}{TP + FN} \quad (1)$$

Doğruluk (ACC): Doğruluk, doğru sınıflandırılmış örneklerin toplam örnek sayısına oranıdır. Bu oran, Denklem (2)'de gösterildiği gibi hesaplanır;

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

Yanlış Pozitif Oranı (FPR): FPR, toplam negatif örnekler arasında yanlış pozitif örneklerin oranını temsil eder. Bu oran, Denklem (3)'de gösterildiği gibi hesaplanır;

$$FPR = \frac{FP}{FP + TN} \quad (3)$$

ROC (Receiver Operating Characteristic) eğrisi, farklı sınıflandırma skor eşiği değerleri için TPR ve FPR arasındaki ilişkiyi gösterir. ROC eğrisi, sınıflandırma problemlerinde önemli bir metriktir. ROC eğrisi, y ekseninde TPR 'yi ve x ekseninde FPR 'yi göstermektedir; eğri üzerindeki her nokta, örneklerin pozitif veya negatif olarak sınıflandırılması için farklı bir eşiği temsil etmektedir. ROC eğrisi altındaki alan (AUC), sınıflandırıcının ayırım gücünü ölçmek için kullanılan önemli bir metriktir. AUC değeri 0 ile 1 arasında değişir ve daha yüksek bir değer, daha iyi bir sınıflandırıcı performansını göstermektedir (Vujovici, 2021). Hassasiyet (Precision): Hassasiyet, doğru pozitif tahminlerin toplam tahminlere oranı olarak tanımlanır. Diğer bir deyişle, bir sınıflandırma modelinin yaptığı doğru pozitif tahminlerin oranını gösterir. Yüksek hassasiyet, düşük sayıda yanlış pozitif tahmin anlamına gelmektedir.

Bu oran, Denklem (4)'de gösterildiği gibi hesaplanır;

$$Kesinlik = \frac{TP}{TP + FN} \quad (4)$$

Duyarlılık (Recall): Duyarlılık, doğru pozitiflerin tespit edilme oranı olarak tanımlanır. Bir sınıflandırma modelinin doğru pozitif örnekleri doğru bir şekilde tespit etme oranını gösterir. Yüksek duyarlılık, düşük sayıda yanlış negatif anlamına gelir. Bu oran, Denklem (5)'de gösterildiği gibi hesaplanır;

$$FPR = \frac{TP}{TP + FN} \quad (5)$$

F1 Skoru: F1 skoru, hassasiyet ve duyarlılık metriklerinin harmonik ortalamasını temsil eden bir metriktir. Hem hassasiyet hem de duyarlılık metriklerini dikkate alarak bir modelin performansını değerlendirmek için kullanılır. F1 skoru, hem yanlış pozitiflerin hem de yanlış negatiflerin dengeli bir şekilde azaltılması gereken durumlarda özellikle kullanışlıdır. Bu oran, Denklem (6)'da gösterildiği gibi hesaplanır;

$$F1 \text{ skoru} = \frac{2 * Kesinlik * Geri \text{ çağırma}}{Kesinlik + Geri \text{ çağırma}} \quad (6)$$

Regresyon analizinde model performansını değerlendirmek için çeşitli kriterler kullanılır. Bunlar arasında en yaygın olanları Kök Ortalama Kare Hatası (RMSE), R^2 ve hatanın mutlak ortalaması (MAE) kriterleridir. Bu kriterler, modelin ne kadar iyi performans gösterdiğini ve tahminlerinin gerçek değerlere ne kadar yakın olduğunu ölçmek için kullanılır.

RMSE, bir modelin tahmin ettiği değerlerle gerçek değerler arasındaki ortalama hata miktarını ölçen bir metriktir. Bu metrik, hata karelerinin ortalamasını alıp karekökünü alarak hesaplanır. RMSE değeri ne kadar küçükse, modelin performansı o kadar iyidir. RMSE, özellikle büyük hataların model performansını nasıl etkilediğini görmek için kullanışlıdır, çünkü hataların karesi alındığından büyük hatalara daha fazla ağırlık verir. Bu değer, Denklem (7)'de gösterildiği gibi hesaplanır;

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i|^2} \quad (7)$$

Burada y_i gerçek değeri, $\tilde{y}_i$ tahmin edilen değeri ve n ise veri noktalarının sayısını temsil etmektedir.

R^2 , bir modelin bağımlı değişkendeki (y) değişkenliğin ne kadarını açıkladığını gösteren bir istatistiktir. R^2 değeri 0 ile 1 arasında değişir ve 1'e ne kadar yakınsa modelin o kadar iyi olduğunu gösterir. Yani, R^2 değeri yüksek olan bir model, veri noktalarının model üzerindeki

dağılımını daha iyi açıklayabilir. R^2 değeri, açıklanan varyans oranını gösterir. Bu oran, Denklem (8)'de gösterildiği gibi hesaplanır;

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

Burada $\bar{y}$ gerçek değerlerin ortalamasıdır.

MAE, tahmin edilen değerler ile gerçek değerler arasındaki ortalama mutlak farkı ölçen bir metriktir. MAE, hataların ortalama büyüklüğünü doğrudan gösterir ve hataların işaretini dikkate almaz. Bu değer, Denklem (9)'da gösterildiği gibi hesaplanır;

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (9)$$

Bu performans kriterleri, regresyon modellerinin doğruluğunu ve güvenilirliğini değerlendirmek için önemli araçlardır. Her biri farklı bir bakış açısı sunarak, modelin çeşitli yönlerden nasıl performans gösterdiğini anlamaya yardımcı olur. RMSE, büyük hataları vurgularken; MAE, ortalama hata büyüklüğünü doğrudan verir ve R^2 , modelin açıklayıcılığını gösterir (Hodson, 2022).

1.5. Matematiksel ve İstatistiksel Özellikler

Tez çalışmasında Örüntü analizi yöntemi ile öznitelik çıkarmak için kullanılan matematiksel ve istatistiksel özellikler aşağıda verilmiştir;

Ortalama Değer (Mean): Verilerin merkezi eğilimini temsil eden, tüm verilerin toplamının veri sayısına bölünmesiyle elde edilen değerdir. Bu değer, Denklem (10)'da gösterildiği gibi hesaplanır;

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (10)$$

Maksimum Değer: Veri setindeki en büyük değeri ifade eder. Bu değer, Denklem (11)'de gösterildiği gibi hesaplanır;

$$Maksimum_Değer = \max(X_i) \quad (11)$$

Standart Sapma (Standard Deviation): Verilerin ortalamadan ne kadar saptığını gösteren bir ölçüdür; düşük standart sapma, verilerin ortalamaya yakın olduğunu, yüksek standart sapma ise verilerin daha geniş bir alana yayıldığını gösterir. Bu değer, Denklem (12)'de gösterildiği gibi hesaplanır;

$$s = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (X_i - \bar{X})^2} \quad (12)$$

Pattern Genişliği: Pattern genişliği, akım örüntülerinin uzunluklarını ifade eder ve belirli bir veri dizisinin başlangıç ve bitiş indeksleri arasındaki farkla hesaplanmaktadır. Bu değer, Denklem (13)'de gösterildiği gibi hesaplanır;

$$Pattern_genişliği = start_{index} - end_{index} \quad (13)$$

Çarpıklık (Skewness): Verilerin simetrik olup olmadığını gösteren bir ölçüdür; pozitif çarpıklık, verilerin sağa, negatif çarpıklık ise sola çarpık olduğunu gösterir. Bu değer, Denklem (14)'de gösterildiği gibi hesaplanır;

$$\text{Çarpıklık} = \frac{1}{N} \sum_{i=1}^N \left(\frac{X_i - \bar{X}}{s} \right)^3 \quad (14)$$

Basıklık (Kurtosis): Verilerin keskinliğini veya basıklığını gösteren bir ölçüdür; yüksek kurtosis, verilerin keskin bir zirveye sahip olduğunu, düşük kurtosis ise daha basık bir zirveye sahip olduğunu belirtir. Bu değer, Denklem (15)'de gösterildiği gibi hesaplanır (Mutlag, 2020);


$$Basıklık = \frac{1}{N} \sum_{i=1}^N \left(\frac{X_i - \bar{X}}{s} \right)^4 \quad (15)$$

Enerji: Veri setinin genel gücünü veya büyüklüğünü temsil eden bir ölçüdür; genellikle sinyal işleme veya zaman-frekans analizlerinde kullanılır. Bu değer, Denklem (16)'da gösterildiği gibi hesaplanır;

$$Enerji = \sum_{i=1}^n |X_i|^2 \quad (16)$$

1.6. Ayırık Dalgacık Dönüşümü

Ayrık Dalgacık Dönüşümü (DWT), veriyi farklı ölçeklerde işleyerek frekans ve zaman domainlerinde çok çözünürlüklü analiz yapma olanağı sağlar. Bu yöntemle, sinyal belirli bir seviyede detay ve yaklaşım bileşenlerine ayrıştırılır, bu da sinyalin zaman ve frekansla ilgili özelliklerinin incelenmesini mümkün kılar. DWT'nin temel amacı, bir sinyali farklı frekans bantlarına ayrıştırırken her bant için zaman bilgisini korumaktır. Böylece, yüksek frekanslı bileşenlerdeki kısa zamanlı değişiklikler ile düşük frekanslı bileşenlerdeki uzun zamanlı değişiklikler analiz edilebilir. Yaklaşım katsayıları, sinyalin düşük frekanslı bileşenlerini temsil eder ve sinyal, düşük geçiren filtreden geçirilip ardından aşağı örneklenerek elde edilir. Detay katsayıları ise sinyalin yüksek frekanslı bileşenlerini temsil eder; bu bileşenler, sinyalin yüksek geçiren filtreden geçirilmesi ve ardından aşağı örneklenmesiyle elde edilir (URL-3, 2024). Bu işlemler, sinyalin farklı frekans bileşenlerinin ayrıntılı bir şekilde analiz edilmesini sağlamaktadır. Şekil 9' da üç seviyeli ayırık dalgacık dönüşümü verilmiştir.



Şekil 9. Üç seviyeli DWT

Düşük Geçiren Filtreleme ve Örnekleme:

$$A_{j+1}[k] = \sum_n x[n]xh[2k - n] \quad (17)$$


Yüksek Geçiren Filtreleme ve Aşağı Örnekleme:

$$D_{j+1}[k] = \sum_n x[n]xg[2k - n] \quad (18)$$

Her seviyede, sinyal ilk olarak alçak geçiren ve yüksek geçiren filtrelerden geçirilir ve ardından aşağı örnekleme yapılır. Bu işlem her seviye için tekrarlanır.


h yüksek geçiren filtreyi, g alçak geçiren filtreyi, $x[n]$ orijinal sinyali, $A_{j+1}[k]$ yaklaşım katsayılarını, $D_{j+1}[k]$ detay katsayılarını temsil etmektedir.

En yaygın bilinen dalgacık aileleri arasında haar, daubechies (db), symlets (sym), coiflets (coif), biorthogonal (bior), morlet, mexican ve Discrete Meyer (dmey) bulunmaktadır. Şekil 10'da dalgacık ailesinden birkaç örnek verilmiştir.



Şekil 10. Dalgacık ailesinden örnekler (Budu, 2014).

Tez çalışmasında db dalgacık ailesine ait sonuçlar alınmıştır. Bu dalgacıklar, ortogonalite ve kompakt destek özellikleri nedeniyle sinyal işleme alanında yaygın olarak kullanılır. Her ayrıştırma seviyesi, daha ayrıntılı bir frekans çözünürlüğü sağlar. Ancak çok fazla seviye, hesaplama karmaşıklığını ve veri boyutunu artırmaktadır. Çoğu pratik uygulama için beş seviye genellikle yeterlidir. 1. seviye detay katsayıları, sinyalin en yüksek frekans bileşenlerini yakalar ve en hızlı değişiklikleri temsil eder. Bu bileşenler, farklı sinyal türlerini ayırt etmek için kritik öneme sahiptir. Şekil 11’de db dalgacık ailesine ait örnekler verilmiştir.



Şekil 11. Db dalgacık ailesine ait örnekler (Gupta, 2014).

Tez çalışmasında db18 ve db10 ailesi 1.seviye katsayıları ile en iyi sonuçlar elde edilmiştir. Bunun başlıca nedeni aşağıdaki gibi sıralanabilir;

1. En yüksek frekans bileşenleri, sinyaldeki en hızlı değişimleri temsil eder. Bu bileşenler, farklı sinyal türleri arasındaki farkları belirlemede önemlidir.
2. 1. seviye detay katsayıları, sinyaldeki geçici olayları veya ani değişiklikleri yakalamada etkilidir.
3. Daha yüksek frekans bileşenleri, sinyalin geniş bir spektrumunu analiz etme ve daha fazla bilgi çıkarma imkanı sağlar.
4. Yüksek dereceli daubechies dalgacıkları, polinomsal eğilimlere sahip sinyalleri daha iyi temsil edebilir ve daha düzgün yeniden yapılandırmalar sağlar.

1.7. The Fast Walsh-Hadamard Dönüşümü (FWHT)

Hızlı Walsh-Hadamard Dönüşümü (FWHT), Walsh-Hadamard Dönüşümü'nün hesaplama karmaşıklığını azaltmak amacıyla geliştirilmiş genelleştirilmiş bir Fourier Dönüşümü versiyonudur. FWHT, bir sinyali, non-sinusoidal ve ortogonal bir dönüşüm tekniği kullanarak bir dizi temel fonksiyona ayırmaktadır.

FWHT dönüşüm matrisi, hem zaman hem de frekans bilgilerini içeren Walsh fonksiyonlarından oluşur. Walsh fonksiyonları yalnızca +1 veya -1 değerlerini alır. Sonuç olarak, FWHT dönüşüm matrisi (H_n), Walsh fonksiyonlarından oluşan bir Hadamard dönüşüm matrisidir. Hadamard dönüşümleri, aynı zamanda Walsh dönüşümleri veya Walsh-Fourier dönüşümleri olarak da bilinmektedir.

Hadamard dönüşümü, boyut-2 ayrık Fourier dönüşümlerinin birleşiminden oluşan bir dönüşümdür ve aslında $2 \times 2 \times 2 \times \dots \times 2 \times 2 \times 2$ boyutunda çok boyutlu bir Ayrık Fourier Dönüşümü'ne eşdeğerdir. Bu özellik, Hadamard dönüşümünün hızlı bir şekilde hesaplanmasını sağlar (URL-4, 2024). N uzunluğundaki bir $x(t)$ sinyali için FWHT, Denklem (19)'da tanımlanmaktadır:

$$y_n = \frac{1}{N} \sum_{i=0}^{N-1} x_i WAL(n, i) \quad (19)$$

FWHT, sinyal işleme ve veri sıkıştırma gibi birçok alanda kullanılan etkili bir dönüşüm yöntemidir. FWHT algoritması, sinyalin boyutunu yarıya indirerek ve giderek daha küçük FWHT'ler hesaplayarak çalışır. Bu böl ve fethet yaklaşımı, algoritmanın hesaplama karmaşıklığını önemli ölçüde azaltır. WHT, sinyal işleme, veri sıkıştırma, veri analizi ve spektral analiz gibi birçok uygulamada frekans bilgisi elde etmek için kullanılabilir.

Walsh-Hadamard matrisi n dereceli olarak özyinelemeli (rekürsif) şekilde Denklem (20) ve Denklem (21)'de tanımlanmaktadır;

$$H_1 = [1] \quad (20)$$

$$H_{2n} = \begin{bmatrix} H_n & H_n \\ H_n & -H_n \end{bmatrix} \quad (21)$$

Örneğin, 2 ve 4 dereceli Walsh-Hadamard matrisleri Denklem (22) ve Denklem (23)'de verilmiştir;

$$H_{2n} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \quad (22)$$


$$H_4 = \begin{pmatrix} 1 & 1 & 1 & 1 \\ 1 & -1 & 1 & -1 \\ 1 & 1 & -1 & -1 \\ 1 & -1 & -1 & 1 \end{pmatrix} \quad (23)$$

Bir uzunluğu $N=2^n$ olan x vektörünün FWHT'sini hesaplamak için, vektör özyinelemeli olarak bölünür ve Walsh-Hadamard matrisleri kullanılarak birleştirilir (Okumus, 2022).

1.8. Asenkron Motorun Dinamik Modeli

Asenkron motorların matematiksel modellenmesinde, keyfi (dq) döner referans çerçevesi basitleştirilmiş bir yaklaşım sunmaktadır. Bu yöntem, sistemin istenen herhangi bir hızda dönebilen bir referans çerçevesinde çalıştığını varsayar. Bu dönüşüm, zamanla değişen katsayılar tanıtarak diferansiyel denklemleri basitleştirmektedir (URL-5, 2023). Şekil 12'de dq-çerçevesi için eşdeğer devre modeli tanımlanmış olup, semboller için açıklamalar Tablo 2'de verilmiştir.

Denklemler, stator voltajları q-ekseni için Denklem (24), d-ekseni için Denklem (25), rotor voltajları q-ekseni için Denklem (26), d-ekseni için Denklem (27) ve elektromanyetik tork için Denklem (28)'de verilmiştir.



Şekil 12. Keyfi bir referans çerçevesinde asenkron motorun eşdeğer devre modeli

Tablo 2. Model Denklemlerinde Kullanılan Semboller

V_{qs}, I_{qs}	Stator q-eksenindeki voltaj
V_{ds}, I_{ds}	d-eksenindeki stator voltajı ve akımı
V'_{qr}, I'_{qr}	q-eksenindeki rotor voltajı ve akımı
V'_{dr}, I'_{dr}	d-eksenindeki rotor voltajı ve akımı
R_s, R_r	Stator ve rotor direnci
w, w_r	Elektriksel açısal hızlar
ϕ_{ds}, ϕ_{qs}	Stator q-eksenindeki ve d-eksenindeki akılar
ϕ'_{ds}, ϕ'_{qs}	Rotor q-eksenindeki ve d-eksenindeki akılar
T_e	Elektromanyetik tork

$$V_{qs} = R_s I_{qs} + \frac{d}{dt} \phi_{qs} + w \phi_{ds} \quad (24)$$

$$V_{ds} = R_s I_{ds} + \frac{d}{dt} \phi_{ds} + w \phi_{qs} \quad (25)$$

$$V'_{qr} = R'_r I'_{qr} + \frac{d}{dt} \phi'_{qr} + (w - w_r) \phi'_{dr} \quad (26)$$

$$V'_{dr} = R'_r I'_{dr} + \frac{d}{dt} \varphi'_{dr} + (w - w_r) \varphi'_{qr} \quad (27)$$

$$T_e = 1.5(\varphi_{ds} I_{qs} - \varphi_{qs} I_{ds}) \quad (28)$$

Simülasyon çalışmalarında, 1.5 kW, 4 kW, 7.5 kW, 15 kW ve 22 kW olmak üzere farklı güçlere sahip asenkron pompa motorlarının modelleri kullanılmaktadır. Bu motorlara ait elektriksel parametreler ayrıntılı olarak Tablo 3'da sunulmuştur.

Tablo 3. Asenkron Motorların Elektriksel Parametreleri


Güç (kW)	1.5	4	7.5	15	22
Hız (rpm)	1428	1430	1440	1460	1440
Frekans (Hz)	50	50	50	50	50
Stator Akımı (A)	3.64	9	16	31	44
Stator Direnci (Ω)	4.85	1.405	0.7384	0.2147	0.12
Rotor Direnci (Ω)	3.805	1.395	0.7402	0.2205	0.18
Stator Endüktansı (L)	0.274	0.005839	0.003045	0.000991	0.12
Rotor Endüktansı (L)	0.274	0.005839	0.003045	0.000991	0.12
Ortak Endüktans (Lm)	0.258	0.1722	0.1241	0.06419	0,0035
Kutupların sayısı	2	2	2	2	2
Eylemsizlik Momenti (kg/m ²)	0.031	0.0131	0.0343	0.102	0.33
Sürtünme Katsayısı (Nm.s/rad)	0.00114	0.002985	0.000503	0.009541	0.02791

1.8.1. Motor Kalkış Akımı

Bir asenkron motorunun başlangıç akımı, motor ilk kez çalıştırıldığında kısa bir süre için meydana gelen çok yüksek bir akımdır. Bu akım genellikle motorun nominal tam yük akımının 5-7 katına kadar çıkabilmektedir ve rotor henüz hareket etmeye başlamadığında meydana gelmektedir. Rotor hareket etmeye ve hız kazanmaya başladığında ani akım hızla azalmakta ve motor normal çalışma akımı seviyesine ulaşmaktadır. Bu işlem genellikle birkaç saniye sürer. Yüksek ani akımın nedeni, motor hareketsizken stator sargıları

aracılığıyla bir manyetik alan oluşturmaması ve rotorun henüz bu manyetik alana karşı bir karşıt elektromotor kuvvet oluşturmamış olmasıdır. Bu durum çok yüksek bir başlangıç akımının çekilmesine neden olur ve bu da motorun bağlı olduğu elektrik şebekesinde önemli gerilim düşüşlerine yol açmaktadır. Başlangıç akımının olumsuz etkilerini azaltmak için çeşitli yol verme yöntemleri kullanılsa da, tarımsal sulamada kaçak elektrik kullanımı yapan pompa motorlarının genellikle doğrudan hat yol verme yöntemiyle devreye alındığı tespit edilmiştir. Bu yöntem motorun hızlı ve doğrudan başlatılmasını kolaylaştırır, ancak yüksek akım nedeniyle şebekeyle ilgili sonuçları da beraberinde getirmektedir. Şekil 13'de üç fazlı motor-pompa sisteminin gerçek zamanlı üç fazlı başlangıç akım grafiğini göstermektedir. Grafiği incelediğimizde, pompa çalıştırıldığında mevcut bir şebeke yükünün bulunduğu gözlemlenmektedir. 0,3 saniye noktasında motor-pompa sistemi aktif hale gelmekte ve A fazının pik akım değeri 180 Amper'e ulaşmaktadır. 0,6. saniyede motorun başlatma süresi tamamlanmakta ve motor nominal akım değerine ulaşmaktadır. Bu süre içerisinde motor yükü ve şebekedeki diğer yüklerin akım bilgisi de bulunmaktadır.


Asenkron motorlar tarafından tahrik edilen dalgıç su pompaları, tarımsal sulamada yaygın olarak kullanılmaktadır. Pompa kısmı, asenkron motora yük torkunu sağlar. Bu tez çalışmasında, debi, statik basınç ve basma yüksekliği gibi pompa karakteristiklerine odaklanmak yerine, asenkron motordan elde edilen elektriksel karakteristikler üzerinde durulmuştur. Pompa karakteristiklerindeki değişiklikler, asenkron motor üzerinde farklı yük torklarına neden olduğundan, veri setinde bu değişikliklere karşılık gelen farklı tork değerleri kullanılmıştır.



Şekil 13. Motor-pompa sisteminin gerçek zamanlı üç faz başlangıç akım grafiği

1.9. Literatür Araştırması

NTL üzerine yapılan literatür çalışmaları Şekil 14’de verildiği gibi dört ana kategoriye ayrılmaktadır: oyun teorisi tabanlı yöntemler, deterministik yöntemler, donanım tabanlı yöntemler ve makine öğrenimi tabanlı yöntemler.



Şekil 14. NTL üzerine yapılan literatür çalışmalarının gruplanması

Elektrik hırsızlığının tespiti, oyun teorisi perspektifinden ele alınabilmektedir. Bu yaklaşım, enerji şirketleri ile elektrik hırsızları arasındaki etkileşimleri analiz etmek için oyun teorisi ilkelerini ve tekniklerini kullanmaktadır. Wei ve arkadaşları, Benford yasasını kullanarak akıllı sayaç verilerinde şüpheli olarak işaretlenen verileri analiz etmektedir. Şebeke ve birden fazla hırsızlık yeri arasındaki stratejik etkileşimleri incelemek için bir Stackelberg oyun modeli oluşturmuşlardır. Stackelberg dengesini sağlamak için örneklem oranı ve eşiği belirlemek üzere bir olasılık oranı testi kullanılmıştır. Önerilen yöntem, dört hırsızlık senaryosu için gerçek kullanım verilerine karşı doğrulanmış ve her bir akıllı sayaç için %95'in üzerinde hırsızlık tespit oranı elde edilmiştir (Wei, Sundararajan, Sarwat, Biswas, & Erfan, 2017).

Cardenas ve arkadaşları, elektrik hırsızlığı tespiti ve koruma önlemlerinin bir dağıtım şirketinin maliyeti üzerindeki etkilerini incelemeyi mümkün kılan bir model önermişlerdir. Bu amaçla, dağıtım şirketi ile müşteriler arasında bir oyun formüle etmişlerdir ve bu oyunun Nash dengesini, bir olasılık yoğunluk fonksiyonu olarak belirlemişlerdir. Oyun teorisine dayalı yaklaşımlar, dağıtım şirketi ile müşteriler arasındaki olası stratejileri ve etkileşimleri anlamakta yararlıdır, ancak bu aktörlerin hepsini kapsayan uygulanabilir bir model geliştirmek güçtür (Cárdenas, Amin, Schwartz, Dong, & Sastry, 2012).

Deterministik yöntemler kullanarak elektrik hırsızlığını tespit eden ve yerleştiren çalışmalar da mevcuttur. Uvais, bir kontrolör tabanlı tespit ve lokalizasyon sistemi

önermektedir. Dağıtım trafosunun besleyici çıkışlarından ve ev sayaçlarından alınan voltaj ve akım ölçümleri toplanmaktadır. Sayaçlardan toplanan veriler, dağıtım hattındaki voltaj düşüşü ve akımla birlikte, devre kesicileri etkinleştirerek elektrik hırsızlığının yeri deterministik bir yöntem ile belirlenmektedir. Ancak, bu çalışmanın sadece basit bir simülasyon ortamında gerçekleştirilmesi ve devre kesicilerin etkinleştirildiğinde diğer abonelere potansiyel zarar vermesi, sistemin sahada uygulanmasını zorlaştırmaktadır (Uvais, 2020) .

Raza ve arkadaşları, elektrik hırsızlığını tespit etmek ve yerini belirlemek için etkili bir strateji önermektedir. Bu çalışmada, birden fazla trafonun bulunduğu bir dağıtım hattı modeli kullanılmıştır. Hırsızlığı tespit etmek için, dağıtım trafosu fiderlerinin gerçek voltajları AMI'den toplanmaktadır. Trafoların voltajları da simüle edilen sistemden hesaplanmaktadır. Ölçülen voltajlar gerçek voltajlarla karşılaştırılmakta ve herhangi bir noktadaki fark ortalama farkı aştığında elektrik hırsızlığı tespit edilmekte ve yeri belirlenmektedir. Önerilen algoritmada NTL hesaplamak için güç akış analizi yapılmaktadır. Ancak, bu algoritmanın tek trafolu düşük voltaj dağıtım şebekesine uygulanması, doğru güç akış analizi ve NTL hesaplamaları yapamadığı için zordur (Raza, Imran, Khattak, Ulasayr, & Ilyas, 2021) .

Metaliya ve arkadaşları, düğümlerdeki voltaj farklarına ve hat parametrelerine dayalı deterministik bir yöntem önermektedir. Önerilen yöntem, IEEE 33 dağıtım sisteminde uygulanmış ve çeşitli çalışma koşullarında tatmin edici sonuçlar elde edilmiştir. Ancak çalışma simüle edilmiş veriler kullanmakta olup, sahada test edilmemiştir (Metaliya & Deshpande, 2021).

Komolafe ve arkadaşları, bir dağıtım şebekesinde elektrik hırsızlığını tespiti ve lokasyonu için basit bir deterministik yöntem önermektedirler. Önerilen yöntemde, branş dirençleri bir ara bellekte depolanmakta ve dirençler, düğümler ve direklerin voltaj farkları kullanılarak lokalizasyon tespiti sağlanmaktadır. Yöntem, Nijerya'nın Ekong Uko Caddesi'ndeki bir dağıtım ağına uygulanmış ve elektrik hırsızlığının yeri %94 doğrulukla tespit edilmiştir (Komolafe & Udofia, 2020).

Dasgupta ve arkadaşları, bir dağıtım hattında güç hırsızlığının lokasyon tespiti için bir algoritma önermektedirler. Algoritmanın ana gereksinimi, dağıtım hattının düğümlerinde veya transformatörlerinde voltaj ölçüm cihazlarının kullanılmasıdır. Önerilen yöntemde, ardışık düğümler arasındaki voltaj büyüklüğü farkı kullanılmaktadır. Bu yöntemin iki farklı varyasyonu önerilmiştir. İlk yöntem, ardışık düğümler arasındaki voltaj ölçüm farkını

kullanırken, ikinci yöntem normalleştirilmiş voltaj farkı çifti tekniğini kullanmaktadır. Her iki yöntemde de, istatistiksel bir yaklaşım kullanılarak, özellikle Mahalanobis mesafesi ölçümü ile anomali değer tespiti yapılmaktadır. Önerilen yöntemin başlıca avantajı, yalnızca voltaj ölçümlerine dayanması ve ağ parametrelerine ihtiyaç duymamasıdır. IEEE 34 test şebekesi üzerinde yapılan simülasyonlar, önerilen yöntemin etkinliğini göstermiştir (Dasgupta, Padmanaban, & Hazra, 2017).

Hasan ve arkadaşları, bir dağıtım hattındaki düğümlerde meydana gelen elektrik hırsızlığı olaylarını tespit ve lokasyonu için voltaj profillerine dayanan basit bir yaklaşım sunmaktadırlar. Önerilen metodoloji, ağdaki tüm düğümlerden 15 dakikalık voltaj büyüklüğü profillerini kullanmakta ve bu voltaj profilleri arasındaki istatistiksel farklılıkları tespit etmek için bir yaklaşım önermektedir. Voltaj profilleri üzerinde Welch t-testi uygulanmakta ve her düğüm için p-değerleri elde edilmektedir. P-değerleri önceden belirlenmiş bir eşik değeriyle karşılaştırılarak eşik değerden daha düşük p-değerine sahip düğümler belirlenmektedir. En küçük p-değerine sahip düğüm, hırsızlık olayının meydana geldiği düğüm olarak belirlenmektedir. Bu algoritmayı değerlendirmek için 59 düğümlü bir test ağı kullanılmış ve sonuçlar, önerilen yaklaşımın elektrik hırsızlığının meydana geldiği düğümü makul bir doğrulukla belirleyebildiğini göstermektedir (Hasan, Rahman, Islam, & Yusuf, 2023).

Kim ve arkadaşları, güç akışını detaylı bir şekilde analiz etmek ve NTL'leri etkin bir şekilde tespit etmek için ara ölçüm monitörlerine dayalı bir akıllı güç dağıtım ağı modeli önermiştir. Donanım mimarisi tanımlanmış ve toplayıcılar arasında oluşturulan denge doğrusal denkleminde dayanan bir NTL tespit algoritması geliştirilmiştir. Elektrik hırsızlığına karşı tüketiciler için bir dürüstlük katsayısı belirlenmiştir. Simülasyon sonuçları, önerilen NTL tespit algoritmasının %95 doğruluk oranına ulaştığını göstermektedir (Kim, Sun, Sim, Kim, & Wang, 2019).

Donanım tabanlı yöntemler, belirli ekipmanlara dayalı olarak elektrik hırsızlığını tespit etmeye yönelik koruma cihazları geliştirmeye veya algoritmalar tasarlamaya odaklanmaktadır.

Engelbrecht ve arkadaşları, gerçek zamanlı ölçümler ile voltaj ve akım tespit devresi tarafından kaydedilen tahmini değerler arasındaki sapmaları karşılaştırarak elektrik hırsızlığı yapan kullanıcıları tespit eden bir anomali tespit cihazı önermektedir. İzleme ve kontrol cihazlarının dağıtım maliyetlerini azaltmayı amaçlayan çalışmalar da bulunmaktadır. Bir dağıtım şebekesine Fider Uzaktan Terminal Üniteleri (FRTU) veya Dijital Koruyucu Röleler

gibi akıllı izleme ve kontrol ekipmanlarının kurulması, enerji hırsızlığını tespit etmenin etkili bir yoludur (Engelbrecht, Hancke, & Osifeko, 2019).

Liao ve arkadaşları, dağıtım hattında FRTU'ların stratejik olarak konuşlandırılmasını önermektedir. Enerji kullanımı anormallikleri tüketici faturalama merkezlerinden tespit edilebilmektedir. Dağıtılabilecek FRTU sayısı bütçe kısıtlamaları ile sınırlı olsa da, önerilen algoritma, farklı zaman dilimlerinde FRTU'ların kurulumu için kritik yerleri belirlemektedir. Simülasyon sonuçları, önerilen çok aşamalı yöntemi kullanarak altyapı iyileştirmelerinin uygulanmasının, dağıtım sistemleri için yatırım planlamasını artırdığını göstermektedir (Liao, Ten, & Hu, 2013).

Donanım tabanlı çözümler, ek sensörler, ölçüm cihazları ve izleme ekipmanları gerektirdiğinden, yüksek maliyetlidir. Bu maliyetler, dağıtım şirketleri için önemli bir finansal yük oluşturabilmektedir.

Makine öğrenimi tabanlı yöntemler, anormal elektrik tüketim davranışlarını tespit etmek için müşterilerin tarihsel güç tüketim verilerini ve diğer dış verileri analiz etmektedir. Bu tez çalışmasındaki literatür incelemesi, makine öğrenimi tabanlı yöntemler üzerine yoğunlaşmıştır. Literatürde, enerji hırsızlığını tespit etmek için akıllı sayaç tüketim verilerini kullanarak kötü niyetli tüketicileri belirlemeye yönelik önemli makine öğrenimi çalışmaları bulunmaktadır.

Jindal ve arkadaşları, Karar Ağacı (DT) ve SVM sınıflandırıcılarının kullanıldığı hibrit bir yöntem sunmaktadır. Hane halkı büyüklüğü, mevsim, zaman dilimi ve sıcaklık gibi çeşitli özellikler DT'ye giriş olarak sağlanmaktadır. DT algoritması, bir tüketici için belirli bir süre boyunca beklenen elektrik tüketimini hesaplamaktadır. SVM sınıflandırıcısı, hane büyüklüğü, mevsim, zaman dilimi, sıcaklık, beklenen elektrik tüketimi ve gerçek elektrik tüketim değerleri gibi girdileri almaktadır. SVM sınıflandırıcısı, tüketicileri normal veya hırsız olarak sınıflandırmaktadır. Sonuçlar, önerilen yöntemin %92,5 doğruluk oranı ve %5,12 düşük yanlış pozitif oranı ile hırsız tüketicileri tanımlamada başarılı olduğunu göstermektedir (Jindal, ve diğerleri, 2016).

Buzau ve arkadaşları, akıllı sayaç verilerini ve coğrafi lokasyon gibi ek bilgileri kullanarak anormal elektrik tüketim davranışlarını analiz eden denetimli öğrenme tabanlı bir yöntem önermektedir. Ayrıca, İspanya'nın önde gelen şirketi Endesa tarafından sağlanan gerçek bir veri seti kullanılarak, XGBoost yönteminin k-En Yakın Komşular (kNN), SVM ve Doğrusal Regresyon (LR) yöntemlerinden daha iyi performans gösterdiği görülmüştür (Buzau, Tejedor-Aguilera, Cruz-Romero, & Gómez-Expósito, 2019).

Handique ve Das, normal şartlarda farklı yükler altında bir ANN modeli eğitmiştir. SM elektrik parametreleri model için giriş verisi olarak kullanılmaktadır. Bu model, farklı yükler altında güç tahmini yapmakta ve tahmin edilen güç değeri ile gerçek güç değerini karşılaştırarak elektrik hırsızlığını tespit etmektedir (Handique & Das, 2019). Khan ve arkadaşları, akıllı şebekelerde elektrik hırsızlarını etkili bir şekilde tespit etmek için hibrit bir derin öğrenme modeli sunmaktadır. İlk olarak, akıllı sayaç verilerinden veriyi temizlemek için ön işleme teknikleri kullanılmaktadır. Daha sonra, AlexNet gibi özellik çıkarma teknikleri boyutsallık sorununu ele almaktadır. Önerilen yöntemin etkinliği, akıllı sayaçlardan elde edilen gerçek veri seti kullanılarak yapılan simülasyonlarla değerlendirilmiştir. Çeşitli karşılaştırma modelleri de performans analizini yapmak için uygulanmıştır. Önerilen model, doğruluk, hassasiyet, duyarlılık ve F1 değerlerinde sırasıyla %86, %89, %86 ve %84 değerlerine ulaşmıştır (Khan, Raza, Ara, & Bouzguenda, 2023).

Gündüz ve arkadaşları, 2104 konut kullanıcılarından alınan gerçek elektrik tüketim verilerine dayalı CNN tabanlı modeller kullanarak enerji hırsızlığını tespit etmeye çalışmaktadır. Modeller, kullanıcıların hem normal kullanım hem de kötü niyetli enerji tüketim desenlerini tahmin etmeye çalışmaktadır. CNN, tüketici davranışları içindeki saldırı desenlerini tanımlamak için kullanılmaktadır. Özellikle, normal kullanım örneklerden kötü niyetli enerji tüketim desenlerini oluşturmak için altı saldırı vektörü kullanılmaktadır. Daha sonra CNN tabanlı dedektörler enerji hırsızlığını tespit etmek için önerilmektedir. Ayrıca, GAN algoritması dengelenmemiş veri sorununu ele almak için kullanılmaktadır. CNN tabanlı modellerle beraber, SVM, RF, LR, KNN ve DT gibi makine öğrenimi algoritmaları beraber kullanılarak sonuçlar elde edilmiştir. Sonuçlar, önerilen CNN+LR ve CNN+RF modellerinin enerji hırsızlığını tespit etmek için çok umut verici sınıflandırma yöntemleri olduğunu göstermektedir (Gunduz & Das, 2024).

Jokar ve arkadaşları, AMI tüketim desenlerine dayalı bir enerji hırsızlığı tespit sistemi önermişlerdir. Bunun için SVM kullanılarak %94 sınıflandırma doğruluğu elde edilmiştir (Jokar, Arianpoo, & Leung, 2016). Gunturi ve arkadaşları, DT ve SVM kullanarak iki aşamalı bir enerji hırsızlığı tespit sistemi sunarak %92,5 doğruluk elde etmişlerdir. Ancak, çalışmada, veri setinin dengeli olup olmaması hakkında bir bilgi verilmemiştir (Gunturi & Sarkar, 2021). Alromih ve arkadaşları, simüle edilmiş veriler kullanılarak yapay sinir ağları ile %93 tespit oranı elde etmiştir (Alromih, J Clark, & Gope, 2021). Souza ve arkadaşları, dağıtım sistemlerinde enerji hırsızlığını tespit etmek için Çok Katmanlı Algılayıcı Yapay Sinir Ağı (MP-ANN) kullanılarak ortalama %93,4 tespit oranı elde etmişlerdir (Souza M. ,

ve diğerleri, 2020). Ancak, bu çalışmada da veri setinin dengeli olup olmadığı hakkında bilgi verilmemiştir. Ullah ve arkadaşları, CNN, kapılı tekrarlayan birimler (GRU) ve PSO'yu birleştiren hibrit bir derin sinir ağı (DNN) yaklaşımı önermiştir (Ullah, Javaid, Samuel, Imran, & Shoaib, 2020). Nabil ve arkadaşları, GRU sınıflandırıcı kullanılarak %93 tespit oranı elde etmiştir. Ancak veri seti dengesi belirtilmemiştir (Nabil, Ismail, Mahmoud, Shahin, & Qaraqe, 2018). Zheng ve arkadaşları, konvolüsyonel uzun kısa süreli hafıza (ConvLSTM) modeli kullanılarak %98 doğruluk oranı elde etmişlerdir (Zheng, Yang, Niu, Dai, & Zhou, 2018).

Lin ve arkadaşları, güç tüketiminin zaman serisi verilerinden elektrik hırsızlığı yapan kullanıcıları tespit etmek amacıyla uyarlanabilir bir zaman serisi tekrarlayan sinir ağı modeli önermektedir. Modelin eğitimi için, Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE) algoritması kullanılarak sanal hırsızlık verisi üretilmiştir. Model, optimize edilerek 47 gerçek anormal örneği tahmin etmek için kullanılmış ve sadece üç örnek yanlış tahmin edilmiştir. Bu sonuçlar, modelin elektrik hırsızlığını tespit etmedeki etkinliğini ortaya koymaktadır (Lin, ve diğerleri, 2021).

Kawoosa ve arkadaşları, tüketicilerin elektrik tüketim kalıplarını analiz ederek Aşırı Gradyan Artırma (XGBoost) algoritmasını kullanan yeni bir elektrik hırsızlığı tespit modeli önermişlerdir. Veriyi dengelemek ve hırsızlık ve hırsızlık olmayan veri örneklerinin eşit dağılımını sağlamak için altı farklı sentetik hırsızlık saldırısı kullanılmıştır. Ayrıca, sınıflandırmada XGBoost algoritmasının kullanımı, özellikle elektrik hırsızlığı vakalarını tespit etmede, az sayıda yanlış pozitifle kayda değer doğruluk oranları göstermiştir. Önerilen model, bölgesel elektrik tüketim parametrelerini ve diğer değişkenleri giriş özellikleri olarak kullanarak bölgesel elektrik hırsızlığını tanımlamaktadır. Elde edilen sonuçlar, k-neural ağları, hafif gradyan artırma, rastgele orman, destek vektör makinesi, karar ağacı ve AdaBoost gibi diğer yöntemlerle kıyaslanmış çok daha üstün bir başarı elde edilmiştir. Yapay saldırı senaryoları kullanılarak yapılan simülasyon sonuçları, modelin performansını iyileştirmiş ve doğruluk, hatırlama ve F1 skorlarının sırasıyla %96, %95 ve %95 olduğunu göstermiştir. Tespit oranı ve yanlış pozitif oranı sırasıyla %96 ve %3 olarak elde edilmiştir (Kawoosa, Prashar, Faheem, Jha, & Khan, 2023).

Petrlik ve arkadaşları, makine öğrenimini kullanarak elektrik hırsızlığı için en iyi tahmin modelini önermeyi amaçlamaktadır. 42.372 tüketicinin elektrik tüketim verileri, Çin Devlet Şebeke Şirketi tarafından yayınlanan bir veri kümesinden alınmıştır. Metodoloji, verinin tamamlanması, veri dengesinin sağlanması (aşırı örnekleme ve eksik örnekleme) ve

hırsızlık tespitini iyileştirmek için özellik çıkarımını içermektedir. Beş makine öğrenme modeli test edilmiştir ve SVM modeli en yüksek doğruluğu %81 ile elde etmiştir, ardından K-En Yakın Komşular %79, Rastgele Orman %80, Lojistik Regresyon %69 ve Naive Bayes %68 ile takip etmiştir. Çalışma, SVM modelinin %81 doğruluk ile en iyi performansı sergilediği sonucuna varmaktadır (Petrlik Azabache, ve diğerleri, 2022).

Appiah ve arkadaşları, akıllı şebekelerde elektrik hırsızlığını etkili bir şekilde tespit etmek için aşırı rastgele ağaç sınıflandırıcı kullanan bir tespit modeli sunmaktadır. Veri sınıf dengesizliğini ele almak için SMOTE Tekniği kullanılmış ve önerilen modelin hiperparametrelerini optimize etmek için GSO kullanılmıştır. Önerilen model, doğruluk, Matthew's korelasyon katsayısı, tespit oranı, doğruluk, F1 skoru ve ROC eğrisi altındaki alan değerleri sırasıyla %98, %95.06, %98, %97, %98 ve %99.65 oranları ile elektrik hırsızlığını tespit etme yeteneğini göstermektedir (Appiah, Akowuah, Ikpo, & Dede, 2023).

Bir başka çalışmada Zarkovic ve arkadaşları, elektrik tüketim ölçümlerini kullanarak enerji hırsızlığını tespit etmek için kullanılan metodolojilerin kapsamlı bir incelemesini sunmaktadır. Bu araştırma, ANN, ANFIS, otoencoder sinir ağları ve K-means kümeleme gibi çeşitli yapay zeka algoritmalarının pratik uygulamalarını vurgulamaktadır. Gerçek dağıtım ağlarından doğrudan elde edilen veriler kullanılmaktadır. ANN, farklı tüketici türlerini %7.62 hata ile doğru bir şekilde tanımlamaktadır. Buna karşılık, K-means algoritması %9.26 hata ile biraz daha yüksek bir hata göstermektedir, adaptif sinir-bulanık çıkarım sistemi ANFIS ise başlangıçtaki anomali türünü tespit edememiş ve %11.11 hata ile sonuçlanmıştır. Araştırma, yapay zeka algoritmalarının elektrik tüketimindeki düzensizlikleri tespit etmede daha etkili hale getirebileceğini göstermektedir. Bu yaklaşım, özellikle SM'den elde edilen verilerle birleştiğinde, dağıtım ağlarını korumaya ve sorunları tanımlamaya yardımcı olabileceği düşünülmektedir (Žarković & Dobrić, 2024).

Pereira ve arkadaşları, elektrik hırsızlığının tespiti ve dengesiz veri işleme teknikleriyle ilgili çeşitli makine öğrenme yöntemlerinin karşılaştırmalı bir analizini sunmaktadır. Analiz, veri kümesinin dengesiz sınıflara sahip olduğunu ortaya koymakta ve bu soruna yönelik çoğu çalışmanın dengeleme tekniklerini kullanmadığını göstermektedir. Ağırlıklandırma, RUS, ROS, K-medoids, SMOTE ve CBOS gibi teknikler ve LR, RF, SVM ve ANN gibi makine öğrenme yöntemleri karşılaştırılmaktadır. Sonuçlar, SMOTE ve ANN'nin en iyi AUC ve F1-skor değerlerini elde ettiğini, bu metriklerin dengesiz sınıflar için daha uygun olduğunu göstermektedir. RF ile CBOS kombinasyonu da iyi sonuçlar

vermiştir. Çalışmanın bulguları, elektrik hırsızlığını tespit etmek için veri işleme teknikleri ve makine öğrenme yöntemleri sunmaktadır (Pereira & Saraiva, 2020).

Yang ve arkadaşları, tüketici enerji kullanım davranışlarını incelemek ve anomali katsayılarını belirlemek için iki doğrusal regresyon tabanlı algoritma önermektedir. Bu algoritmalar, yasadışı kullanım yapan SM'leri tespit edebilmektedir. Ayrıca, enerji hırsızlığının zamanlarını ve yerlerini belirlemek için kategorik değişkenler ve tespit katsayıları belirlenmiştir. Bu amaçla, İrlanda'da 5.000'den fazla konut ve ticari mülkten yarım saatlik enerji kullanım verileri kullanılmıştır. Simülasyon sonuçları, önerilen algoritmaların yasa dışı enerji tüketiminde bulunan tüm tüketicileri başarıyla tespit ettiğini ve sahte akıllı sayaçları tanımladığını göstermektedir (Yang, ve diğerleri, 2022).

Son yıllarda, Bitcoin'in değerinin artmasıyla birlikte, Bitcoin madencileri arasında elektrik hırsızlığı vakaları ortaya çıkmıştır. Kang ve arkadaşları, bitcoin madencilerinin güç tüketim özelliklerini analiz etmeyi ve bir veri toplama sistemi aracılığıyla güç tüketim davranışlarını izlemeyi amaçlamaktadır. Çalışma, voltaj ve güç gibi elektriksel miktarların karşılaştırmalı analizini gerçekleştirmektedir. Önerilen algoritma Pearson korelasyonuna dayanmaktadır. Her müşterinin elektrik tüketimi ile hat kaybı istatistikleri arasındaki Pearson korelasyon katsayısı hesaplanmaktadır. Çok küçük bir örneklem olan sadece 16 kullanıcı üzerinde yapılan çalışma, kullanıcıların %62.50'sinin anormal güç tüketimi sergilediğini bulmuştur. Bu nedenle, bu araştırmanın ekonomik faydaları önemlidir (Kang, Shang, Zhang, & Liao, 2022).

Biswas ve arkadaşları, elektrik hırsızlığını, doğrusal olmayanlık varsayımını veya saldırı modları için herhangi bir eğitim maliyeti gerektirmeyen bir zaman serisi korelasyon analizi problemi olarak formüle etmektedir. Tüketicilerin elektrik tüketim kalıplarından şüphe seviyesi değerlendirmek için iki katsayı tanımlanmıştır. Bu katsayılar 0.60 ile 0.86 arasında belirlenmiştir. Tüketiciler, tüketim kalıpları ile dağıtım hattındaki teknik olmayan kayıplar arasındaki korelasyona dayalı olarak tanımlanmaktadır. 5 dakikalık UMass Akıllı veri kümesi üzerinde korelasyon analizi gerçekleştirilmiştir. Gerçek veri kümesi üzerindeki çeşitli saldırı türleri ile kapsamlı deneyler, önerilen tekniklerin tespit hassasiyetini önemli ölçüde artırdığını göstermektedir (Biswas, ve diğerleri, 2020).

Bian ve arkadaşları, LSTM ve dikkat mekanizması ile parçacık sürü optimizasyonunu kullanarak yasadışı tüketim yapan tüketicileri tanımlamak için bir model sunmaktadır. Veri kümesi, Massachusetts Üniversitesi tarafından sağlanan halka açık bir veri setinden saatlik sıcaklık, nem ve vücut sıcaklığı verilerini içermektedir. Sonuçlar, RMSE, MAE, MAPE gibi

metrikler kullanılarak değerlendirilmektedir. MAPE değeri %0.087, MAE %0.152 ve RMSE %0.186 olarak belirlenmiştir. Elde edilen sonuçlar CNN-LSTM, LSTM, GRU, SVM, RF ve LR gibi yöntemlerle karşılaştırılmaktadır (Bian, ve diğerleri, 2021).

Souza ve arkadaşları, IEEE70 test dağıtım ağına dayalı sentetik bir veri kümesinde kendiliğinden SOM ve çok katmanlı algılayıcı yapay sinir ağları MP-ANN kombinasyonunu kullanarak yasadışı tüketim yapan tüketicileri tanımlamak için bir yöntem önermektedir. İki aşamalı yöntemde, ilk aşama, SOM kullanarak günlük yük çizelgesi için karakteristik gruplar temelinde tüketicileri sınıflandırmaktadır. İkinci aşamada, ayrı gruplar üzerinde eğitilen MP-ANN, şüpheli enerji tüketicilerini tanımlamaktadır. Deneylerden elde edilen performans metrikleri şu şekildedir: DR (Tespit oranı): %93.4, FPR: %1.9. Bu sonuçlar, önerilen yöntemin şüpheli tüketicileri tanımlamadaki başarısını göstermektedir. SOM ve MP-ANN kombinasyonu, tüketici davranışını anlamak ve güvensiz tüketicileri tespit etmek için etkili bir yöntem olduğunu kanıtlamaktadır (Souza M. , ve diğerleri, 2020).

Jiang ve arkadaşları, LSTM ve CNN algoritmalarına dayanan yeni bir elektrik hırsızlığı tespit modeli önermişlerdir. Bu yöntem, kullanıcı yük verilerinden güç tüketim özelliklerini çıkaran CNN-LSTM algoritmasına dayanmaktadır. CNN, özellik çıkarımı için kullanılırken, LSTM sınıflandırma için kullanılmıştır. Akıllı sayaç verilerinden elde edilen elektrik tüketim davranışlarından özellik vektörlerinin çıkarılarak modeller eğitilmektedir. Algoritma, elektrik hırsızlığını tespit etmede %94 doğruluk oranı sergilemektedir (Jiang, Xu, Jiang, & Zhang, 2022).

Sim ve arkadaşları, akıllı dağıtım sistemlerinde elektrik hırsızlığını tespit ve lokalizasyonu için CNN tabanlı bir yöntem önermişlerdir. Elektrik hırsızlığının yaygın bir yöntemi, SM'i manipüle ederek gerçek kullanımdan daha düşük tüketim göstermelerini sağlamaktır. Önerilen yöntem, SM ve gözlemci sayaçlardan elde edilen verileri birleştirmektedir. Gözlemci sayaçlardan sayaçlarından elde edilen veriler, belirli bir bölgenin elektrik tüketimini temsil etmektedir. Girdinin uzaysal eksenini oluşturmak için 2D görüntüler oluşturulmakta ve bu görüntüler CNN algoritmasına giriş olarak verilmektedir. Önerilen yöntem SimBench veri kümesi kullanılarak değerlendirilmiştir. Sonuçlar, yöntemin elektrik hırsızlığını tespitinde %0.99 AUC ve %0.96 F1 skoru elde ettiğini göstermiştir (Sim, Lee, & Shin, 2023).

Lepolesa ve arkadaşlarının yaptığı çalışmada, elektrik hırsızlığını tespit etmek için derin sinir ağı tabanlı bir sınıflandırma yaklaşımı önerilmiştir. Bu yaklaşım, zaman ve frekans alanlarında elde edilen özellikleri kullanmaktadır. Önerilen yöntem SGCC (Çin

Devlet Şebeke Şirketi) tarafından yayınlanan gerçekçi bir elektrik tüketim veri kümesine uygulanmaktadır. Bu veri kümesi, Ocak 2014 ile Ekim 2016 arasında toplanan günlük elektrik tüketim verilerini içermektedir. Veri kümesindeki eksik veri ve sınıf dengesizliği gibi sorunları ele almak için veri interpolasyonu ve sentetik veri üretim teknikleri kullanılmıştır. Bayes optimizasyonu kullanılarak hiperparametreler optimize edilmiştir, bu da elektrik hırsızlığını tespit etme performansını artırmıştır. Elde edilen sonuçlara göre, doğruluk oranı %91.8 ve AUC oranı %97 olarak belirlenmiştir (Lepolesa, Achari, & Cheng, 2022).

El-Toukhy ve arkadaşlarının yaptığı bir çalışmada, akıllı güç şebekelerinde elektrik hırsızlığını tespit etmek için derin pekiştirmeli öğrenme yöntemleri araştırılmıştır. Çalışma, müşteri elektrik tüketim okumalarının gerçek değerlerini içeren bir veri kümesi kullanmıştır. Eğitim sırasında tespit hatalarına dayalı olarak ödüller verilmiştir. Altı farklı saldırı fonksiyonu, siber saldırılar oluşturmak için yapay olarak üretilmiştir. Önerilen yaklaşım çeşitli senaryolarda değerlendirilmiş ve performans açısından, pekiştirmeli öğrenme tabanlı DQN ve DDQN yöntemleri, derin öğrenme tabanlı modellere kıyasla üstün sonuçlar göstermiştir. Ayrıca, müşteri tüketim kalıplarındaki değişiklikler incelenmiş ve sonuçlar, tüketim kalıplarındaki değişikliklerden önce ve sonra benzer performans elde edildiğini göstermektedir. Ayrıca, önerilen tespit modelinin yeni siber saldırıları öğrenebildiği ve yeni bir siber saldırı meydana geldiğinde yüksek doğruluk elde edebildiği gösterilmiştir (El-Toukhy, Srivastava, Fouda, & Alsabaan, 2023).

Gabriel ve arkadaşları, manipüle edilen sayaçların tespiti ve lokalizasyonu için Süper Durumlu Gizli Markov Modelleri tabanlı kapsamlı bir yaklaşım sunmuşlardır. Önerilen yöntem, SM manipülasyonunu tespit etmekle birlikte, aynı zamanda hangi sayaçların manipüle edildiğini de belirlemektedir. Bu yöntem, tüketicilerin tüketim profillerine dayanmaktadır. Araştırmada iki farklı veri kümesi kullanılmaktadır: Elektrik Tüketimi ve Konut (ECO) veri kümesi ve Birleşik Krallık Evleri için Kişiselleştirilmiş Yenileme Karar Destek Araçları (REFIT) veri kümesi. Sonuçlar, 50 W'ı aşan manipülasyonların doğru bir şekilde tespit edilebildiğini göstermektedir (Gabriel, Matthes, Keller, & Hagenmeyer, 2019).

Luya ve arkadaşları, akıllı sayaç verilerini kullanarak doğrusal regresyon tabanlı bir algoritma önermektedirler. Bir doğrusal regresyon modeli, akıllı sayaçlardan ve bir dağıtım transformatöründen elde edilen voltaj ve güç ölçümleri kullanılarak müşteri güç tüketimini tahmin etmek için oluşturulmuştur. Tahmin edilen güç tüketimi ile gerçek sayaç okuması arasında eşik tabanlı bir kontrol uygulanmakta, böylece anormal tüketimi olan sayaçlar tespit

edilebilmektedir. Algoritma, enerji hırsızlığı yapan müşterilere ait sayaçların tespit edilmesini ve yasa dışı tüketimin boyutunun belirlenmesini sağlamaktadır (Luya & Angelo Pedrasa, 2019).

Kara ve arkadaşları, günlük elektrik tüketim verilerinin analizine dayalı olarak elektrik hırsızlığı vakalarını tespit etmek için üç farklı makine öğrenme modelini eğitmiştir. Bu modeller, LightGBM, XGBoost ve CatBoost olmak üzere karar ağaçlarına dayalı modellerdir. Modeller, günlük tüketici elektrik kullanımını yasal veya yasa dışı tüketim olarak sınıflandırmaktadır. Çalışmada, Çin Devlet Şebeke Şirketi tarafından yayınlanan bir akıllı sayaç veri kümesi kullanılmıştır. Sonuçlar, CatBoost modelinin diğer modellere kıyasla üstün bir performans sergilediğini ve %78.10 doğruluk ve %74.17 AUC değeri elde ettiğini göstermektedir. LightGBM modeli ayrıca %72.48 duyarlılık sergilemektedir (Kara & Aksu, 2023).

Haq ve arkadaşları, tüketicilerin güç tüketim verilerini kullanarak enerji hırsızlığını tespit etmek için derin öğrenme tabanlı bir model sunmaktadır. CNN modeli, bir ön işleme tekniği uygulandıktan sonra güç tüketim veri kümesi üzerinde eğitilmiştir. Deneysel sonuçlar, derin CNN modelinin önceki modellerden daha iyi performans sergilediğini ve enerji hırsızlığını tespit etmede yüksek doğruluk sağladığını göstermektedir (Haq, Pei, Zhanga, Jianjunb, & Ahmad, 2023).

Zheng ve arkadaşları, elektrik hırsızlığını ve gerçekleştiği zaman dilimlerini tanımlamak için Çok Görevli Derin Artık Ağ önermektedir (Zheng, Yang, Niu, Dai, & Zhou, 2018).

Chandel ve arkadaşları, tüketim verilerindeki anormallikleri sınıflandırmak için CNN ve çift yönlü LSTM ağlarının bir kombinasyonunu kullanarak akıllı sayaçlarla elektrik hırsızlığını tespit etme yöntemi önermektedir (Chandel & Thakur, 2019).

Markovska ve arkadaşları, elektrik tüketim verilerini sınıflandırmak için Yönlendirilmiş Zaman Konvolüsyonel Ağ tabanlı bir yöntem önermektedir ve yüksek sınıflandırma performansı göstermektedir (Markovska, Gerazov, Zlatkova, & Taskovski, 2023). Farid ve arkadaşları, SGCC verisetini kullanarak elektrik hırsızlığının etkilerini araştırmak için CNN'leri ve Uzaysal Dönüşüm Ağlarını birleştiren hibrit bir sınıflandırıcı kullanmaktadır (Farid, Iltaf, & Afzal, 2023).

Zhang ve arkadaşları, veri ön işleme ve hiperparametre optimizasyonuna odaklanan optimize edilmiş bir derin öğrenme modeli sunmaktadır (Zhang, Wang, Liu, Li, & Li, 2023).

Gelişmiş sinyal işleme ve özellik çıkarma yöntemleri, AMR sistemlerinde anormallik tespitini iyileştirmede özellikle etkilidir.

Janthong ve arkadaşları, üç fazlı bir sistemde voltaj ve akım büyüklüklerini kullanarak anormallik tespitinde Pade, Prony, Shank, otokorelasyon ve kovaryans tekniklerini kullanmışlardır. Prony yöntemi ve kNN algoritması en iyi sınıflandırma sonuçlarını elde etmiştir (Janthong, Chalermyanont, & Duangsoithong, 2023).

Li ve arkadaşları, elektrik tüketim zaman serisi verilerinde anormal kullanıcıları tespit etmek için özelleştirilebilir bir zaman serisi tekrarlayan sinir ağı yöntemi önermektedir. Sentetik anormal veriler, sentetik SMOTE kullanılarak oluşturulmuştur (Li, ve diğerleri, 2022).

Liu ve arkadaşları, birden fazla fiyatlandırma şeması kullanarak gizli elektrik hırsızlığı saldırılarını kolaylaştırmayı araştırmış ve bu saldırıların etkinliğini maksimize etmek için optimizasyon problemleri önermiştir (Liu, Liu, Sun, Zhang, & Liu, 2020).

Fei ve arkadaşları, NTL tespiti için karşıt öngörücü kodlama (ND-CP) olarak bilinen kendinden gözetimli bir tespit yöntemi önermektedir. Akıllı sayaç veri dizileri ilk olarak bir boyutlu evrişimsel sinir ağına (1D-CNN) beslenmektedir. Ardından, kapılı tekrarlayan birim (GRU) verileri kullanılarak global bilgiler çıkarılmaktadır. Sonrasında, GRU modelinden elde edilen tahmin çıktısı, karşıt öğrenme için pozitif ve negatif örnek çiftleri oluşturmak amacıyla kullanılmaktadır. Son olarak, ND-CP tarafından çıkarılan uzun vadeli özellikleri kullanarak bir katmanlı sinir ağı sınıflandırıcısı eğitilmektedir. Önerilen yöntemin etkinliğini doğrulamak için gerçek elektrik tüketim verileri ile deneyler yapılmıştır (Fei, Li, Zhu, Dong, & Li, 2022).

Sajad ve arkadaşları, Pakistan'da elektrik hırsızlığını incelemiş ve akıllı sayaçların şebeke modernizasyonunda kullanımını araştırmıştır. Bu amaçla, ekonomik akıllı sayaç geliştirmeye odaklanarak şebeke modernizasyonu için bir akıllı sayaç geliştirmişlerdir (Ali, Yongzhi, & Ali, 2023).

Dengelenmiş veri işleme, elektrik hırsızlığını tespit etmek için kullanılan makine öğrenimi modellerinin performansını önemli ölçüde artırmaktadır. Janthong ve arkadaşları, voltaj ve akım büyüklüklerini kullanarak dengesiz verileri işlemek için bir teknik sunmaktadır. Çalışma, üç yöntemi benimsemiştir: adaptif sentetik örnekleme, görüntü veri artırma ve dengeleme modelleri (Janthong, Chalermyanont, & Duangsoithong, 2023).

Oprea ve arkadaşları, Tunus'taki elektrik tüketim verilerinde analitik fonksiyonlar kullanarak dolandırıcılığı tespit ederek AUC puanında önemli bir artış elde etmiştir. Bu

yaklaşımlar, elektrik hırsızlığını tespitte özellikle duyarlılık, hassasiyet ve doğruluğu artırmada etkilidir (Oprea & Adela, 2022).

Literatürdeki bazı çalışmalarda elektrik hırsızlığı, anomali çalışması olarak ele alınmıştır. Zideh ve arkadaşları, fiziksel sistem kısıtlamalarını makine öğrenme modellerine entegre eden Fizik Destekli Makine Öğrenmesi yöntemini kullanmıştır. Bu yöntem, model çıktılarının sistemin fiziksel yasalarına uymasını sağlamak için fizik tabanlı kayıp fonksiyonları ve fizik destekli sinir ağlarını kullanmaktadır. Bu entegrasyon, modelin genelleme yeteneğini ve bilimsel tutarlılığını artırmakta ve güç sistemlerinde anomali tespiti ve lokalizasyon için özellikle etkili hale getirmektedir (Zideh, Chatterjee, & Srivastava, 2024).

Zhang ve arkadaşları, yük tüketim profillerinde anomali tespiti için zaman serisi yöntemlerinin önemini vurgulamaktadır. Çalışmaları, ARIMA modelleri ile sinir ağlarının kombinasyonunun hem uzun vadeli tahmin doğruluğunu hem de anomali tespit performansını artırdığını göstermektedir. Bu hibrit modeller, doğrusal olmayan tüketim kalıplarını etkili bir şekilde yakalamakta ve normal ile anormal davranışlar arasındaki farkı belirlemektedir (Zhang, Wu, & Boulet, 2021).

Passerini ve arkadaşları, akıllı şebekelerde anomali tespiti için güç hattı modemlerinin potansiyelini incelemektedir. Çalışmaları, güç hattı modemi sistemlerinde iletişim ve algılama doğruluğu arasındaki dengeyi tartışarak pilot tabanlı ve yansıma algılama yöntemleriyle anomalileri tahmin etme tekniklerine odaklanmaktadır (Passerini & Tonello, 2019).

Madabhushi ve arkadaşları, makine öğrenme yaklaşımları, zaman serisi analizi ve kümeleme teknikleri dahil olmak üzere güç şebekelerine uygulanan çeşitli anomali tespit yöntemlerinin kapsamlı bir incelemesini sunmaktadır. Çalışmaları, ağın istikrarını sağlamak için sağlam tespit mekanizmalarının gerekliliğini vurgulamaktadır (Madabhushi & Dewri, 2023).

Chu ve arkadaşları, doğruluk artırmak için anomali tespiti ve kümelemeye dayalı bir yöntem önermektedir. Voltaj dizisi benzerliğini ölçmek için dinamik zaman bükme kullanılırken, yerel aykırı değer faktörü anomali tespiti için kullanılmaktadır. Kümeleme, faz bilgilerini belirlemektedir ve Çin'de yapılan vaka çalışmaları ile doğrulanmıştır. Sonuçlar, doğruluğun ve uyarlanabilirliğin arttığını göstermektedir (Chu, ve diğerleri, 2022).

Yu ve arkadaşları, enerji elektroniği ağlarındaki anomalileri hızlı ve kesin bir şekilde tanımlamak için yeni bir katmanlı renkli düğüm graf algoritması sunmaktadır. Algoritma,

ilişkili dalga formlarının ve sensörlerin analizinde son derece verimli olacak şekilde tasarlanmıştır (Yu, ve diğerleri, 2022).

Duan , güç dağıtım sistemlerinde anomalileri tespit etmek için Transformer-GAN modelini sunmaktadır. Bu model, Transformer ağlarının ve GAN'ların güçlü yönlerini birleştirerek tespit doğruluğunu, genelleme yeteneğini ve dayanıklılığını artırmaktadır. Önerilen model, %95.18 doğruluk oranı elde etmektedir. Ayrıca, %96.64 AUC değeri, normal ve anormal kalıplar arasında etkili bir şekilde ayırım yapma konusundaki etkinliğini göstermektedir (Duan, 2024).

Dağıtım ağına yapılan bir siber saldırı, önemli sonuçlar doğurabilmektedir. Bu tür saldırılar, yaygın elektrik kesintilerine, temel hizmetlerin kesintiye uğramasına, ekonomik kayıplara ve toplumsal huzursuzluğa yol açabilmektedir.

Alasali ve arkadaşları, AGŞ'leri hedef alan siber saldırıların potansiyel etkilerini incelemektedir. Bu amaçla, ETAP yazılımı kullanılarak 5MW güneş enerjisi sistemleri içeren bir ağ modeli oluşturulmuştur. Üç farklı saldırı senaryosu analiz edilmiştir: ağ kaynağına saldırı, fotovoltaik bağlantısının kesilmesi ve yük bağlantısının kesilmesi. Bu araştırma, AGŞ'lerde siber saldırıların sonuçlarını, dağıtılmış enerji kaynakları dahil olmak üzere kapsamlı bir şekilde değerlendirmektedir. Ağ kaynaklarının %50 kaybı senaryosunda, bara voltajları %0.10 ile %0.12 arasında düşmüştür. Yük kaybının %25 olduğu senaryoda, voltaj %0.60 birim artmış, trafo kayıpları azalmış, ancak kablo kaynaklarındaki kayıplar artmıştır. PV sistemi olmadan, güneş sistemi optimal bara voltaj seviyelerini korumuş ve trafo kayıplarını azaltmış, ancak bağlantı kesildikten sonra kablo kayıpları artmıştır (Alasali, ve diğerleri, 2023).

Bhusal ve arkadaşları, dağıtık jeneratörlere sahip dağıtım sistemlerindeki koordineli voltaj düzenleme şemalarının kontrol sistemlerine yönelik koordineli veri sahtekarlığı saldırılarını tespit etmek, yerleştirmek ve farklılaştırmak için iki aşamalı bir makine öğrenme yaklaşımı geliştirmiştir. İlk aşamada, bir rastgele orman regresyon modeli, belirli bir an için voltaj büyüklüklerini tahmin etmektedir. Model, geçmiş voltaj ölçümleri ve meteorolojik veriler kullanılarak eğitilmiştir. İkinci aşamada, lojistik regresyon modeli tespit ve yerleştirme için kullanılmaktadır. Bu, modelin tahmin edilen voltajı ile gerçek zamanlı ölçülen voltajın karşılaştırılmasını içermektedir. Önerilen yöntemin performansı, ABD'deki 240 düğümlü gerçek dağıtım sistemi ve IEEE 123 düğümlü dağıtım sistemi üzerinde doğrulanmıştır. Sonuçlar, bu yöntemin %1 kadar küçük sapmalarla düşük marjlı saldırıları

%99'a kadar doğrulukla tespit edebileceğini göstermektedir (Bhusal, Gautam, & Benidris, 2021).

Akıllı şebekelerde sürdürülebilir taşımacılık için elektrikli araçların artan kullanımı, dağıtım şebekesinin siber saldırılara karşı savunmasızlığı konusundaki endişeleri artırmıştır.

Mokarim ve arkadaşları, düşük voltajlı dağıtım ağı üzerindeki bu tür saldırıların etkisini analiz etmeyi amaçlamaktadır. IEEE Avrupa Düşük Voltaj Test Besleyicisi, standart model olarak kullanılmakta ve sonuçlar değerlendirilmiştir. Sonuç olarak, Avrupa çapında bir bağlamda elektrikli araç şarj istasyonlarına yapılan bir siber saldırının sonuçları, simülasyon sonuçları kullanılarak analiz edilmiştir. Özellikle, bu sonuçlar, aşırı güç emilimi durumunda özel koruma cihazlarının arızalanmasını ve ağ ekipmanlarının zarar görmesini içermektedir (Mokarim, Gaggero, & Marchese, 2023).

Long ve arkadaşları, dağıtım sistemi durum tahmini temel alınarak bir siber giriş tespit yöntemi sunmaktadır. Yöntem, dağıtım ağındaki belirsizlikleri her bir durum değişkeninin aralığı ile temsil etmektedir. Önerilen model, IEEE 33 bus ve 123 bus sistemlerine uygulanmıştır. Elde edilen sonuçlar, önerilen yöntemin geçerliliğini doğrulamak için Monte Carlo ve Gauss eliminasyon algoritması sonuçları ile karşılaştırılmıştır. Bu karşılaştırmalar, önerilen yöntemin etkinliğini ve doğruluğunu göstermektedir (Long, ve diğerleri, 2020).

Li ve arkadaşları, dağıtım hatlarında siber saldırıların uyarlanabilir hiyerarşik tespiti ve lokalizasyonu için bir sistem önermektedir. Bu amaçla, derin öğrenme modeli eğitilmiştir. Bu makalede, aktif bir dağıtım ağına meydana gelen siber saldırıları simüle etmek için FDI (Sahte Veri Enjeksiyonu) saldırısı modellenmiştir. IEEE 37 düğümlü modeline dayalı güneş çiftliklerine sahip bir akıllı şebeke örneği simüle edilmiştir. Algoritma, önce siber saldırı alt bölgesini tahmin etmekte, ardından tahmin edilen alt bölge içinde belirli siber saldırının yerini belirlemektedir. Önerilen yöntem, 0 db Gauss beyaz gürültüsü varlığında bile %70 lokalizasyon doğruluğu sağlamaktadır (Li, ve diğerleri, 2022).

Leite ve arkadaşları, NTL'leri tespit etmek için voltaj ve akım değişimlerini izleyen çok değişkenli bir kontrol grafiğine dayalı bir yöntem önermektedir. Bu çalışmanın temel amacı, farklı türde siber saldırılar nedeniyle oluşan NTL'leri belirlemek ve yerini tespit ederek etkin bir metodoloji geliştirmektir. Bu amaçla, enerji hırsızlığının gerçekleştiği tüketim noktasını belirlemek için A-Yıldız algoritmasına dayalı bir yol bulma yöntemi kullanılmakta ve siber saldırıdan etkilenen hedef tüketim noktasını görselleştirmek için coğrafi bilgi sistemi uygulaması ile entegre edilmektedir. Sayısal sonuçlar, gerçek bir

dağıtım ağını izlemek için uygulandığında önerilen metodolojinin etkinliğini göstermektedir (Leite & Mantovani, 2018).

Yenilikçi makine öğrenimi ve siber güvenlik teknikleri, akıllı şebeke altyapısını giderek daha karmaşık siber tehditlere karşı korumak için hayati öneme sahiptir.

Gabriel ve arkadaşları, süper durum gizli Markov modelleri kullanarak sayaç manipülasyonunu tespit etmek ve potansiyel olarak manipüle edilmiş sayaçları belirlemek için merkezi bir ölçüm cihazı ile birleştirilmiş yeni bir tespit yöntemi önermiştir (Gabriel, Matthes, Keller, & Hagenmeyer, 2019).

Achaal ve arkadaşları, akıllı şebeke bileşenlerini ve iletişim bağlantılarını analiz ederek olası siber tehditleri tanımlamış ve şebeke güvenliğini artırmak için önlemler önermiştir. Bu çalışmalar, akıllı şebeke altyapısını korumada gelişmiş makine öğrenimi ve siber güvenlik tekniklerinin kritik önemini vurgulamaktadır (Achaal, Adda, Berger, Ibrahim, & Awde, 2024).

Makine öğrenimi tabanlı tespit yöntemleri, çeşitli saldırı türleriyle mücadelede de önemlidir.

Takiddin ve arkadaşları, basit ve karmaşık saldırıların etkilerini değerlendirirken, özellikle hızlı gradyan işaret, temel iteratif yöntem ve kNN yöntemi ile veri saldırılarını incelemiştir. Makine öğrenimi tabanlı tespit modellerinin veri saldırılarına karşı etkinliğini değerlendirmişlerdir (Takiddin, Ismail, & Serpedin, 2022). Najafzadeh ve arkadaşları, kripto para madenciliği abonelerinin yasa dışı elektrik tüketimini tespit etmek için makine öğrenimi teknikleri, sinir ağları ve destek vektör makineleri gibi çeşitli yöntemleri araştırmıştır (Najafzadeh & Gholami, 2022).

Deng ve arkadaşları, koordine edilmiş siber-fiziksel saldırıları tespit etmek ve yerini belirlemek için yeni bir yaklaşım önermiştir. Hibrit ve ensemble modeller, elektrik hırsızlığını tespitinde doğruluk ve dayanıklılığı önemli ölçüde artırmaktadır (Deng, Zhuang, & Liang, 2017).

Ali ve arkadaşları, izinsiz tüketimi tespit etmek için regresyon model geliştirme ve olasılık yoğunluk fonksiyonu oluşturma gibi istatistiksel ve makine öğrenimi tabanlı bir yaklaşım sunmaktadır (Ali, Mokhtar, & Shaaban, 2022).

Dağıtım şebekesinde yasa dışı enerji tüketimi dışında enerji kaybına neden olan farklı anomali çalışmalarında bulunmaktadır. Arıza tespiti bu çalışmaların önemli bir kısmını oluşturmaktadır. Senemmar ve arkadaşları, gemi güç sistemlerinde arıza tespiti, sınıflandırma ve lokalizasyon için derin öğrenme tabanlı yenilikçi bir yöntem önermektedir.

Bu amaçla, derin sinir ağı, kapılı tekrarlayan birim ve LSTM olmak üzere üç farklı ANN tabanlı arıza tespit yöntemi geliştirilmiş ve yöntem sonuçları karşılaştırılmıştır. Geliştirilen modellerde, güç sistemlerindeki bus noktalarının hat voltajları giriş verisi olarak kullanılmıştır. Eğitim ve test verileri için 8 bus bir güç sistemi simüle edilmiştir. Sonuçlar, tüm yöntemlerin arıza tespiti, sınıflandırma ve lokalizasyon açısından %99'un üzerinde doğruluk elde ettiğini göstermektedir. Ayrıca, yük varyasyonları ve gürültünün modellerin performansı üzerindeki etkileri analiz edilmiştir. Modellerin, yük varyasyonlarına ve gürültülü girdilere karşı yüksek doğrulukla arızaları tespit edebildiği, sınıflandırabildiği ve lokalizasyon tespitini yapabildiği gösterilmiştir (Senemmar & Zhang, 2021).

Sharma ve arkadaşları, iletim hatlarında meydana gelen farklı güç sistemi arızalarını tespit etmek ve sınıflandırmak için bir teknik sunmaktadır. Faz-toprak, faz-faz, faz-faz-toprak arızaları dikkate alınmıştır. Veri örnekleme frekansı 2 kHz olarak belirlenmiştir. Arıza sınıflandırması için kural tabanlı karar ağacı kullanılmıştır. Bu çalışmada, A fazındaki akımın diferansiyel değeri alınmış ve elde edilen tepe değerleri, sınıflandırma için kural tabanlı karar ağacına giriş olarak kullanılmıştır. Simülasyon çalışması için MATLAB/Simulink kullanılmış ve önerilen yöntemin farklı arıza türlerini etkili bir şekilde tespit edip sınıflandırdığı sonucuna varılmıştır (Sharma, Mahela, Kumar, & Kumar, 2018).

Wasnik ve arkadaşları, etiketli ve etiketlenmemiş verileri verimli bir şekilde işleyen yarı denetimli bir öğrenme algoritması sunmaktadır. Bu çalışmada, arıza tespiti ve sınıflandırma, KNN modeli kullanılarak gerçekleştirilmiştir. Arıza senaryoları MATLAB/Simulink ortamında oluşturulmuş ve giriş verisi olarak anlık akım değerleri ölçülmüştür. Her etiketli örnek ile yeni veya etiketlenmemiş örnek arasındaki mesafe hesaplanmış ve minimum mesafeye sahip k etiketli noktaya karşılık gelen arıza sınıfı belirlenmiştir. Simülasyonda çeşitli arıza lokasyonları ve dirençler dikkate alınarak elde edilen veriler zenginleştirilmiştir. Önerilen yöntem, iletim hattı arızalarını tespit etme ve sınıflandırmada %97 doğruluk sağlamaktadır (Wasnik, Phadkule, & Thakur, 2019).

Mohajer ve arkadaşları, dağıtık jeneratörlere sahip dağıtım ağlarında arıza yerini tespit etmek için yeni bir teknik önermektedir. Simülasyonlar PSCAD ve MATLAB'da gerçekleştirilmiş ve sonuçlar elde edilmiştir. Bu yöntem için, besleyicinin başlangıcındaki ve dağıtık terminallerdeki voltaj ve akım bilgileri kullanılmıştır. Lokalizasyon, bir optimizasyon problemi olarak ele alınmış ve genetik algoritma kullanılmıştır. Önerilen yöntemin tek hat-toprak arızaları için maksimum hatası %0.66 olarak belirlenmiştir (Mohajer & Sadeh, 2022).

Okumus ve arkadaşları, Trabzon ilinde bulunan Akyazı-Düzköy dağıtım besleyicisinde meydana gelen arızaları tespit edip sınıflandırmışlardır. Besleyici, Digsilent Powerfactory kullanılarak modellenmiştir. İlk olarak, modelin doğrulanması için yük akışı ve kısa devre analizleri yapılmıştır. Ardından, faz akımına dalgacık dönüşümü uygulanmış ve elde edilen katsayıların enerji değeri alınarak arıza tespiti ve sınıflandırması gerçekleştirilmiştir. Modelde çeşitli lokasyonlarda farklı kısa devre arızaları oluşturulmuş ve yöntemin başarısı analiz edilmiştir. Sonuçlar, kısa devre arızalarının ve lokasyonlarının başarıyla tespit edilebildiğini göstermektedir (Okumus & Nuroglu, 2019).

Caporuscio ve arkadaşları, dağıtım güç sistemleri için veri odaklı bir toprak arızası yer tespit yöntemi sunmaktadır. 11 bus içeren 20 kV'lik bir güç sistemi Matlab/Simulink'te modellenmiş ve toprak arızaları simüle edilmiştir. Arızalar farklı lokasyonlarda ve çeşitli sistem operasyonel durumlarında oluşturulmuştur. Üç fazlı voltaj bilgilerini içeren bir veri kümesi, ANN eğitmek için kullanılmıştır. Sonuçlar, yöntemin arıza mesafesi tahmini için %0.4 hata oranı elde ettiğini göstermektedir (Caporuscio, Dupuis, & Löwe, 2023).

Sapountzoglou ve arkadaşları, besleyici başlangıç noktasındaki voltaj bilgileri ve besleyici dalları boyunca voltaj düşüşünün analizi temel alınarak yeni bir arıza tespiti ve lokalizasyon yöntemi sunmaktadır. Yöntem, tek fazlı kısa devre ve üç fazlı kısa devre arızalarını tespit ve lokalizasyon yeteneğine sahiptir. Yöntemin performansını değerlendirmek için 0.1Ω ile $1\text{ k}\Omega$ arasında değişen farklı arıza dirençleri dikkate alınmış ve lokalizasyon doğruluğu ölçülmüştür. 50Ω arıza direnci dikkate alındığında %96.03 lokalizasyon doğruluğu bulunmuştur (Sapountzoglou, Raison, & Silva, 2019).

Dağıtık enerji üretiminin artan entegrasyonu, dağıtım hatlarında akıllı cihazların, örneğin SM ve PMU (Akım fazör ölçüm ünitesi) 'ların varlığını gerektirmektedir. Bu cihazlar, arıza tespit süresini önemli ölçüde azaltmak için kullanılabilir. Çoğu arıza tespit algoritması, ağ topolojisi hakkında bir dizi varsayım yaparak ve iterasyonlar kullanarak çalışmaktadır. Bu, hesaplanan arıza mesafesi ile gerçek arıza mesafesi arasında önemli bir tutarsızlığa yol açar.

Sreerama ve arkadaşları, arıza tespiti ve lokalizasyon için Petri ağları kullanan bir yöntem önermiştir. Petri ağları, iterasyon gerektirmeden çalışmakta ve giriş verilerine dayanarak arızanın yerini kesin olarak daraltabilmektedir. Tek ve çoklu arıza senaryoları için bir dağıtım hattı simüle edilmiştir. Elde edilen sonuçlar, önerilen algoritmanın etkinliğini göstermektedir (Sreerama & Swarup, 2017). Literatürde, güç şebeke verilerinin analizi için birçok sinyal işleme yöntemi kullanılmıştır. En sık kullanılan yöntemler arasında zaman

serisi analizi, Hızlı Fourier Dönüşümü (FFT), Kısa Süreli Fourier Dönüşümü (STFT) ve Wavelet Dönüşümü (WT) bulunmaktadır. Zaman serisi analizi, sinyalin frekans bilgilerini yakalama konusunda sınırlı kalırken, FFT sinyalin tüm frekans bilgilerini yakalama yeteneğine sahiptir, ancak bunu zaman bilgisi kaybı pahasına gerçekleştirir. STFT, hem zaman hem de frekans bilgilerini yakalama yeteneğine sahiptir; geniş bir zaman penceresi iyi frekans çözünürlüğü, ancak kötü zaman çözünürlüğü sağlamaktadır. Dar bir zaman penceresi ise iyi zaman çözünürlüğü, ancak düşük frekans çözünürlüğü sağlamaktadır. WT, bir sinyali belirli bir zaman-frekans çözünürlüğüne bölme yeteneğine sahip olup, güç şebeke sinyalindeki ani değişiklikleri daha etkili bir şekilde yakalayabilmektedir. Ayrıca makine öğrenme yöntemlerinin yüksek hesaplama hızı, iyi genelleme yeteneği ve şebeke gürültüsünden etkilenmeden hızlı tespit sağlaması başarılı sonuçların alınmasını sağlamıştır. Literatürde, WT ve makine öğrenme algoritmalarını birleştiren çalışmalar, esas olarak güç kalitesi ve arıza sınıflandırmaya odaklanmıştır.

Sebastian ve arkadaşları, güç kalitesi olaylarının sınıflandırılması için DWT kullanan bir yöntem önermiştir. DWT'den elde edilen özellik verileri, yapay sinir ağları kullanılarak sınıflandırılmış ve %92.9 doğrulukla sınıflandırma başarısı elde edilmiştir (Sebastian & D'Sa, 2015).

Abdulwahid ve arkadaşları, mikroşebekelerdeki iletim hatlarında arıza sınıflandırma ve tespit için yeni bir teknik önermiştir. Voltaj sinyallerinin yüksek frekans bileşenleri DWT ile analiz edilerek Wavelet Dönüşüm Katsayıları ve Wavelet Enerji Katsayıları çıkarılmış ve bu özellikler ANN'de girdi olarak kullanılmıştır (Abdulwahid, 2019).

Jayamaha ve arkadaşları, DC mikroşebekeler için wavelet çok çözünürlüklü analiz ve makine öğrenme tabanlı arıza tespit yöntemi önermiştir. WT, akım ölçümlerinin özellik vektörünü çıkarmak için kullanılmıştır. Bu özellikler, arıza sınıflandırma ve lokalizasyon için ANN'ye girdi olarak kullanılmış ve %99 doğruluk elde edilmiştir. Ayrıca, önerilen yöntemin, 40 dB gürültü varlığında %98.5 doğrulukla sınıflandırma başarısı gösterdiği kanıtlanmıştır (Jayamaha, Lidula, & Rajapakse, 2019).

Neethu ve arkadaşları, DWT ve ANN kullanan yeni bir yaklaşım önermiştir. 5 seviyeli db4 wavelet ailesi, wavelet dönüşümü için optimal olarak kabul edilmiştir. Özellik matrisleri detay katsayıları kullanılarak oluşturulmuş ve bu veriler yapay sinir ağına girdi olarak verilmiştir. Sonuçlar, %0.1 ortalama hata oranı göstermektedir (Neethu & Angel, 2017).

Tablo 4'de literatür taraması bölümünde atıfta bulunulan bazı çalışmalarla ilgili özet bilgiler sunulmuştur.

Tablo 4. Literatür İncelemesi

Referans	Çalışma Kapsamı	NTL Tespit Türü	Veri	Uygulama Alanı	Kullanılan Yöntem	Uygulama
(Uvais, 2020)	Tespit ve lokalizasyon	DY	Akım, voltaj	AGŞ	DY	Basit simülasyon ortamı
(Raza, Imran, Khattak, Ulasayar, & Ilyas, 2021)	Tespit ve lokalizasyon	DY	Voltaj	AGŞ	DY	Birden fazla trafolu dağıtım hattı modeli
(Metaliya & Deshpande, 2021)	Tespit ve lokalizasyon	DY	Voltaj	AGŞ	DY	IEEE 33 dağıtım sistemi
(Komolafe & Udofia, 2020)	Tespit ve lokalizasyon	DY	Empedans, Voltaj	AGŞ	DY	Nijerya'nın Ekong Uko Caddesi'ndeki dağıtım ağı
(Dasgupta, Padmanaban, & Hazra, 2017)	Tespit ve lokalizasyon	DY	Voltaj	AGŞ	Normalleştirilmiş voltaj farkı çifti (NVDD), Mahalanobis mesafesi	IEEE 34 test şebekesi
(Hasan, Saydur, Shazid, & Jubair, 2023)	Tespit ve lokalizasyon	DY	Voltaj	SM	Welch t-testi, voltaj profilleri	59 düğümlü test ağı
(Engelbrecht, Hancke, & Osifeko, 2019)	Tespit	DT	Akım, voltaj	SM	SVM	-
(Jindal, ve diğerleri, 2016)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi, hane halkı büyüklüğü, mevsim, zaman dilimi, sıcaklık	SM	Karar Ağacı (DT), SVM,	-
(Buzau, Tejedor-Aguilera, Cruz-Romero, & Gómez-Expósito, 2019)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi, coğrafi lokasyon	SM	XGBoost, kNN, SVM, Doğrusal Regresyon (LR)	İspanya'nın önde gelen şirketi Endesa'nın veri seti
(Gunduz & Das, 2024)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	CNN, SVM, RF, LR, KNN, DT, GAN	2104 konut kullanıcısından alınan gerçek elektrik tüketim verileri
(Jokar, Arianpoo, & Leung, 2016)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	Destek Vektör Makinesi (SVM)	-
(Farid, Iltaf, & Afzal, 2023)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	CNN, STN	SGCC veri seti
(Kawoosa, Prashar, Faheem, Jha, & Khan, 2023)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	XGBoost	Sentetik Hırsızlık Senaryoları ve Gerçek Tüketim Verileri
(Petrlik Azabache, ve diğerleri, 2022)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	SVM	Çin Devlet Şebeke Şirketi Veri Seti
(Yang, ve diğerleri, 2022)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	Doğrusal Regresyon Tabanlı Algoritmalar	İrlanda'dan Gerçek Veriler

Referans	Çalışma Kapsamı	NTL Tespit Türü	Veri	Uygulama Alanı	Kullanılan Yöntem	Uygulama
(Bian, ve diğerleri, 2021)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi, mevsim, zaman dilimi, sıcaklık	SM	LSTM ve Dikkat Mekanizması	Massachusetts Üniversitesi'nden Halka Açık Veri Seti
(Souza M. , ve diğerleri, 2020)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	SOM ve MP-ANN	IEEE 70 Dağıtım Ağı Üzerine Sentetik Veri
(Sim, Lee, & Shin, 2023)	Tespit ve lokalizasyon	MÖ	Sayaç tüketim verisi	SM	CNN algoritması, 2D görüntüler, SM ve OM sayaç verileri	SimBench veri kümesi
(Lepolesa, Achari, & Cheng, 2022)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	Zaman ve frekans alanlarında özellik çıkarımı, veri interpolasyonu, sentetik veri üretimi	SGCC veri kümesi
(Gabriel, Matthes, Keller, & Hagenmeyer, 2019)	Tespit ve lokalizasyon	MÖ	Sayaç tüketim verisi	SM	SSHMM, tüketim profilleri, SM manipülasyonu	ECO ve REFIT veri kümesi
(Farid, Iltaf, & Afzal, 2023)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	CNN, STN	SGCC veri seti
(Chu, ve diğerleri, 2022)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	Dinamik zaman bükme, yerel aykırı değer faktörü, kümeleme	SGCC veri seti
(Bhusal, Gautam, & Benidris, 2021)	Tespit ve sınıflandırma	MÖ	Voltaj	AGŞ	Rastgele orman regresyon modeli, lojistik regresyon modeli	ABD'deki 240 düğümlü dağıtım sistemi, IEEE 123 düğümlü dağıtım sistemi
(Li, ve diğerleri, 2022)	Tespit ve lokalizasyon	MÖ	Voltaj	AGŞ	Derin öğrenme modeli	IEEE 37 düğümlü model, güneş çiftliklerine sahip akıllı şebeke örneği
(Petrlik Azabache, ve diğerleri, 2022)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	SVM	Çin Devlet Şebeke Şirketi Veri Seti
(Yang, ve diğerleri, 2022)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi	SM	Doğrusal Regresyon Tabanlı Algoritmalar	İrlanda'dan Gerçek Veriler
(Bian, ve diğerleri, 2021)	Tespit ve sınıflandırma	MÖ	Sayaç tüketim verisi, mevsim, zaman dilimi, sıcaklık	SM	LSTM ve Dikkat Mekanizması	Massachusetts Üniversitesi'nden Halka Açık Veri Seti

DY: Deterministik yöntem, MÖ: Makine Öğrenmesi, AGŞ: Alçak gerilim Şebekesi, SM: Akıllı Sayaç

1.9.1. Motivasyon ve Katkılar

Ülkemizde tarımsal sulama için kullanılan enerji, yıllık toplam tüketimin önemli bir kısmını oluşturmaktadır, bu da enerji tüketiminin takibini ve doğru faturalanmasını kritik hale getirmektedir. Bu tez çalışmasında tarımsal sulama sistemlerindeki kaçak elektrik kullanımlarını tespit etmek için etkili bir sistem önerilmektedir. Kaçak elektrik tüketen yükler, dağıtım hattına doğrudan temas yoluyla bağlantısı gerçekleştirilen sulama motorlarıdır. Konuyla ilgili literatürdeki çalışmaların çoğu, akıllı sayaçların manipülasyonu nedeniyle oluşan kaçak elektrik kullanımlarına odaklanmaktadır. Bu çalışmalarda, çeşitli akıllı algoritmalarla anormallikler tespit edilerek manipüle edilen sayacın lokasyonu belirlenebilmektedir. Ancak, dağıtım hattına doğrudan temas eden kaçak kullanımların yerini belirlemek çok daha karmaşık olmakla beraber bu konuda çok az çalışma bulunmaktadır. Bu çalışmalarda deterministik yöntemler kullanılmış olsa da dağıtım hatlarındaki dinamik yük profilinden dolayı bu tür yöntemlerin performansı düşmektedir.

AGŞ hatlarında, farklı türde iletkenler ve fazla dallanma bulunmaktadır. Bu özellikler, doğrudan dağıtım hattına temas yoluyla meydana gelen elektrik hırsızlıklarının belirlenmesi için empedans tabanlı deterministik yöntemlerin etkinliğini azaltmaktadır. Tez çalışmasında önerilen sistem ve makine öğrenmesi tabanlı yöntem, bu olumsuzlukların üstesinden gelmektedir. Dağıtım hattına doğrudan temas eden yasa dışı kullanımları yüksek doğrulukla tespit edilebilmekte, yük sınıflandırması ve kaçak tüketim yeri yüksek doğrulukla belirlenebilmektedir.

Elektrik dağıtım şirketinin teknik personeli, genellikle gündüz saatlerinde bölgesel tarama yöntemiyle yasadışı olarak devreye alınan yüklerin yerini tespit edebilmektedir. Ancak, kırsal alanlarda uzun dağıtım hatlarında tespit yapmak zor ve zaman alıcıdır. Tez çalışmasında önerilen Akıllı şebeke otomasyon sistemi, dağıtım hattının uzaktan izlenmesini ve kontrol edilmesini sağlayarak yasadışı yüklerin hızlı ve doğru bir şekilde tespit edilmesini sağlamaktadır.

Bu çalışmanın önerdiği yöntem, yalnızca üç fazlı akım verilerini kullanarak karar destek sistemleri geliştirmeyi amaçlamaktadır. Tarımsal sulamada yasa dışı elektrik kullanımının yerinin belirlenmesinde kablosuz IoT ağı ve makine öğrenimi kullanan ilk çalışma olması açısından literatüre önemli bir katkı sağlamaktadır. Simülasyonlar, gerçek ağ parametreleri kullanılarak gerçekleştirilmiş ve önerilen yöntemin başarımları gerçek saha ölçümleri üzerinde gösterilmiştir.

Mevcut literatürde, dağıtım hatlarında diğer yer belirleme çalışmaları için (örneğin, arıza yeri belirleme) PMU'ların gerekliliği açıktır. Bu çalışmada, ek bir donanım gerektirmeden elektrik hırsızlığının yerini tespit etmek için yeni bir yöntem önerilmektedir. Bu yöntem, akıllı sayaçlar, ileri sensörler ve otomasyon sistemleri gibi akıllı şebeke bileşenlerini birleştirmektedir.

Tez çalışması, hem zaman hem de frekans domenine ait sonuçlar elde ederek sinyal işleme teknikleri açısından özgün bir yaklaşım sunmaktadır. Lokalizasyon tespiti ve sınıflandırma çalışması için Örüntü Analizi, DWT ve FWHT yöntemleri olmak üzere üç farklı yöntemin sonuçları karşılaştırılmıştır. Bu karşılaştırmalı analiz, her bir yöntemin göreceli güçlü ve zayıf yönlerini ortaya koyarak, gelecekteki araştırmalara belirli uygulamalar için en uygun tekniklerin seçimi konusunda rehberlik etmektedir. Ayrıca, makine öğrenme tekniklerinin lokalizasyon tespit sürecine entegrasyonu, sistemin zamanla adapte olmasını ve gelişmesini sağlayarak tespit yeteneklerinin sürekli iyileştirilmesini mümkün kılmaktadır. Gerçek saha ölçümlerinin kullanılmasıyla literatürdeki bu boşluk doldurulmuş, böylece bu alandaki çalışmalara önemli bir katkı sağlanmıştır.

Küresel ısınma sonucunda ortaya çıkan kuraklık etkileri taban suyuna erişimi zorlaştırarak sulama için harcanan enerjiyi artırmaktadır. Bu eğilimin devam etmesi beklenmektedir. Dolayısıyla sulama için gerekli enerjinin verimli bir şekilde harcanması önemlidir. Bu tez çalışmasında önerilen sistem ile tarımsal sulamada kullanılacak elektrik enerjisinin kaçak kullanımını engelleyerek enerji verimliliğinin artırılması hedeflenmektedir. Ayrıca kaçak kullanımların engellenmesi durumunda, çiftçiler kritik öneme sahip su kaynaklarını daha etkin olarak kullanmaya yönlendirilmiş olacaklardır (Gökalp & Çakmak, 2013).

Bu tez çalışmasının başlıca katkıları aşağıdaki gibi sıralanabilir;

- Tarımsal sulama sistemlerindeki kaçak elektrik kullanımlarını tespit etmek için makine öğrenmesi tabanlı yeni bir yöntem önerilmesi ve bu konuda literatürde yapılan ilk çalışma olması,
- Dağıtım hattına doğrudan temas eden kaçak elektrik kullanımlarının yüksek doğrulukla tespiti, sınıflandırılması ve yer tespitinin gerçekleştirilmesi konularında literatürde yapılmış ilk kapsamlı çalışma olması,
- İleri IoT tabanlı (RF Mesh Topolojisi) veri toplama ve gerçek zamanlı makine öğrenme algoritmalarının entegrasyonun sağlandığı özgün bir sistemin önerilmesi,

- Ek donanım gereksinimi olmaksızın, yalnızca üç fazlı akım verilerini kullanarak sonuçların elde edilmesi,
- Simülasyonlar ve gerçek saha ölçümleri ile yöntemin başarımlarının gösterilmesi,
- Zaman ve frekans domenine ait sonuçlar elde ederek sinyal işleme teknikleri açısından özgün bir yaklaşımın sunulması,
- Lokalizasyon tespiti ve sınıflandırma çalışması için farklı makine öğrenmesi yöntemlerinin karşılaştırılması ve en uygun tekniklerin belirlenmesi,
- Kaçak elektrik tespitinde yüksek doğruluk ve güvenilirliğin sağlanması,
- Enerji kayıplarının önlenmesi ve şebeke kararlılığının sağlanması,
- Önerilen sistem ile enerji verimliliğinin artırılması ve su kaynaklarının daha etkin kullanımının sağlanması.

Tablo 5'te, literatür taraması bölümünde atıfta bulunulan çalışmaların kapsamlı bir karşılaştırması sunularak mevcut araştırmalardaki boşluklar ortaya koyulmaktadır.

Bu tezin geri kalan bölümleri aşağıdaki şekilde yapılandırılmıştır: Bölüm 2'de yapılan çalışmalar kapsamlı açıklamalarla tanımlanmaktadır. Bölüm 3'te bulgular ve tartışma kısmında elde edilen sonuçlar ve analizler sunulmaktadır. Bölüm 4'te sonuçlar ele alınmakta ve Bölüm 5'te gelecekteki potansiyel çalışmalar için öneriler sunulmaktadır.

Tablo 5. Tez çalışmasının literatür çalışmalar ile kıyaslanması


Yazar	Tespit	Lokalizasyon	Sınıflandırma	IoT Tabanlı	Makine Öğrenimi	Karşılaştırmalı Analiz	Dağıtım Hattı Üzerindeki Hırsızlık	Donanım Tabanlı	Gerçek Saha Ölçümleri
(Wei, Sundararajan, Sarwat, Biswas, & Erfan, 2017)	✓	×	×	×	×	×	×	×	✓
(Uvais, 2020)	✓	✓	×	×	×	×	✓	×	×
(Metaliya & Deshpande, 2021)	✓	✓	×	×	×	×	✓	×	×
(Komolafe & Udofia, 2020)	✓	✓	×	×	×	×	✓	×	✓
(Dasgupta, Padmanaban, & Hazra, 2017)	✓	✓	×	×	×	×	✓	✓	×
(Jindal, ve diğerleri, 2016)	✓	×	✓	×	✓	✓	×	×	✓
(Buzau, Tejedor-Aguilera, Cruz-Romero, & Gómez-Expósito, 2019)	✓	×	✓	×	✓	✓	✓	×	✓
(Gunduz & Das, 2024)	✓	×	✓	×	✓	✓	×	×	✓
(Jokar, Arianpoo, & Leung, 2016)	✓	×	✓	×	✓	✓	×	×	✓
(Kawoosa, Prashar, Faheem, Jha, & Khan, 2023)	✓	×	✓	×	✓	✓	×	×	✓
(Petrlik Azabache, ve diğerleri, 2022)	✓	×	✓	×	✓	✓	×	×	✓
(Appiah, Akowuah, Ikpo, & Dede, 2023)	✓	×	×	×	✓	✓	×	×	✓
(Yang, ve diğerleri, 2022)	✓	×	×	×	✓	✓	×	×	✓
(Souza M. , ve diğerleri, 2020)	✓	×	✓	×	✓	✓	×	×	×
(El-Toukhy, Srivastava, Fouda, & Alsabaan, 2023)	✓	×	✓	×	✓	✓	×	×	✓
(Gabriel, Matthes, Keller, & Hagenmeyer, 2019)	✓	✓	×	×	✓	✓	×	×	✓
(Kara & Aksu, 2023)	✓	×	✓	×	✓	✓	×	×	✓
(Zheng, Yang, Niu, Dai, & Zhou, 2018)}	✓	×	✓	×	✓	✓	✓	×	✓
(Farid, Iltaf, & Afzal, 2023)	✓	×	✓	×	✓	✓	×	×	✓
Tez çalışması	✓	✓	✓	✓	✓	✓	✓	✓	✓

2. YAPILAN ÇALIŞMALAR


2.1. Sistem Mimarisi

Bu çalışmada, tarımsal sulama sistemlerindeki elektrik hırsızlığı olaylarını tespit etmek amacıyla RF Mesh ağına dayalı bir izleme sistemi önerilmektedir. Bu izleme sistemi, dağıtım transformatörüne ve müşteri sayaçlarına entegre edilmiş ölçüm bileşenlerini kullanmaktadır. Bu düzenekte, sayaçlar periyodik olarak müşteri yükleri tarafından çekilen anlık gücü iletmektedir. Kablosuz IoT ağını kullanarak, akıllı sayaçlar tarafından rapor edilen toplam periyodik enerji tüketimi, dağıtım trafo merkezinde gözlemlenen toplam taleple karşılaştırılmaktadır. Şekil 15’de gösterildiği üzere, sistemin ölçüm bileşenleri hem dağıtım trafosuna hem de müşteri sayaçlarına entegre edilmiştir. Trafo merkezinde lokasyonlandırılan gömülü bilgisayar sistemi, dağıtım hatlarının akım ve gerilim değerlerini sürekli olarak izlemektedir. Motor aktivasyonunu doğru bir şekilde tespit etmek için, her trafo merkezi hattı 10-bit örnekleme yapabilen analog dijital dönüştürücüler kullanılarak 1.4 kHz’de örneklenmektedir. RF modemler enerji tüketim verilerini toplamakta ve kablosuz olarak veri toplayıcısına iletmektedir. Toplanan veriler, IPv6 bağlantısı üzerinden 4G/LTE baz istasyonu aracılığıyla merkezi yönetim sunucusuna iletilmektedir.

Şekil 16’da, kaçak elektrik tüketiminin tespiti, sınıflandırılması ve lokalizasyonu için kullanılan algoritma adımları verilmiştir. İlk adımda, fider ölçüm noktasından toplanan akım verileri kullanarak sistemdeki kaçak tüketim tespiti gerçekleştirilmektedir. Tespit gerçekleştiğinde, veriler ön işleme tabi tutulmaktadır. Bu ön işleme aşaması, verilerin daha anlamlı hale getirilmesini ve analizlerin daha doğru yapılmasını sağlamaktadır. Ardından, ön işlenmiş verilerden çeşitli yöntemler kullanılarak öznitelikler çıkarılmaktadır. Bu öznitelik çıkarımı aşaması, verilerin enformasyon içeriğini zenginleştirerek daha doğru sınıflandırma ve tespit sonuçları elde edilmesini sağlamaktadır. Elde edilen özniteliklerden oluşturulan verisetleri, makine öğrenmesi algoritmalarının giriş verisi olarak kullanılmakta ve bu sayede yükün sınıflandırılması ve kaçak tüketimin lokalizasyonu sonuçları elde edilmektedir. Ayrıca, Tablo 6’da bu algoritmanın ikinci tespit yöntemi kullanılarak oluşturulmuş pseudo kodu yer almaktadır.



Şekil 15. Sistem Mimarisi



Şekil 16. Kaçak elektrik tüketiminin tespiti, sınıflandırılması ve lokalizasyonu için kullanılan algoritma


Tablo 6. Kaçak tespit, sınıflandırma ve lokalizasyon algoritması pseudo kodu

1	procedure Kaçak-Tüketim-Algoritması(3 Faz Akım Verisi, i: zaman indeksi, j: faz bilgisi, Th)
2	Başla
3	Veriyi al (3 Faz Akım Verisi)
4	$j \leftarrow 1$
5	repeat
6	for j in 1 to 3 do
7	Ardışık Tepe Değerlerini Bul $T(i,j)$
8	if $T(i+1,j) - T(i,j) \geq Th$ then
9	Kaçak tespit edildi
10	end if
11	$j \leftarrow j + 1$
12	end for
13	until j = 3
14	Kaçak tüketimi tespit et
15	Veriyi ön işlemeden geçir
16	Öz nitelikleri çıkar
17	Örüntü analizi, DWT yöntemi, FWHT yöntemi kullan
18	Yükü sınıflandır
19	Kaçak tüketimin yerini belirle
20	Bitir
21	return Kaçak-Tüketim-Algoritması
22	end procedure

2.2. Kaçak Tüketimin Tespiti

Kaçak tüketimin tespiti için iki farklı yöntem önerilmektedir;

1.Yöntem : Şekil 17’de görüldüğü gibi tespit süreci iki aşamalı güç kontrolü içermektedir. İlk olarak, trafodan çekilen toplam toplam güç ile hat sayaçlarından çekilen toplam güç karşılaştırılmaktadır. Bu, kaçak elektrik tüketimi yapan bir yükün devrede olup olmadığını belirlemektedir. İkinci olarak, bir fider bazlı tespit süreci gerçekleştirilmektedir. Bu amaçla, fiderden çekilen toplam güç ile fider sayaçlarından çekilen toplam güç karşılaştırılmaktadır. Böylece kaçak elektrik kullanımının hangi fider üzerinde olduğu tespit edilmektedir. %7 teknik kayıp varsayılarak, 0.93 eşik değeri belirlenmiştir.



Şekil 17. Kaçak tüketimin tespiti için önerilen 1. tespit algoritması

P_T : Trafodan çekilen toplam güç, P_k : Fiderden çekilen toplam güç, P_i : Fidere bağlı sayaçlardan çekilen toplam güç, α : Eşik değeri.


2.Yöntem : Bufferlarda saklanan 3 faz akım verileri, bir matriste ($Data(i,j)$) toplanmaktadır. Bu matrisin her bir sütunu, faz akımlarını (I_a, I_b, I_c) temsil etmektedir. Bir anormallik oluştuğunda, diferansiyel değerler belirli bir eşik değerinin (T_h) üzerine çıkmaktadır. Bu eşik değeri, akımdaki ani değişiklikleri tespit etmek amacıyla kullanılmaktadır. Bu nedenle, her sütun sırayla analiz edilmekte ve ardışık iki değer arasındaki fark belirlenen sınır değerini aşarsa, kaçak kullanım tespiti gerçekleştirilmektedir.

Şekil 18'deki 2.tespit algoritması üç faz akım verilerini analiz ederek kaçak elektrik kullanımını tespit etmeyi amaçlamaktadır. Algoritma başlangıçta faz indeksini (j) 1 olarak belirlemekte ve her bir faz için ($j \leq 3$) döngüsel olarak çalışmaktadır. Tespit için 2 sn veri penceresi kullanılmaktadır. Her faz için, tepe değerleri bulunmakta ve mevcut zaman dilimindeki akım verisi tepe değeri $T(i, j)$ ile bir sonraki zaman dilimindeki akım verisi tepe değeri $T(i+1, j)$ arasındaki fark hesaplanarak belirlenen bir eşik değeri (T_h) ile karşılaştırılmaktadır. Eğer fark eşik değerini aşıyorsa, kaçak kullanım tespit edilmiş olarak işaretlenmektedir. Bu süreç, tüm fazlar için tekrarlanarak olası kaçak kullanımların belirlenmesini sağlamaktadır. Kaçak bir kullanım olayı tespit edildiğinde, yükü sınıflandırmak için makine öğrenimi (ML) tabanlı algoritmalar devreye girmektedir.

Bu tez çalışmasında, iki ayrı pilot sahada gerçekleştirilen analizlerin sonuçları

sunulmaktadır. Elazığ örneği ile ilgili çalışmada, iki farklı giriş verisi kullanılarak sonuçlar elde edilmiştir. İlk önce fider başlangıcından ölçülen A fazına ait tek faz akım verisi kullanılmış kaçak tespiti, sınıflandırılması ve yer tespiti (lokalizasyon) sonuçları alınmıştır. Sonrasında ise üç faz akım verisi ile sonuçlar yeniden elde edilmiştir. Tek faz akım ve üç faz akım verisi, ön işleme adımından geçirildikten sonra üç farklı yöntem uygulanarak öznetelikler elde edilmiştir. Böylece yöntemlerin sonuçları kıyaslanarak en doğru yöntem ile saha sonuçlarının alınması ve Malatya örneğindeki çalışmanın yapılması hedeflenmiştir. Uygulanan öznetelik çıkarma yöntemleri; Örüntü analizi, DWT ve FWHT yöntemleridir. Örüntü analizi yönteminde, simülasyondan elde edilen akım dalgasında gözlemlenen örüntüler uzman görüşüne dayalı olarak manuel olarak belirlenmiştir. Daha sonra bu örüntülerin matematiksel ve istatistiksel özellikleri çıkarılarak bir öznetelik matrisi elde edilmiştir. Bu matris; ortalama değer, tepe değeri, standart sapma, örüntü genişliği, basıklık değeri, çarpıklık değeri ve enerji değerlerini içermektedir. Ayrık dalgacık dönüşümü yönteminde, db18 dalgacık ailesi 1. seviye detay katsayıları öznetelik olarak kullanılmıştır. FWHT dönüşümü yönteminde ise Walsh-Hadamard dönüşümü uygulanarak elde edilen katsayılar öznetelik olarak kullanılmıştır. Oluşturulan özneteliklerden elde edilen veri setleri, makine öğrenmesi algoritmalarına giriş verisi olarak kullanılmaktadır. Malatya örneği ile ilgili çalışmada, fider başlangıcından ölçülen üç faz akım verisi kullanılmış kaçak tespiti, yük sınıflandırması ve yer tespiti (lokalizasyon) sonuçları DWT yöntemiyle elde edilmiştir.

Tüm simülasyonlar MATLAB 2022b Simulink programında gerçekleştirilmiş olup, sınıflandırma ve lokalizasyon analizleri MATLAB Sınıflandırma ve Regresyon aracı kullanılarak yapılmıştır.



2.3. OBE Algoritması Tabanlı Yük Sınıflandırması

OBE algoritması tabanlı yük sınıflandırılması amacı, dağıtım şebekesinde doğrudan temas yoluyla devreye giren kaçak tüketim yapan yüklerin sınıflandırılmasıdır.

Tez çalışmasında, sınıflandırma problemleri için farklı parametrelerle optimize edilmiş OBE algoritması kullanılmıştır. Malatya örneğinde yapılan sınıflandırma çalışmasında bir çok makine öğrenimi algoritması üstün performans gösterdiği için optimizasyon kullanılmamıştır.

Tablo 7, tez çalışmasında sınıflandırma probleminde kullanılan diğer makine öğrenimi modelleri ve bu modellerin hiperparametreleri hakkında bilgi vermektedir.

Tablo 7. Sınıflandırma probleminde kullanılan farklı makine öğrenimi modelleri ve bu modellerin hiperparametreleri

Sınıflandırma Modeli	Hiperparametre
FT	Maksimum bölme sayısı: 100
MT	Maksimum bölme sayısı: 20
CT	Maksimum bölme sayısı: 4
LD	Kovaryans yapısı: Tam
Q	Kovaryans yapısı: Tam
ELR	Öğrenici: Lojistik regresyon
ELSVM	Öğrenici: SVM
GNB	Sayısal tahminciler için dağıtım adı: Gauss
KNB	Sayısal tahminciler için dağıtım adı: Çekirdek
LSVM	Çekirdek fonksiyonu: Doğrusal
QSVM	Çekirdek fonksiyonu: İkinci Dereceden
CSVM	Çekirdek fonksiyonu: Kübik
FGSVM	Çekirdek fonksiyonu: Gauss
MGSVM	Çekirdek fonksiyonu: Gauss
CGSVM	Çekirdek fonksiyonu: Gauss
FKNN	Komşu sayısı: 1
MKNN	Komşu sayısı: 10
CKNN	Komşu sayısı: 100
CoKNN	Komşu sayısı: 10
CuKNN	Komşu sayısı: 10
WKNN	Komşu sayısı: 10
BT	Topluluk yöntemi: AdaBoost
BAT	Topluluk yöntemi: Torbalama
SD	Topluluk yöntemi: Alt Uzay
SKNN	Topluluk yöntemi: Alt Uzay
RBT	Topluluk yöntemi: RUSBoost
NNN	Tam bağlı katman sayısı: 1
MNN	Tam bağlı katman sayısı: 1
WNN	Tam bağlı katman sayısı: 1
BNN	Tam bağlı katman sayısı: 2
TNN	Tam bağlı katman sayısı: 3
SVMK	Öğrenici: SVM
LRK	Öğrenici: Lojistik Regresyon
OBE	Topluluk yöntemi: RUSBoost

2.4. OBE Algoritması Tabanlı Kaçak Yeri Tespiti

Kaçak tüketim yeri tespit algoritmasının amacı, dağıtım şebekesine doğrudan temas yoluyla bağlanan yüklerin devreye girdiği noktanın metre cinsinden konumunu belirlemektir. Tez çalışmasında, lokalizasyon (regresyon) problemleri için farklı parametrelerle optimize edilmiş OBE algoritması kullanılmıştır. Bu çalışmada, regresyon analizinin performansı hata yüzdesi ile belirlenmektedir. Tahminlerin hata oranı IEEE PC37.114 standardına göre hesaplanmıştır (IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines, 2015). Denklem (29), bu değeri hesaplamak için kullanılan denklemi göstermektedir.

$$\frac{\text{Gerçek lokasyon} - \text{Tahmin edilen lokasyon}}{\text{Toplam fider uzunluğu}} * 100 \quad (29)$$

Tablo 8, regresyon probleminde kullanılan diğer makine öğrenimi modelleri ve bu modellerin hiperparametreleri hakkında bilgi vermektedir.

Tablo 8. Lokalizasyon probleminde kullanılan farklı makine öğrenimi modelleri ve bu modellerin hiperparametreleri

Regresyon Modeli	Hiperparametre
LN	Terimler: Doğrusal
MT	Minimum yaprak boyutu: 12
CT	Minimum yaprak boyutu: 36
LSVM	Çekirdek fonksiyonu: Doğrusal
QSVM	Çekirdek fonksiyonu: İkinci Dereceden
CSVM	Çekirdek fonksiyonu: Kübik
FGSVM	Çekirdek fonksiyonu: Gauss
MGSVM	Çekirdek fonksiyonu: Gauss
CGSVM	Çekirdek fonksiyonu: Gauss
BT	Minimum yaprak boyutu: 8
BAT	Minimum yaprak boyutu: 8
SEGPR	Temel fonksiyon: Sabit
MGPR	Temel fonksiyon: Sabit
EGPR	Temel fonksiyon: Sabit
RQGPR	Temel fonksiyon: Sabit
NNN	Tam bağlı katman sayısı: 1
MNN	Tam bağlı katman sayısı: 1
BNN	Tam bağlı katman sayısı: 2
TNN	Tam bağlı katman sayısı: 3
SVMK	Öğrenici: SVM
LRK	Öğrenici: En Küçük Kareler Çekirdek
OBE	Topluluk yöntemi: LSBoost


2.5. Elazığ Örneği ile İlgili Çalışmalar

2.5.1. Verilerin Elde Edilmesi


Kaçak elektrik tüketimi yapan sulama motorlarının yerlerini belirlemek için önerilen yöntemi doğrulamak amacıyla, Elazığ/Türkiye'de bulunan bir pilot dağıtım hattı

MATLAB/Simulink ortamında modellenmiştir. Pilot saha için dağıtım şebekesi topolojisi Şekil 19'da gösterilmiştir. Şekil 20 ve Şekil 21'de dağıtım hattına ait fiderlerin topolojisi gösterilmektedir.

Modellenen fiderler farklı uzunluklara sahip bölgelere ayrılmaktadır ve her bölgede sulama motorları devreye alınarak fider ölçüm noktasından üç faz akım verisi toplanmaktadır. Fider kolları belirlenirken, kısa uzunluğa sahip bölgelerin ana kol içinde olduğu varsayılmaktadır. Motorların elektriksel özelliklerindeki (güç, tork) ve devredeki lokasyonlarındaki değişim, üç fazlı akım dalga formlarında farklı örüntülere yol açmaktadır. Bu amaçla, modellenen iki fider üzerinde dört farklı senaryo geliştirilmektedir. Senaryo 1'de çeşitli konut yükleri devredeyken farklı güçlerdeki motorlar kaçak tüketim yapan yük olarak kullanılmaktadır. Senaryo 2'de, ölçülen motor yükleri F1 fiderindeki B1, B2 ve B3 sayaçlarına bağlanırken, dağıtım hattının farklı lokasyonlarında kaçak yük senaryoları incelenmektedir. Burada, ölçülen motor yüklerinin nominal tork değerleri ile yüklendiği varsayılmaktadır. Senaryo 1 için F1 fiderinden toplam 340 olay F2 fideri için 500 olay simüle edilmektedir. Senaryo 2 için F1 fideri üzerinde 1343 olay simüle edilmiştir. Her bir olay için, 2 saniyelik pencereyi kapsayan üç fazlı akım verileri, 1.4kHz'lik bir örnekleme frekansı kullanılarak fider ölçüm noktasından toplanmaktadır.



Şekil 19. Dağıtım şebekesi topolojisi




Şekil 20. F1 fiderin simülasyon topolojisi

Dağıtım hattı için kablo kesitleri ve uzunlukları ise Tablo 9’da verilmiştir, burada her kablo tipi simülasyon modelinde farklı renkle temsil edilmektedir.

Tablo 9. Dağıtım hattı kablo parametreleri

Kablo Tipi	Kablo Kesiti	Direnç (ohm/km)	Gösterim
Pancy	1	0.6743	kırmızı
NYM Antigron	26, 46	3.08	mavi
Rose	4	1.3558	gri
Aer	1*(3*25+35)	1.2	siyah
Aer	3x70+95	0.4245	yeşil
Aer	370+116+95	0.443	camgöbeği
Aer	1*(3*50+70)	0.641	turuncu
Aer	316+116+25	1.91	macenta



Şekil 21. F2 fiderin simülasyon topolojisi

Elektromanyetik Geçici Durum (EMT) simülasyonları, Tablo 10'da belirtilen simülasyon parametreleri kullanılarak model üzerinde oluşturulmuştur.

Tablo 10. Simülasyon parametreleri


Fider	F1	F2
Lokasyon (m)	35, 205, 315, 430, 544, 655, 755, 923, 1043, 1178, 1322, 561, 673, 960, 773, 943, 1342	30, 140, 255, 330, 342, 160, 45, 245, 345, 527, 567, 255, 540, 695, 809, 923, 1161, 1211, 1226, 1171, 885, 895, 844, 859, 550
Motor Gücü (kw)	4, 7.5, 15, 22	4, 7.5, 15, 22
Tork (% nominal tork)	20, 40, 60, 80, 100	20, 40, 60, 80, 100

Tablo 11, her iki fiderin uzunluklarını ve bu fiderlere bağlı konut yüklerini göstermektedir.


Tablo 11. Fiderlerde simüle edilen ev yükleri ve fider uzunlukları

Fider	Branş	Fider Uzunluğu	P(W)	Q(Var)
F1	L1-L12, L16-L17, L22-L23, L24-L25	1342, 960, 1200, 1386	1600, 500, 900, 1000, 1000, 1000	1100, 300, 600, 700, 800, 600
F2	L1-L11, L15-L16, L21-L25, L21-L28	1226, 895, 580, 540	1600, 2000, 1200, 1200, 500, 2000	1300, 1400, 800, 800, 300, 1400

Şekil 22 ve Şekil 23’de, fider çıkış noktalarından normal durumda ölçülen akım ve gerilim grafikleri gösterilmektedir.




Şekil 22. F1 fider çıkış noktasından normal durumda ölçülen akım ve gerilim grafikleri




Şekil 23. F2 fider çıkış noktasından normal durumda ölçülen akım ve gerilim grafikleri

Elde edilen 3 faz akım örüntü pencereleri ön işleme adımında birleştirilmiştir. Böylece, satırların toplam olay sayısını temsil ettiği ve sütunların üç fazlı akım verilerinin uzunluğuna karşılık geldiği 2183x8400 boyutunda bir veri kümesi oluşturulmuştur. Bu veriseti üç faz akım çalışmalarında kullanılacaktır. Bu verisetinden A fazına ait tek faz bilgisi alınarak 2183x2800 boyutunda bir veri kümesi daha oluşturulmuştur. Bu veri kümeside tek faz akım çalışmalarında veriseti olarak kullanılmıştır. Şekil 24’de, F1 fiderinde 1178 metre uzaklıkta devreye giren 7,5kW’lık bir sulama motoru için ön işleme aşamasından sonraki veri penceresi görülmektedir.



Şekil 24. Fider başlangıcından 1178m uzaklıkta 7,5 kW’lık bir sulama motorunun ön işleme aşamasından sonraki veri penceresi


Tek faz ve üç faz akım verisinin farklı öznitelik çıkarım teknikleri kullanılarak elde edilen veriseti boyutları Şekil 25’de sunulmaktadır.



Şekil 25. Tek faz ve üç faz akım verisinin farklı öznitelik çıkarım teknikleri kullanılarak elde edilen veriseti boyutları


Aşırı uyumu önlemek için çalışmada 5 kat çapraz doğrulama yöntemi kullanılmıştır. Bu yöntemde veri kümesi rastgele karıştırılmakta ve beş gruba ayrılmaktadır. Her iterasyonda bir grup doğrulama kümesi olarak seçilirken, kalan dört grup eğitim kümesi olarak kullanılmıştır. Eğitim veri setinin %20'lik bir kısmı doğrulama için ayrılırken, %25'lik bir kısmı da test için ayrılmaktadır. Bu süreç, modelin performansını değerlendirmek ve genelleme kabiliyetini artırmak için tekrarlanmaktadır.

Sulama motorları devreye girdiğinde fider başlangıcında gözlemlenen akım örüntüsü, motorun devreye girdiği hat lokasyonuna bağlı olarak farklılık göstermektedir. Bunu için, nominal tork değerinin %75'i (34 Nm) olan 7,5 kW gücünde bir motorun F1 fideri boyunca farklı lokasyonlara bağlandığı örnek bir senaryo geliştirilmiştir. Farklı lokasyonlar için akım dalga şekilleri Şekil 26’da verilmiştir. Sonuçlara göre, motorun bağlandığı lokasyon arttıkça başlangıç akımı örüntüsü önemli ölçüde genişlemektedir. Ayrıca, başlangıç akımı tepe değeri hat empedansının etkisiyle artan mesafe ile azalmaktadır.




Şekil 26. Farklı lokasyonlardaki 7,5 kW'lık bir sulama motoru için trafo fiderinde ölçülen akımın dalga şekli.

Şekil 27'de, 7,5 kW'lık bir motorun 755 m'de farklı tork değerleri ile akım ölçümleri gösterilmektedir. Sonuçlar, motorun yükü arttıkça motorun hem kalkış süresinin hem de kalkış akımı değerlerinin arttığını göstermektedir. Ayrıca Şekil 28'de görüldüğü gibi motor gücü arttıkça hem başlangıç akımı hem de nominal akım değerleri artmıştır. Simülasyon sonuçlarından da anlaşılabileceği üzere, sulama motorlarının kalkış (başlangıç) akımı, sulama motorlarının yerini belirlemek ve tanımlamak için kullanılabilecek özellikleri temsil etmektedir.



Şekil 27. Farklı tork değerleri altında 7.5kW sulama motoru için trafo fiderinde ölçülen akımın dalga şekli.




Şekil 28. 755m'de %75 tork altında farklı nominal güçlere sahip sulama motorları için trafo fiderinde ölçülen akımın dalga şekli.

2.5.2. Tek Faz Akım Verisi ile Sınıflandırma ve Lokalizasyon Çalışması

Bu bölümde, tarımsal sulama sistemlerindeki kaçak elektrik kullanımını tespit etmek amacıyla tek faz akım verileri kullanılarak bir dizi analiz gerçekleştirilmiştir. Örüntü analizi, DWT yöntemi ve FWHT yöntemi ile verilerden öznitelikler çıkarılmıştır. Bu öznitelikler, makine öğrenmesi algoritmalarında kullanılarak, kaçak tüketimin sınıflandırılması ve lokalizasyonuna ilişkin sonuçlar elde edilmiştir.

Ölçüm noktasından alınan akım verisi incelendiğinde motorların başlama akım örüntülerinin önemli ayırt edici özelliğe sahip olabileceği düşünülmüştür. O nedenle Örüntü analizi yönteminde, akım penceresinin sadece örüntü kısmı, uzman kişi tarafından elle çıkarılıp matematiksel ve istatistiksel öznitelikleri hesaplanmıştır. Bu öznitelikler ortalama değer, peak değer, standart sapma, patern genişliği, kurtosis değeri, skewness değeri, enerji değeridir. Böylece tek faz akım çalışması için Örüntü analizi yönteminde kullanılmak üzere 2183x7 boyutlarında bir veriseti oluşturulmuştur. Bu veriseti sınıflandırma ve lokalizasyon çalışmasında makine öğrenimi algoritmaları için giriş verisi olarak kullanılacaktır. Şekil 29'da akım veri penceresinden uzman kişi tarafından elle çıkarılan örüntülere (kırmızı renk olarak belirtilmiştir) örnekler gösterilmiştir.



Şekil 29. Akım veri penceresinden uzman kişi tarafından elle çıkarılan örüntüler

DWT yönteminde db18 ana dalgacığı kullanılarak beş seviyeli bir dalgacık ayrıştırması gerçekleştirilmiştir. Veri boyutuna bağlı olarak maksimum seviye 6 olarak bulunmuştur. Ancak, ayrıştırma için genellikle daha küçük bir değer kullanıldığı için ayrıştırma seviyesi 5 olarak belirlenmiştir. Ayrıştırma sonucunda, ilk seviyeden elde edilen detay katsayıları nihai veri kümesi olarak kullanılmıştır. Bu işlem sonucunda 2183x1417 boyutlarında bir özellik matrisi elde edilmiştir. Bu veriseti DWT yöntemiyle sınıflandırma ve lokalizasyon çalışmasında makine öğrenimi algoritmaları için giriş verisi olarak kullanılacaktır.

FWHT yöntemiyle, veriler frekans domeninde FWHT katsayıları kullanılarak elde edilmektedir. Katsayılar, her satırda ek bir sıfır geçişi sergileyerek, değer sırasına göre artan şekilde düzenlenmektedir. Bu işlem sonucunda, 2183x4096 boyutlarında bir veriseti elde edilmektedir. Bu veriseti FWHT yöntemiyle sınıflandırma ve lokalizasyon çalışmasında makine öğrenimi algoritmaları için giriş verisi olarak kullanılacaktır.

Sınıflandırma için kullanılan motor yüklerin etiket bilgisi Tablo 12’de verilmiştir.

Tablo 12. Sınıflandırma için kullanılan motor yüklerin etiket bilgisi

P (Kw)	Label
4	1
7.5	2
15	3
22	4

Tablo 13’de sınıflandırma çalışmasında OBE algoritması için kullanılan optimizasyon parametreleri verilmiştir. GSO ile yapılan optimizasyon sonucunda, hiperparametreler RUSBoost topluluk yöntemiyle belirlenmiştir. Optimum öğrenici sayısı 494, öğrenme oranı 0.0267 olarak ayarlanmıştır. Maksimum bölme sayısı 137 ve toplam yineleme sayısı 30 olacak şekilde modelin performansı en iyi hale getirilmiştir.

Tablo 13. Sınıflandırma çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri

Hiperparametre	Değer
Topluluk yöntemi	RUSBoost
Öğrenici sayısı	494
Öğrenme oranı	0.0267
Maksimum bölme sayısı	137
Yineleme sayısı	30

Tablo 14’de lokalizasyon çalışmasında OBE algoritması için kullanılan optimizasyon parametreleri verilmiştir. GSO kullanılarak yapılan optimizasyon sonucunda, LSBoost (Least Squares Boosting) topluluk yöntemi en uygun yöntem olarak seçilmiştir. LSBoost, tahmin hatalarını minimize etmek için en küçük kareler yaklaşımını kullanarak model performansını artırmaktadır. Optimum öğrenici sayısı 495 olarak belirlenmiştir, bu da modelin daha derin ve detaylı öğrenmesine olanak tanımıştır. Öğrenme oranı 0.045 minimum yaprak boyutu 3 olarak belirlenmiştir. Ayrıca, örneklenmesi gereken tahminci sayısı 475 olarak ayarlanarak modelin tahmin performansı iyileştirilmiş ve toplamda 30 yinelemeyle modelin genel performansı en iyi hale getirilmiştir.

Tablo 14. Lokalizasyon çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri

Hiperparametre	Değer
Topluluk yöntemi	LSBoost
Öğrenici sayısı	495
Öğrenme oranı	0.045
Minimum yaprak boyutu	3
Örneklenmesi gereken tahminci sayısı	475
Yineleme sayısı	30

2.5.3. Üç Faz Akım Verisi ile Sınıflandırma ve Lokalizasyon Çalışması

Bu bölümde, tarımsal sulama sistemlerindeki kaçak elektrik kullanımını tespit etmek amacıyla, üç faz akım verileri kullanılarak DWT ve FWHT yöntemleriyle makine öğrenmesi tabanlı sınıflandırma ve lokalizasyon sonuçları elde edilmiştir. Kıyaslama yapılırken tek faz akım çalışmasında kullanılan Örüntü analizi yöntemi sonuçları da kullanılmıştır.

DWT yönteminde db18 ana dalgacığı kullanılarak 5 seviyeli bir dalgacık ayrıştırması gerçekleştirilmiştir. Ayrıştırma sonucunda, ilk seviyeden elde edilen detay katsayıları nihai veri kümesi olarak kullanılmıştır. Bu işlem sonucunda 2183x4251 boyutlarında bir özellik matrisi elde edilmiştir. Bu veriseti üç faz akım çalışması için, DWT yöntemiyle sınıflandırma ve lokalizasyon çalışmasında makine öğrenimi algoritmalarının giriş verisi olarak kullanılacaktır.

FWHT yönteminde, 2183x12288 boyutlarında bir özellik matrisi elde edilmiştir. Bu veriseti üç faz akım çalışması için, FWHT yöntemiyle sınıflandırma ve lokalizasyon çalışmasında makine öğrenimi algoritmalarının giriş verisi olarak kullanılacaktır.

Sınıflandırma çalışmasında DWT ve FWHT yöntemi içinde kullanılan OBE algoritması, GSO yöntemi ile optimize edilmiş ve AdaBoost topluluk yöntemi kullanılarak geliştirilmiştir. Tablo 15’de optimizasyon parametreleri verilmiştir. Bu modelde, karar ağaçları öğrenici tipi olarak seçilmiş ve maksimum 64 bölme ile 499 öğrenici kullanılmıştır. Öğrenme oranı ise 0.3377 olarak belirlenmiştir. Bu hiperparametreler, modelin öğrenme kapasitesini artırarak daha yüksek doğruluk elde edilmesini sağlamış ve modelin performansını önemli ölçüde artırmıştır.

Tablo 15. Sınıflandırma çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri

Hiperparametre	Değer
Topluluk Yöntemi	AdaBoost
Öğrenici Sayısı	499
Öğrenme Oranı	0.3377
Maksimum Bölme Sayısı	64
Yineleme sayısı	30

Üç faz akım verileri kullanılarak yapılan lokalizasyon çalışmasında, OBE algoritmasının GSO ile optimize edilen hiperparametre değerleri Tablo 16’da sunulmuştur.

Optimize edilmiş hiperparametreler, modelin öğrenme kapasitesini artırarak daha yüksek doğruluk elde edilmesini sağlamıştır. Özellikle 136 öğrenici sayısı, 0.1 öğrenme oranı, 88 minimum yaprak boyutu ve 2362 tahminci sayısı, modelin performansını önemli ölçüde artırmıştır.

Tablo 16. Lokalizasyon çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri


Hiperparametre	Değer
Öğrenici sayısı	136
Öğrenme oranı	0.1
Minimum yaprak boyutu	88
Örnekleme gereken tahminci sayısı	2362
Yineleme sayısı	30

2.6. Malatya Örneği ile İlgili Çalışmalar

Bu bölümde, tarımsal sulama sistemlerindeki kaçak elektrik kullanımını tespit etmek amacıyla ikinci bir pilot saha üzerinde çalışma gerçekleştirilmiştir. Yeni çalışma sahası olarak Malatya'da bir pilot bir fider seçilmiştir. Böylece, birinci pilot sahada en iyi sonuçları veren yöntemin, farklı bir dağıtım hattında da başarısını test etmek amaçlanmıştır. Bu çalışmada üç faz akım bilgisi kullanılarak DWT yöntemi ile özellik çıkarımı gerçekleştirilmiş ve makine öğrenmesi yöntemlerine ait sınıflandırma ve lokalizasyon sonuçları elde edilmiştir.


2.6.1. Verilerin Elde Edilmesi

Tarımsal sulama motorlarının yasadışı elektrik kullanımının tespiti, sınıflandırılması ve lokalizasyonu amacıyla yeni pilot sahada detaylı simülasyon ve analizler yapılmıştır. Önerilen yöntemi doğrulamak için pilot dağıtım hattı MATLAB/Simulink ortamında Şekil 30'da gösterildiği gibi modellenmiştir. Modellenen fiderler farklı uzunluklara sahip bölgelere ayrılmaktadır ve her bölgede sulama motorları devreye alınarak fider ölçüm noktasından üç faz akım verisi toplanmaktadır. Motorların elektriksel özelliklerindeki (güç, tork) ve devredeki lokasyonlarındaki değişim, üç fazlı akım dalga formlarında farklı örüntülere yol açmaktadır.



Şekil 30. Pilot dağıtım hattı parametrelerinin ölçülmesi

Pilot dağıtım hattı fider topolojisi Şekil 31’de gösterilmiştir.



Şekil 31. Pilot dağıtım hattı fider topolojisi

Fider üzerinde ev yüklerinin kullanılması, kaçak elektrik kullanımının tespitinde ev yüklerinin etkisinin de incelenmesine olanak tanımıştır. Modellenen fiderde kullanılan ev yükleri ise Tablo 17’de verilmiştir.

Tablo 17. Modellenen fiderde kullanılan ev yükleri

P(W)	1000	2000	1000	2000	3000	2000	3000	1000	1500	750
Q(VAR)	750	1500	750	1500	2250	1500	2250	750	1000	500

Dağıtım hattı kablo parametreleri Tablo 18’de verilmiştir.

Tablo 18. Dağıtım hattı kablo parametreleri

Kablo Tipi	Kablo Kesiti	Direnç (ohm/km)	Gösterim
Aer	1*(3*50+70)	0.641	turuncu
Aer	1*(3*25+35)	1.2	siyah


Tablo 19’da verilen simülasyon parametreleri kullanılarak model üzerinde EMT simülasyonları oluşturulmuştur.

Tablo 19. Simülasyon parametreleri

Lokasyon (m)	188, 298, 405, 511, 983, 1137, 539, 640, 694, 562, 593
Motor Gücü (kw)	1.5, 4, 7.5, 15, 22
Tork (% nominal tork)	20, 40, 60, 80, 100
Veri	2 saniye uzunluğunda üç faz akım penceresi
Branş	B1 (L1-L6), B2 (L7-L9), B3 (L10-L11)


Çeşitli uzunluklarda bölgelere ayrılmış fider üzerinde, farklı motor güçleri ve tork değerleri kullanılarak oluşturulan senaryolar kapsamında toplam 2200 olay simüle edilmiştir. Her olay için 1,4 kHz örnekleme frekansı ile 2 saniyelik üç fazlı akım verileri kaydedilerek, 2200x8400 boyutlarında kapsamlı bir veri seti oluşturulmuştur. Bu veri seti, yüksek örnekleme frekansı sayesinde, tarımsal sulama motorlarının devreye girme anındaki akım şekillerindeki hızlı değişimlerin detaylı bir şekilde analiz edilmesine olanak tanımaktadır.

Veri setinin %25’i test verisi olarak ayrılmış ve modelin aşırı uyumundan korunmak amacıyla 5 kat çapraz doğrulama yöntemi uygulanmıştır. Veri kümesi rastgele karıştırılarak beş gruba ayrılmış; bir grup doğrulama kümesi olarak kullanılırken, diğer dört grup eğitim kümesi olarak değerlendirilmiştir. Eğitim seti kullanılarak oluşturulan modeller, doğrulama seti üzerinde test edilmiş ve hata oranları belirlenmiştir. Şekil 32, üç faz akım verisinden farklı öznetelik çıkarım teknikleri kullanılarak elde edilen veriseti boyutlarını göstermektedir.




Şekil 32. Üç faz akım verisinden farklı öznitelik çıkarım teknikleri kullanılarak elde edilen veriseti boyutları


Şekil 33, normal koşullar altında transformatör fiderinden ölçülen gerilim ve akım dalga şekillerini, Şekil 34, Şekil 35 ve Şekil 36 ise 7.5 kW'lık bir motorun farklı lokasyonlarda direkt hatta bağlanması sonucu trafo fiderinde ölçülen akım ve gerilim dalga şekillerini göstermektedir. Motorların devreye girdiği hat lokasyonu arttıkça gerilim değeri düşmekte ve akım örüntüleri uzamaktadır. Bu durum, kaçak elektrik kullanımının tespitinde önemli ayırt edici özellikler sunmaktadır.




Şekil 33. Normal şartlar altında trafo fiderinden ölçülen akım ve gerilim değerleri



Şekil 34. 188m mesafede 7,5 kW sulama motoru devreye girdiğinde trafo fiderinde ölçülen akım ve gerilim değerleri



Şekil 35. 511m mesafede 7,5 kW'lık bir sulama motoru devreye girdiğinde trafo fiderinde ölçülen akım ve gerilim değerleri



Şekil 36. 983m mesafede 7,5 kW'lık bir sulama motoru trafo devreye girdiğinde ölçülen akım ve gerilim değerleri

2.6.2. Üç Faz Akım Verisi ile Sınıflandırma ve Lokalizasyon Çalışması

Pilot bölgede yaptığımız araştırmalar, tarımsal sulama sistemlerinde kullanılan yüklerin genellikle 1,5 kW ile 22 kW arasında değişen güç değerlerine sahip dalgıç pompa motorları olduğunu ortaya koymaktadır. Bu nedenle sınıflandırma yapılırken bu çalışmada beş sınıf dikkate alınmıştır. Ayrıca önceki çalışmadan farklı olarak bu pilot sahada yapılan çalışmada branş sınıflandırmasına da yer verilmiştir. Kaçak yük olarak kullanılan sulama motorlarının etiketleme bilgileri ve motorların devreye girdiği branşlar Tablo 20'de verilmiştir.

Tablo 20. Kaçak yük olarak kullanılan sulama motorlarının etiketleme bilgileri ve motorların devreye girdiği branşlar

P (Kw)	Branş	Label
1.5	B1 (L1-L6)	1
4	B2 (L7-L9)	2
7.5	B3 (L10-L11)	3
15		4
22		5

Lokalizasyon çalışmasında önerilen OBE algoritmasının GSO ile optimize edilmesi için kullanılan hiperparametreler Tablo 21’de belirtilmiştir. 177 öğrenci kullanılarak doğruluk artırılmaya çalışılmıştır. Öğrenme oranı 0.1522 olarak belirlenmiş, böylece modelin hızlı ve dengeli bir şekilde öğrenmesi sağlanmıştır. Minimum yaprak boyutu 1 olarak seçilerek, her bir karar ağacının en küçük yaprak düğümünde en az bir veri noktası bulunması sağlanmıştır. Ayrıca, her bir tahminci için 4244 örneklem alınarak modelin genel performansı optimize edilmiştir. Yineleme sayısı 30 olarak belirlenmiştir.

Tablo 21. Lokalizasyon çalışmasında OBE algoritması için optimize edilmiş hiperparametre değerleri

Hiperparametre	Değer
Öğrenici sayısı	177
Öğrenme oranı	0.1522
Minimum yaprak boyutu	1
Örnekleme gereken tahminci sayısı	4244
Yineleme sayısı	30

3. BULGULAR VE TARTIŞMA

3.1. Elazığ Örneği ile İlgili Bulgular

3.1.1. Tek Faz Akım Verisi ile İlgili Bulgular

Örüntü analizi yöntemi kullanılarak kaçak tüketim yapan yüklerin makine öğrenmesi algoritmaları ile sınıflandırma sonuçları Tablo 22’de gösterilmektedir. Sonuçlar incelendiğinde BAT modeli, %72.84 doğruluk, %72.51 hassasiyet, %72.59 duyarlılık ve %72.55 F1-skoru ile en yüksek performansı sergilemiştir. OBE algoritması da yüksek performans göstererek %71.56 doğruluk, %71.26 hassasiyet, %71.80 duyarlılık ve %71.53 F1-skoru değerlerine ulaşmıştır. Diğer modellerle karşılaştırıldığında, FT modeli %65.87 doğruluk, %66.28 hassasiyet, %66.23 duyarlılık ve %66.26 F1-skoru ile BAT ardından iyi sonuçlar elde etmiştir. MNN modeli de %66.79 doğruluk, %66.88 hassasiyet, %67.41 duyarlılık ve %67.14 F1-skoru ile dikkat çekmiştir. Buna karşılık, ELR ve ELSVM gibi bazı modellerin performansı düşük kalmıştır. Bu sonuçlar, tek faz akım verisi kullanıldığında örüntü analizi yöntemiyle en iyi performansı BAT modelinin gerçekleştirdiğini göstermektedir.

Tablo 22. Örüntü analizi yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları

Model	Doğruluk	Hassasiyet	Duyarlılık	F1-skor
FT	0.6587	0.6628	0.6623	0.6626
MT	0.5578	0.5939	0.5733	0.5834
CT	0.4642	0.5034	0.4818	0.4924
LD	0.389	0.3971	0.3889	0.393
Q	0.4312	0.4393	0.4326	0.4359
ELR	0.1963	0.2010	0.2382	0.2410
ELSVM	0.1982	0.2015	0.25	0.2612
GNB	0.3908	0.3988	0.402	0.4004
KNB	0.4697	0.4594	0.4817	0.4703
LSVM	0.389	0.4053	0.3841	0.3944
QSVM	0.5064	0.5063	0.5038	0.505
CSVM	0.5101	0.537	0.5295	0.5332
FGSVM	0.633	0.6312	0.6371	0.6342
MGSVM	0.4752	0.4776	0.4836	0.4806
CGSVM	0.3853	0.402	0.3799	0.3907
FKNN	0.6422	0.6423	0.6417	0.642
MKNN	0.6202	0.6181	0.6144	0.6162
CKNN	0.5156	0.5085	0.5176	0.513
CoKNN	0.5927	0.5876	0.585	0.5863
CuKNN	0.611	0.6092	0.6046	0.6069
WKNN	0.6477	0.6472	0.6474	0.6473
BT	0.6	0.6317	0.6144	0.6229
BAT	0.7284	0.7251	0.7259	0.7255
SD	0.3927	0.3993	0.3935	0.3964
SKNN	0.4073	0.4088	0.4054	0.4071
RBT	0.6092	0.6519	0.626	0.6387
NNN	0.589	0.5873	0.5893	0.5883
MNN	0.6679	0.6688	0.6741	0.6714
WNN	0.6954	0.6935	0.6921	0.6928
BNN	0.655	0.6535	0.6589	0.6562
TNN	0.6385	0.6362	0.6392	0.6377
OBE	0.7156	0.7126	0.7180	0.7153

Tablo 23, DWT yöntemi kullanılarak kaçak tüketim yapan motorların makine öğrenmesi algoritmaları ile sınıflandırma sonuçlarını göstermektedir. Bu tabloda en iyi sonuçlar, %90.83 doğruluk, %90.72 hassasiyet, %90.69 duyarlılık ve %90.71 F1-skoru ile OBE algoritması ile elde edilmiştir. BAT modeli de %89.36 doğruluk, %89.76 hassasiyet, %89.08 duyarlılık ve %89.42 F1-skoru ile yüksek performans sergilemiştir. FT modeli %81.65 doğruluk, %81.64 hassasiyet, %81.50 duyarlılık ve %81.57 F1-skoru ile dikkate değer sonuçlar vermiştir. QSVM modeli %73.39 doğruluk, %74.54 hassasiyet, %72.47 duyarlılık ve %73.49 F1-skoru ile başarılı olmuştur. CSVM modeli ise %78.35 doğruluk, %78.28 hassasiyet, %77.88 duyarlılık ve %78.08 F1-skoru ile iyi performans sergilemiştir. Diğer modeller, özellikle GNB, CT ve ELR, daha düşük doğruluk ve hassasiyet oranları ile zayıf performans göstermiştir. Bu sonuçlar, tek faz akım verisi kullanıldığında DWT yöntemiyle en iyi performansı OBE algoritmasının gerçekleştirdiğini göstermektedir.

Tablo 23. DWT yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları

Model	Doğruluk	Hassasiyet	Duyarlılık	F1-skor
FT	0.8165	0.8164	0.815	0.8157
MT	0.7229	0.7214	0.7249	0.7232
CT	0.4624	0.4679	0.4736	0.4707
LD	0.4294	0.428	0.4281	0.428
ELR	0.3872	-	0.4078	-
ELSVM	0.4679	0.585	0.4786	0.5265
GNB	0.3761	0.4358	0.3728	0.4018
KNB	0.5101	0.5235	0.5086	0.5159
LSVM	0.6495	0.6537	0.6467	0.6502
QSVM	0.7339	0.7454	0.7247	0.7349
CSVM	0.7835	0.7828	0.7788	0.7808
FGSVM	0.6606	0.7467	0.6456	0.6925
MGSVM	0.655	0.6627	0.6477	0.6551
CGSVM	0.5083	0.5458	0.4921	0.5176
FKNN	0.7651	0.7629	0.761	0.7619
MKNN	0.6972	0.6937	0.6925	0.6931
CKNN	0.4954	0.4986	0.489	0.4938
CoKNN	0.7156	0.7102	0.7102	0.7102
CuKNN	0.6771	0.6735	0.6706	0.672
WKNN	0.7321	0.7296	0.7306	0.7301
BT	0.7615	0.7719	0.7652	0.7685
BAT	0.8936	0.8976	0.8908	0.8942
SD	0.6752	0.6735	0.6726	0.673
SKNN	0.7321	0.7319	0.7295	0.7307
RBT	0.7321	0.7522	0.7388	0.7455
NNN	0.6752	0.6716	0.6756	0.6736
MNN	0.7651	0.7636	0.7665	0.765
WNN	0.7688	0.7685	0.7675	0.768
BNN	0.7486	0.7472	0.7492	0.7482
TNN	0.7413	0.7426	0.7369	0.7397
OBE	0.9083	0.9072	0.9069	0.9071

FWHT yöntemi kullanılarak kaçak tüketim yapan motorların makine öğrenmesi algoritmaları ile sınıflandırma sonuçları Tablo 24’de verilmiştir. En iyi sonuçlar, OBE algoritması ile elde edilmiştir. Bu model %79.82 doğruluk, %80.29 hassasiyet, %79.43 duyarlılık ve %79.85 F1-skoru ile en yüksek performansı sergilemiştir. Bunu %79.08 doğruluk, %79.15 hassasiyet, %79.07 duyarlılık ve %79.11 F1-skoru ile TNN modeli takip etmektedir. BAT modeli de %76.88 doğruluk, %77.22 hassasiyet, %76.38 duyarlılık ve %76.79 F1-skoru ile yüksek performans göstermiştir. FT modeli %74.31 doğruluk, %74.88

hassasiyet, %74.04 duyarlılık ve %74.46 F1-skoru ile dikkat çekmiştir. CSVM modeli %75.23 doğruluk, %75.16 hassasiyet, %74.94 duyarlılık ve %75.05 F1-skoru ile iyi performans sergilemiştir. Diğer modeller arasında BT ve WNN modelleri de nispeten yüksek performans göstermiştir. Buna karşın, ELR ve ELSVM gibi bazı modeller düşük performans sergilemiştir. Bu bulgular, tek faz akım verisi kullanıldığında FWHT yöntemiyle en iyi performansı OBE algoritmasının gerçekleştirdiğini göstermektedir


Tablo 24. FWHT yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları

Model	Doğruluk	Hassasiyet	Duyarlılık	F1-skor
FT	0.7431	0.7488	0.7404	0.7446
MT	0.5725	0.5639	0.563	0.5634
CT	0.6642	0.6617	0.6604	0.6611
LD	0.4404	0.4412	0.4418	0.4415
ELR	0.2862	0.2910	0.2687	0.2659
ELSVM	0.3101	0.3199	0.3361	0.3278
GNB	0.3798	0.3985	0.3994	0.3989
KNB	0.4807	0.4794	0.4937	0.4864
LSVM	0.5009	0.4943	0.5023	0.4983
QSVM	0.633	0.6297	0.6293	0.6295
CSVM	0.7523	0.7516	0.7494	0.7505
FGSVM	0.6422	0.6593	0.6399	0.6494
MG SVM	0.5339	0.5269	0.5358	0.5313
CGSVM	0.389	0.4242	0.3901	0.4064
FKNN	0.6312	0.6297	0.6302	0.6299
MKNN	0.5853	0.5797	0.5786	0.5791
CKNN	0.4862	0.482	0.4878	0.4849
CoKNN	0.5743	0.5647	0.5682	0.5665
CuKNN	0.6257	0.6648	0.6247	0.6441
WKNN	0.6385	0.6378	0.6376	0.6377
BT	0.7119	0.7297	0.7091	0.7193
BAT	0.7688	0.7722	0.7638	0.7679
SD	0.4991	0.4991	0.5013	0.5002
SKNN	0.6826	0.68	0.6811	0.6805
RBT	0.6881	0.6973	0.6909	0.6941
NNN	0.6844	0.683	0.6842	0.6836
MNN	0.6954	0.6976	0.6927	0.6952
WNN	0.7174	0.7177	0.7139	0.7158
BNN	0.5138	0.5234	0.5199	0.5216
TNN	0.7908	0.7915	0.7907	0.7911
OBE	0.7982	0.8029	0.7943	0.7985

Şekil 37’de verilen karışıklık matrisleri, Örüntü analizi, DWT yöntemi ve FWHT yöntemi ile en iyi sınıflandırma sonucu veren topluluk yöntemlerinin test verisi üzerindeki


performansını göstermektedir. Örüntü analizi yönteminde, sınıf 1 (4 kW) motorlar %78.5 doğrulukla (124 doğru, 34 yanlış), sınıf 2 (7.5 kW) motorlar %77.0 doğrulukla (104 doğru, 31 yanlış), sınıf 3 (15 kW) motorlar %60.3 doğrulukla (88 doğru, 58 yanlış) ve sınıf 4 (22 kW) motorlar %71.7 doğrulukla (76 doğru, 30 yanlış) sınıflandırılmıştır. DWT yöntemi ile Sınıf 1 motorları %94.5 doğrulukla (137 doğru, 8 yanlış), sınıf 2 motorları %90.8 doğrulukla (129 doğru, 13 yanlış), sınıf 3 motorları %88.7 doğrulukla (133 doğru, 17 yanlış) ve sınıf 4 motorları %88.9 doğrulukla (96 doğru, 12 yanlış) sınıflandırmıştır. FWHT yöntemi ise, sınıf 1 motorları %86.4 doğrulukla (127 doğru, 20 yanlış), Sınıf 2 motorları %77.3 doğrulukla (116 doğru, 34 yanlış), sınıf 3 motorları %73.2 doğrulukla (112 doğru, 41 yanlış) ve sınıf 4 motorları %84.2 doğrulukla (80 doğru, 15 yanlış) sınıflandırmıştır. Genel olarak, DWT yöntemi, tüm sınıflarda en yüksek doğruluk oranlarını sağlayarak en iyi performansı sergilemiştir. Örüntü Analizi ve FWHT yöntemi ise belirli sınıflarda kabul edilebilir sonuçlar vermiş olsa da, genel olarak DWT yönteminden daha düşük doğruluk oranlarına sahip olmuşlardır.

Şekil 38’de verilen ROC eğrileri, Örüntü analizi, DWT yöntemi ve FWHT yöntemi ile en iyi sınıflandırma sonucu veren topluluk yöntemlerinin test verisi üzerindeki performansını göstermektedir. ROC eğrisi, TPR ile FPR arasındaki ilişkiyi göstermektedir ve AUC değeri, modelin ayırt edici gücünü temsil etmektedir. Örüntü analizi yönteminde, sınıf 1 için AUC değeri 0.9385, sınıf 2 için 0.9123, sınıf 3 için 0.8652 ve sınıf 4 için 0.9051 olarak gözlemlenmiştir. DWT yöntemi, tüm sınıflarda en yüksek performansı sergilemiştir: sınıf 1 için AUC değeri 0.9862, sınıf 2 için 0.9820, sınıf 3 için 0.9778 ve sınıf 4 için 0.9851. FWHT yöntemi ise, sınıf 1 için AUC değeri 0.9614, sınıf 2 için 0.9488, sınıf 3 için 0.9322 ve sınıf 4 için 0.9461 değerleriyle iyi performans göstermiştir.



Şekil 37. Test verisi üzerinde en iyi sınıflandırma sonucu veren topluluk yöntemlerinin (a) Örüntü analizi (b) DWT yöntemi ve (c) FWHT yöntemi ile performansını gösteren karmaşık matrisleri

Bu sonuçlar, DWT yöntemi'nin, yüksek AUC değerleri ile en iyi sınıflandırma performansını sağladığını göstermektedir. Örüntü Analizi ve FWHT yöntemi de belirli sınıflarda kabul edilebilir performans sergilemiş olsalar da, genel olarak DWT yöntemi'nden daha düşük AUC değerlerine sahiptirler.



Şekil 38. Test verisi üzerinde en iyi sınıflandırma sonucu veren topluluk yöntemlerinin (a) Örüntü Analizi (b) DWT Yöntemi c) FWHT Yönteminin sınıflandırma performansını gösteren ROC eğrileri

Örüntü analizi yöntemi kullanılarak elde edilen lokalizasyon sonuçları Tablo 25’de verilmiştir. MGPR yöntemi, doğrulama aşamasında 78,48 RMSE, 0,96 R^2 ve 50,02 MAE; test aşamasında ise 69,36 RMSE, 0,97 R^2 ve 45,40 MAE değerleri ile en iyi performansı sergilemiştir. Diğer modellerin performansını karşılaştırdığımızda, MGPR yönteminin daha düşük hata oranları sunduğu görülmektedir. Örneğin, QSVM modeli doğrulama aşamasında

133,06 RMSE ve 0,87 R^2 ile iyi performans göstermesine rağmen test aşamasında MGPR kadar başarılı olamamıştır. Benzer şekilde, SEGPR doğrulama aşamasında 102,94 RMSE ve 0,92 R^2 değerleri ile iyi sonuçlar elde etmesine karşın test aşamasında MGPR'nin gerisinde kalmıştır. OBE yöntemi ise doğrulama aşamasında 95,75 RMSE, 0,93 R^2 ve 66,45 MAE; test aşamasında ise 95.10 RMSE, 0,93 R^2 ve 64.86 MAE değerleriyle MGPR yöntemi kadar iyi sonuç üretememiştir.

Tablo 25. Örüntü analizi yöntemi kullanılarak elde edilen lokalizasyon sonuçları

Model	Doğrulama			Test		
	RMSE	R^2	MAE	RMSE	R^2	MAE
LN	230.81	0.61	180.92	230.3	0.62	181.49
MT	164.74	0.8	115.42	152.72	0.83	105.13
CT	206.42	0.69	151.54	193.25	0.73	143.03
LSVM	235.29	0.6	178.85	236.12	0.6	179.09
QSVM	133.06	0.87	94.64	128.69	0.88	92.3
CSVM	417.21	-0.26	146.58	124.28	0.89	85.09
FGSVM	133.41	0.87	89.51	116.23	0.9	76.9
MGSVM	148.11	0.84	102.48	143.64	0.85	98.58
CGSVM	231.24	0.61	171.5	230.09	0.62	169.97
BT	148.36	0.84	112.31	150.61	0.84	111.46
BAT	119.76	0.9	82.6	117.11	0.9	76.97
SEGPR	102.94	0.92	55.9	69.39	0.97	47.34
MGPR	78.48	0.96	50.02	69.36	0.97	45.4
EGPR	83.15	0.95	51.9	79.48	0.95	48.25
RQGPR	78.02	0.96	51.46	69.37	0.97	47.34
NNN	89.35	0.94	61.19	85.13	0.95	58.72
MNN	79.7	0.95	53.79	75.9	0.96	50.37
BNN	81.5	0.95	56.48	90.74	0.94	65.63
TNN	81.67	0.95	55.17	77.99	0.96	52.29
OBE	95.75	0.93	66.45	95.1	0.93	64.86

Tablo 26, DWT yöntemi kullanılarak elde edilen lokalizasyon sonuçları verilmiştir. OBE algoritması, doğrulama aşamasında 59.71 RMSE, 0.97 R^2 ve 41.86 MAE; test aşamasında ise 53.44 RMSE, 0.98 R^2 ve 37.25 MAE değerleri ile diğer modellere kıyasla üstün performans sergilemiştir. Diğer modellerin performanslarına baktığımızda, SEGPR modeli doğrulama aşamasında 98.43 RMSE, 0.93 R^2 ve 67.16 MAE; test aşamasında ise 74.69 RMSE, 0.95 R^2 ve 56.30 MAE değerleriyle iyi sonuçlar elde etmiştir. MGPR modeli

de yüksek doğruluk ve düşük hata oranlarıyla dikkat çekmiş, doğrulama aşamasında 88.84 RMSE, 0.94 R^2 ve 61.04 MAE; test aşamasında ise 73.65 RMSE, 0.96 R^2 ve 50.72 MAE değerleriyle başarılı olmuştur. RQGPR modeli de benzer şekilde yüksek performans sergileyerek doğrulama aşamasında 83.57 RMSE, 0.95 R^2 ve 56.71 MAE; test aşamasında ise 70.07 RMSE, 0.96 R^2 ve 47.13 MAE değerlerini elde etmiştir. NN modelleri arasında, BNN doğrulama aşamasında 150.72 RMSE, 0.84 R^2 ve 89.39 MAE; test aşamasında 136.76 RMSE, 0.86 R^2 ve 76.62 MAE değerleri ile başarılı sonuçlar elde etmiştir. Ancak, LN ve LSVM gibi modeller düşük R^2 ve yüksek RMSE değerleri ile zayıf performans sergilemiştir.

Tablo 26. DWT yöntemi kullanılarak elde edilen lokalizasyon sonuçları

Model	Doğrulama			Test		
	RMSE	R^2	MAE	RMSE	R^2	MAE
LN	4229.97	-128.38	2320.35	571.05	-1.36	336.53
MT	134.69	0.87	81.74	111.27	0.91	67.06
CT	179.45	0.82	107.63	151.72	0.86	126.13
LSVM	167.05	0.8	109.94	156.48	0.82	108.08
QSVM	645.02	-2.01	118.47	202.51	0.71	94.91
CSVM	5645.34	-229.46	271.83	479.59	-0.66	118.24
FGSVM	226.41	0.63	166.11	211.06	0.68	146.05
MGSVM	144.44	0.85	101.42	143.64	0.85	98.58
CGSVM	215.13	0.67	155.75	208.49	0.69	147.42
BT	144.68	0.83	122.7	159.63	0.85	98.36
BAT	87.94	0.93	69.11	74.69	0.93	57.37
SEGPR	98.43	0.93	67.16	74.69	0.95	56.3
MGPR	88.84	0.94	61.04	73.65	0.96	50.72
EGPR	85.72	0.95	61.94	74.69	0.95	49.42
RQGPR	83.57	0.95	56.71	70.07	0.96	47.13
NNN	171.91	0.79	102.32	170	0.79	97.85
MNN	152.78	0.83	95.56	157.51	0.82	86.02
BNN	150.72	0.84	89.39	136.76	0.86	76.62
TNN	156.3	0.83	94.87	137.7	0.84	78.67
OBE	59.71	0.97	41.86	53.44	0.98	37.25

Tablo 27, test veri seti için DWT tekniğinden elde edilen maksimum hata, ortalama hata ve standart sapma değerlerinin sonuçlarını sunmaktadır. Algoritmanın performansı, farklı seviyelerdeki ilgili detay katsayılarıyla birlikte çeşitli ana dalgacıklar kullanılarak değerlendirilmiştir. Db18 ana dalgacığı seviye 1 katsayıları ile lokasyon tespitinde %18,78

maksimum hata, %3,02 ortalama hata ve %3,19 standart sapma deęerleri elde edilmiřtir. Bylece ana dalgacıklar ierisinde en dřk ortalama deęer gzlemlenmiřtir. Seviye 3 katsayıları ile %67,76 en yksek maksimum hata oranı elde edilmiřtir. Dięer seviyelere bakıldığında, db17 dalgacıęı ile seviye 1 sonuları, maksimum hata %17,93, ortalama hata %3,08 ve standart sapma %3,03 olarak belirtilmiřtir. Elde edilen sonular ana dalgacıklar ierisinde en dřk maksimum hata ve standart sapma deęerlerinin db17 dalgacıęı seviye 1 katsayıları ile elde edildięini gstermektedir. Db10 dalgacıęı ile maksimum hata %19,42, ortalama hata %3,10 ve standart sapma %3,15 olarak belirlenmiřtir. Db18 ve db17'ye kıyasla daha yksek hata deęerleri gstermektedir. Db7 ve db6 dalgacıkları da, benzer řekilde maksimum hata ve ortalama hata deęerlerinde yksek deęerler gstermektedir. zellikle db6 ile seviye 5'te maksimum hata %44,55 olarak gzlemlenmiřtir, Db5 ve db4 dalgacıkları ise farklı seviyelerde deęiřen hata oranlarına sahiptir. Db5 ile seviye 1'de maksimum hata %38,70 iken, db4 ile seviye 1'de %37,73 olarak belirtilmiřtir. Ortalama hata oranları ise sırasıyla 3,06 ve 3,07'dir. Standart sapma olarak db5 dalgacıęı ile %3.56, db4 dalgacıęı ile %3.46 deęerleri elde edilmiřtir.

Tablo 27. DWT tekniğinden elde edilen maksimum hata, ortalama hata ve standart sapma değerleri

Ana dalgacık	Hata	1.Seviye	2.Seviye	3.Seviye	4.Seviye	5.Seviye
Db18	Maks. Hata	18.78	22.87	67.76	40.32	36.13
	Ort. Hata	3.02	3.52	4.14	3.56	3.87
	Std. Sapma	3.19	3.42	5.02	3.63	4.11
Db17	Maks. Hata	17.93	22.65	34.24	56.89	50.56
	Ort. Hata	3.08	3.71	3.75	3.83	3.96
	Std. Sapma	3.03	3.85	4.01	4.05	4.63
Db10	Maks. Hata	19.42	35.31	53.84	28.44	33.13
	Ort. Hata	3.10	3.22	3.50	3.60	4.02
	Std. Sapma	3.15	3.50	4.19	2.73	4.06
Db7	Maks. Hata	20.12	21.17	36.43	26.7	29.5
	Ort. Hata	3.06	3.32	3.65	3.35	3.65
	Std. Sapma	3.12	3.42	3.87	3.63	3.80
Db6	Maks. Hata	37.93	28.65	38.45	40.45	44.55
	Ort. Hata	3.15	3.81	3.90	3.83	4.16
	Std. Sapma	3.46	3.95	4.01	4.24	4.53
Db5	Maks. Hata	38.70	39.31	45.84	29.44	31.73
	Ort. Hata	3.06	3.22	3.45	3.38	4.09
	Std. Sapma	3.56	3.40	4.10	3.72	4.20
Db4	Maks. Hata	37.73	38.90	44.84	30.72	32.44
	Ort. Hata	3.07	3.12	3.67	3.30	4.14
	Std. Sapma	3.46	3.58	4.15	3.52	4.28

FWHT yöntemi ile elde edilen lokalizasyon sonuçları Tablo 28’de verilmiştir. OBE algoritması, doğrulama aşamasında 82.38 RMSE, 0.95 R^2 ve 54.34 MAE; test aşamasında ise 83.99 RMSE, 0.95 R^2 ve 53.71 MAE değerleri ile diğer modellere kıyasla üstün performans sergilemiştir. Diğer modellere baktığımızda, MGPR ve RQGPR modelleri de yüksek performans sergilemiştir. MGPR modeli, doğrulama aşamasında 90.09 RMSE, 0.95 R^2 ve 56.64 MAE; test aşamasında ise 76.87 RMSE, 0.95 R^2 ve 49.14 MAE değerlerini elde etmiştir. Benzer şekilde, RQGPR modeli de doğrulama aşamasında 90.09 RMSE, 0.95 R^2 ve 56.64 MAE; test aşamasında ise 76.87 RMSE, 0.95 R^2 ve 49.14 MAE değerleri ile dikkat çekmiştir. MT modeli, doğrulama aşamasında 130.8 RMSE, 0.88 R^2 ve 75.89 MAE; test aşamasında ise 116.27 RMSE, 0.89 R^2 ve 77.6 MAE değerleri ile iyi sonuçlar elde etmiştir. BAT modeli de benzer şekilde başarılı sonuçlar vererek doğrulama aşamasında 98.15 RMSE, 0.94 R^2 ve 57.53 MAE; test aşamasında ise 91.23 RMSE, 0.94 R^2 ve 57.14 MAE

değerlerini göstermiştir. Buna karşın, LN ve LSVM gibi modeller düşük performans sergilemiştir.

Tablo 28. FWHT yöntemi kullanılarak elde edilen lokalizasyon sonuçları

Model	Doğrulama			Test		
	RMSE	R ²	MAE	RMSE	R ²	MAE
LN	13646.27	-1346.89	2694.77	6228.52	-279.52	1774.55
MT	130.8	0.88	75.89	116.27	0.89	77.6
CT	151.99	0.85	90.45	142.57	0.85	102.04
LSVM	203.77	0.7	137.27	191.3	0.74	127.93
QSVM	370.72	0.01	110.55	253.77	0.53	94.49
CSVM	169.16	0.79	115.89	153.51	0.82	98.99
FGSVM	169.16	0.79	115.89	153.51	0.82	98.99
MGSVM	180.84	0.74	101.58	153.76	0.87	82.91
CGSVM	235.13	0.64	170.26	230.57	0.67	166.22
BT	123.95	0.89	82.6	141.95	0.85	94.24
BAT	98.15	0.94	57.53	91.23	0.94	57.14
SEGPR	99.49	0.93	58.79	74.04	0.95	49.44
MGPR	90.09	0.95	56.64	76.87	0.95	49.14
EGPR	98.8	0.93	62.06	96.87	0.93	57.46
RQGPR	90.09	0.95	56.64	76.87	0.95	49.14
NNN	208.17	0.76	73.36	182.89	0.76	83.49
MNN	162.64	0.81	95.8	254.59	0.53	86.26
BNN	150.78	0.82	89.49	132.41	0.87	65.36
TNN	146.34	0.83	84.13	140.75	0.82	65.97
OBE	82.38	0.95	54.34	83.99	0.95	53.71

Tek faz akım verisi kullanılarak kaçak yükün devreye girdiği hat lokasyonunun tespitinde en başarılı sonucu DWT yöntemi sunmuştur.

Tablo 29, kaçak elektrik tüketimi yapan yüklerin lokasyonlarını her üç yöntem için karşılaştırmalı olarak sunmaktadır. Tahminler yöntemler için en iyi performansı veren modeller kullanılarak yapılmıştır. Ortalama hata oranları, Örüntü analizi için %4,09, DWT yöntemi için %3,02 ve FWHT yöntemi için %4,86 olarak hesaplanmıştır. DWT yöntemi, çoğu durumda en düşük hata oranlarını sağlayarak daha doğru lokasyon tahmini yapmıştır. Örneğin, 35 metrede devreye giren 22 kW gücünde bir yük için DWT yöntemi hatasız doğru tahmin yaparken, aynı yük için Örüntü analizi %0,27 ve FWHT yöntemi %0,33 hata oranlarına sahiptir. Benzer şekilde, 673 metrede devreye giren 15 kW gücünde bir yük için DWT yöntemi %0,01 hata oranı ile en doğru tahmini sağlamıştır. 7.5 kW ve 4 kW gücündeki


diğer yüklerde de DWT yöntemi en düşük hata oranları ile dikkat çekmiştir. Tablodaki tüm sonuçlar, DWT yönteminin, farklı güç değerlerine sahip motorların varlığında bile diğer yöntemlere göre daha yüksek doğruluk sağladığını göstermektedir. Bu, DWT yönteminin kaçak elektrik tüketimi yapan yüklerin lokasyon tahmininde üstün bir performans sergilediğini kanıtlamaktadır.

Tablo 29. Kaçak elektrik tüketimi yapan yüklerin lokasyonlarının her üç yöntem için karşılaştırmalı olarak sunulması


Güç (kw)	Gerçek (m)	Fider (m)	Örüntü Analizi		DWT Yöntemi		FWHT Yöntemi	
			Tahmin (m)	%Hata	Tahmin (m)	%Hata	Tahmin (m)	%Hata
22	35	1342	38.61	0.27	35	0	39.44	0.33
15	673	1342	705.74	2.44	672.91	0.01	649.08	1.78
7.5	550	1226	473.08	6.27	550.13	0.01	419.62	10.63
4	330	1226	445.76	9.4	330.13	0.04	347.01	5.1
4	980	980	984.01	0.41	980.1	0.01	1013.81	3.45
22	35	1342	34.24	2.19	35.6	0.04	35.44	1.26
15	1178	1342	1134.2	3.26	1178.63	0.05	896.64	20.97
7.5	315	1342	289.5	1.9	315.65	0.05	388.69	5.49
7.5	35	1342	36.32	3.78	35.91	1.1	35.4	1.13
15	1322	1342	1328.76	0.51	1322.7	0.05	1308.04	1.07
4	550	1226	462.5	5.75	548.97	0.31	424.19	10.46
15	1226	1342	586.69	5.09	656.36	0.1	584.19	5.28
15	895	895	818.72	8.54	894.01	0.01	883.68	1.27
7.5	35	1342	710.93	3.28	753.48	1	752.48	2.6
7.5	844	1342	835.44	1.16	841.1	0.15	841.1	6.27
4	1352	1342	528.41	1.51	541.94	0.16	591.74	3.56
15	561	1342	606.13	3.36	558.9	0.16	587.52	1.98

Şekil 39’da, tahmin edilen değerler ile gerçek değerler arasındaki ilişkiyi göstermektedir. Her bir grafikte, yatay ekseninde gerçek değerler, dikey ekseninde ise tahmin edilen değerler yer almaktadır. Mükemmel yanıt veren bir regresyon modelinde, tahmin edilen değerler gerçek değerlere eşitse tüm noktalar doğru üzerinde yer almaktadır. Doğrunun herhangi bir noktadan dikey uzaklığı, o nokta için tahmin hatasını göstermektedir. Yüksek doğruluk derecesine sahip bir regresyon modeli minimum hataya sahip olmakta ve bu da tahmin edilen değerlerin doğrusala yakın bir dağılım göstermesine neden olmaktadır. Grafiklere göre,


DWT yöntemi tahmin edilen ve gerçek değerler arasında en yüksek doğruluğu göstermektedir, çünkü veri noktaları mükemmel tahmin çizgisine en yakın ve en yoğun şekilde dağılmıştır. Örüntü analizi grafiğinde veri noktaları daha geniş bir alana dağılmış olup, bazı tahminlerin gerçek değerlerden önemli ölçüde sapması görülmektedir. FWHT yöntemi ise DWT yöntemi kadar olmasa da oldukça iyi bir performans sergilemiş, ancak yine de bazı sapmalar mevcuttur. Genel olarak, DWT yöntemi en doğru tahminleri yaparken, FWHT yöntemi ve örüntü analizi de kabul edilebilir sonuçlar üretmiştir.



a)



b)



c)

Şekil 39. Test verisi üzerinde en iyi lokalizasyon sonucu veren topluluk yöntemlerinin (a) Örüntü Analizi (b) DWT Yöntemi c) FWHT Yöntemi sonuçları

3.1.2. Üç Faz Akım Verisi ile İlgili Bulgular

Üç faz akım bilgisi kullanılarak DWT yöntemiyle elde edilen sınıflandırma sonuçları Tablo 30’da verilmiştir. Makine öğrenmesi sonuçlarına göre, en iyi performansı OBE algoritması sergilemiştir. OBE algoritması, %93.21 doğruluk, %93.47 hassasiyet, %93.11 duyarlılık ve %93.29 F1-skoru ile en yüksek doğruluk oranına sahiptir. BAT modeli de yüksek performans göstermiş, %90.64 doğruluk, %91.11 hassasiyet, %90.34 duyarlılık ve %90.73 F1-skoru elde etmiştir. FT modeli ise %85.87 doğruluk, %86.07 hassasiyet, %85.81 duyarlılık ve %85.94 F1-skoru ile dikkat çekmiştir. QSVM, CSVM ve BT modelleri de iyi performans sergileyerek sırasıyla %73.94, %77.25 ve %76.33 doğruluk oranlarına ulaşmıştır. Diğer yandan, LD ve ELR gibi modellerin performansları nispeten düşüktür. LD modeli %53.58 doğruluk, %53.45 hassasiyet, %53.76 duyarlılık ve %53.60 F1-skoru, ELR modeli ise %37.06 doğruluk, %52.38 hassasiyet, %34.70 duyarlılık ve %41.74 F1-skoru ile düşük bir performans sergilemiştir.

Tablo 30. DWT yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları

Model	Doğruluk	Hassasiyet	Duyarlılık	F1-skor
FT	0.8587	0.8607	0.8581	0.8594
MT	0.7321	0.7311	0.7341	0.7326
CT	0.4881	0.6102	0.5117	0.5566
LD	0.5358	0.5345	0.5376	0.536
ELR	0.3706	0.5238	0.347	0.4174
ELSVM	0.4862	-	0.4542	-
GNB	0.3945	0.4468	0.391	0.417
KNB	0.5009	0.531	0.5018	0.516
LSVM	0.6606	0.6637	0.6554	0.6595
QSVM	0.7394	0.7558	0.73	0.7427
CSVM	0.7725	0.771	0.7673	0.7691
FGSVM	0.6771	0.7624	0.664	0.7098
MGsVM	0.6532	0.6645	0.6472	0.6557
CGSVM	0.4936	0.5172	0.4777	0.4967
FKNN	0.7615	0.7605	0.7576	0.759
MKNN	0.7138	0.7101	0.7085	0.7093
CKNN	0.4862	0.487	0.4787	0.4828
CoKNN	0.7229	0.7181	0.7231	0.7206
CuKNN	0.6972	0.6931	0.693	0.6931
WKNN	0.7431	0.7405	0.7397	0.7401
BT	0.7633	0.7772	0.7628	0.7699
BAT	0.9064	0.9111	0.9034	0.9073
SD	0.567	0.5675	0.5707	0.5691
SKNN	0.7211	0.7232	0.7203	0.7217
RBT	0.7651	0.7669	0.7698	0.7684
NNN	0.7119	0.7067	0.708	0.7074
MNN	0.7908	0.7892	0.7915	0.7904
WNN	0.7761	0.774	0.7736	0.7738
BNN	0.7633	0.7594	0.7622	0.7608
TNN	0.7468	0.7437	0.7446	0.7441
OBE	0.9321	0.9347	0.9311	0.9329

Tablo 31’de, sınıflandırma çalışması için FWHT yöntemi kullanılarak çeşitli makine öğrenmesi modellerinin performans sonuçları verilmiştir. En iyi performansı, %79.82 doğruluk, %79.68 hassasiyet, %79.42 duyarlılık ve %79.55 F1-skoru ile OBE algoritması göstermiştir. FT modeli %74.31 doğruluk, %74.88 hassasiyet, %74.04 duyarlılık ve %74.46 F1-skoru ile iyi bir performans sergilemiştir. MT modeli ise %62.57 doğruluk, %66.48 hassasiyet, %62.47 duyarlılık ve %64.41 F1-skoru ile kabul edilebilir bir performans

göstermiştir. Diğer yandan, CT modeli %51.38 doğruluk, %52.34 hassasiyet, %51.99 duyarlılık ve %52.16 F1-skoru ile düşük bir performans sergilemiştir. LD modeli %44.04 doğruluk, %44.12 hassasiyet, %44.18 duyarlılık ve %44.15 F1-skoru ile zayıf bir performans göstermiştir. ELR ve ELSVM modelleri, sırasıyla %40.18 ve %32.66 doğruluk oranları ile en düşük performansı sergilemişlerdir. GNB modeli %37.98 doğruluk, %39.85 hassasiyet, %39.94 duyarlılık ve %39.89 F1-skoru ile benzer şekilde düşük bir performans sergilemiştir. KNB modeli ise %48.07 doğruluk, %47.94 hassasiyet, %49.37 duyarlılık ve %48.64 F1-skoru ile biraz daha iyi bir performans sergilemiştir.



Tablo 31. FWHT yöntemi kullanılarak elde edilen yük sınıflandırma sonuçları


Model	Doğruluk	Hassasiyet	Duyarlılık	F1-skor
FT	0.7431	0.7488	0.7404	0.7446
MT	0.6257	0.6648	0.6247	0.6441
CT	0.5138	0.5234	0.5199	0.5216
LD	0.4404	0.4412	0.4418	0.4415
ELR	0.4018	-	0.4118	-
ELSVM	0.3266	0.3509	0.3106	0.3296
GNB	0.3798	0.3985	0.3994	0.3989
KNB	0.4807	0.4794	0.4937	0.4864
LSVM	0.5064	0.5014	0.508	0.5047
QSVM	0.6367	0.6331	0.6315	0.6323
CSVM	0.7541	0.7522	0.7511	0.7517
FGSVM	0.6422	0.6593	0.6399	0.6494
MGsVM	0.5339	0.5269	0.5358	0.5313
CGSVM	0.389	0.4242	0.3901	0.4064
FKNN	0.6312	0.6297	0.6302	0.6299
MKNN	0.5853	0.5797	0.5786	0.5791
CKNN	0.4862	0.482	0.4878	0.4849
CoKNN	0.5743	0.5647	0.5682	0.5665
CuKNN	0.5725	0.5639	0.563	0.5634
WKNN	0.6385	0.6378	0.6376	0.6377
BT	0.7119	0.7297	0.7091	0.7193
BAT	0.7615	0.7678	0.758	0.7629
SD	0.5174	0.5177	0.5198	0.5187
SKNN	0.6844	0.6826	0.6829	0.6827
RBT	0.6862	0.6914	0.6873	0.6893
NNN	0.6697	0.6844	0.6686	0.6764
MNN	0.7009	0.7007	0.6991	0.6999
WNN	0.7174	0.7143	0.7157	0.715
BNN	0.6862	0.6912	0.6844	0.6878
TNN	0.7174	0.7127	0.709	0.7109
OBE	0.7982	0.7968	0.7942	0.7955

Üç faz akım verisi kullanılarak en iyi sınıflandırma sonucu veren topluluk yöntemlerinin test verisi üzerindeki performansı Şekil 40'daki karmaşık matrislerde gösterilmiştir. Örüntü analizi yöntemi ile sınıf 1 motorlar (4 kW) için %78.5, sınıf 2 motorlar (7.5 kW) için %77, sınıf 3 motorlar (15 kW) için %60.3 ve sınıf 4 motorlar (22 kW) için %71.7 doğruluk oranı elde edilmiştir; genel doğruluk oranı ise %71.9'dur. DWT yöntemi ile sınıf 1 motorlar için %95.8, sınıf 2 motorlar için %91.2, sınıf 3 motorlar için %90.7 ve sınıf


4 motorlar için %96.1 doğruluk oranı elde edilmiştir; genel doğruluk oranı ise %93.2'dir. FWHT yöntemi ile sınıf 1 motorlar için %84.1, sınıf 2 motorlar için %82.5, sınıf 3 motorlar için %72.9 ve sınıf 4 motorlar için %79.2 doğruluk oranı elde edilmiştir; genel doğruluk oranı ise %79.8'dir. Bu sonuçlar, DWT yönteminin diğer yöntemlere kıyasla daha yüksek doğruluk oranları ile en iyi performansı sergilediğini göstermektedir. FWHT yöntemi de yüksek performans göstermiştir ancak DWT yöntemi kadar başarılı değildir. Örüntü Analizi yöntemi ise diğer iki yöntemle göre daha düşük doğruluk oranları ile en düşük performansı sergilemiştir. Bu veriler, DWT yönteminin üç faz akım verisi ile kaçak elektrik kullanan sulama motorlarının sınıflandırılmasında en etkili yöntem olduğunu ortaya koymaktadır.

ROC eğrileri, sınıflandırma modellerinin performansını değerlendirmek için kullanılır ve Şekil 41'de verilen grafikte üç farklı yöntemin test verisi üzerindeki performansı ROC eğrileri ile gösterilmektedir. Örüntü analizi yöntemi için ROC eğrisi, sınıf 1 motorlar için AUC değerinin 0.9385 olduğunu göstermektedir. Sınıf 2 motorlar için AUC değeri 0.9123, sınıf 3 motorlar için AUC değeri 0.8652 ve sınıf 4 motorlar için AUC değeri 0.9051 olarak hesaplanmıştır. DWT yöntemi için ROC eğrisi, sınıf 1 motorlar için 0.994, sınıf 2 motorlar için 0.9896, sınıf 3 motorlar için 0.9916 ve sınıf 4 motorlar için 0.9951 AUC değerlerini göstermektedir. Bu, DWT yönteminin yüksek bir doğrulukla sınıflandırma yapabildiğini göstermektedir.

FWHT yöntemi için ROC eğrisi, sınıf 1 motorlar için 0.962, sınıf 2 motorlar için 0.9542, sınıf 3 motorlar için 0.9251 ve sınıf 4 motorlar için 0.9541 AUC değerlerini göstermektedir. Genel olarak, DWT yöntemi en yüksek AUC değerlerine sahip olup, en iyi performansı sergilemektedir. FWHT yöntemi de yüksek performans göstermekte, ancak DWT yöntemine kıyasla biraz daha düşük kalmaktadır. Örüntü Analizi yöntemi ise diğer iki yöntemle kıyasla daha düşük AUC değerlerine sahiptir. Bu sonuçlar, DWT yönteminin üç faz akım verisi ile kaçak elektrik kullanan sulama motorlarının sınıflandırılmasında en etkili yöntem olduğunu ortaya koymaktadır.



Şekil 40. Test verisi üzerinde en iyi sınıflandırma sonucu veren topluluk yöntemlerinin (a) Örüntü analizi, (b) DWT yöntemi ve (c) FWHT yöntemi ile performansını gösteren karmaşık matrisleri



Şekil 41. Test verisi üzerinde en iyi sınıflandırma sonucu veren topluluk yöntemlerinin (a) Örüntü Analizi (b) DWT Yöntemi c) FWHT Yönteminin sınıflandırma performansını gösteren ROC eğrileri

Tablo 32’de, DWT yöntemi kullanılarak OBE algoritmasının doğrulama ve test performans sonuçlarının diğer makine öğrenimi yöntemleriyle karşılaştırması sunulmuştur. OBE algoritması, doğrulama aşamasında 60.64 RMSE, 0.97 R^2 ve 43.90 MAE; test aşamasında ise 40.91 MAE, 56.40 RMSE ve 0.98 R^2 değerleri ile en yüksek performansı göstermiştir. Diğer yöntemlerle karşılaştırıldığında, LN modeli, doğrulama ve test aşamalarında negatif R^2 değerleri ve yüksek hata oranları ile en düşük performansı sergilemiştir (doğrulama: 4180.50 RMSE, -125.48 R^2 , 2457.26 MAE; test: 2603.67 MAE, 5449.10 RMSE, -213.70

R²). BT modeli de yüksek performans göstermiş, doğrulama aşamasında 90.31 RMSE, 0.94 R² ve 63.75 MAE; test aşamasında ise 61.72 MAE, 84.63 RMSE ve 0.95 R² değerlerine ulaşmıştır. BAT modeli ise doğrulama aşamasında 78.47 RMSE, 0.96 R² ve 50.41 MAE; test aşamasında ise 43.66 MAE, 70.86 RMSE ve 0.96 R² ile iyi sonuçlar vermiştir. GPR yöntemleri, özellikle MGPR, EGPR ve RQGPR, yüksek doğruluk oranları ile dikkat çekmiştir. MGPR doğrulama aşamasında 82.88 RMSE, 0.95 R² ve 57.28 MAE; test aşamasında ise 46.81 MAE, 69.74 RMSE ve 0.96 R² değerleri elde etmiştir. EGPR ve RQGPR benzer performanslar göstermiştir. Diğer modeller arasında, FT ve MT modelleri nispeten iyi performans sergilemiş, ancak OBE algoritmasına göre daha düşük doğruluk oranları ile sonuçlanmıştır. NN modelleri ise genel olarak daha düşük performans göstermiştir.

Tablo 32. DWT yöntemi kullanılarak elde edilen lokalizasyon sonuçları

Model	Doğrulama			Test		
	RMSE	R ²	MAE	RMSE	R ²	MAE
LN	4180.50	-125.48	2457.26	5449.10	-213.70	2603.67
MT	113.68	0.91	68.15	109.29	0.91	63.77
CT	134.13	0.87	94.39	129.87	0.88	84.70
LSVM	141.54	0.86	95.38	141.84	0.85	92.31
QSVM	343.77	0.14	87.77	224.27	0.64	76.54
CSVM	1073.94	-7.35	110.24	184.01	0.76	70.77
FGSVM	229.96	0.62	170.17	216.86	0.66	152.23
MGSVM	134.78	0.87	88.58	122.07	0.89	81.52
CGSVM	207.78	0.69	148.46	198.89	0.71	139.87
BT	90.31	0.94	63.75	84.63	0.95	61.72
BAT	78.47	0.96	50.41	70.86	0.96	43.66
SEGPR	88.68	0.94	61.73	74.15	0.96	50.86
MGPR	82.88	0.95	57.28	69.74	0.96	46.81
EGPR	82.34	0.95	55.45	70.94	0.96	47.15
RQGPR	80.64	0.95	54.37	68.61	0.97	45.05
NNN	127.86	0.88	76.76	128.75	0.88	72.27
MNN	124.45	0.89	74.41	113.67	0.91	65.35
BNN	117.36	0.90	71.82	94.96	0.93	54.71
TNN	115.10	0.90	69.44	92.74	0.94	54.70
OBE	60.64	0.97	43.90	56.40	0.98	40.91

Farklı ana dalgacıklar ve seviye detay katsayıları kullanılarak değerlendirilmiş maksimum hata, ortalama hata ve standart sapma değerleri Tablo 33’de gösterilmektedir. Db18 ana dalgacığının 1. seviye katsayıları, lokalizasyon tespiti açısından en iyi performansı sergilemiş ve maksimum hata %18.97, ortalama hata %3.33, standart sapma ise 3.22 olarak hesaplanmıştır. Bu, diğer seviye ve dalgacıklara kıyasla en düşük hata oranıdır. Db18’in diğer seviyelerinde ise maksimum hata %24.82 ile %44.37 arasında, ortalama hata %4.37 ile %4.68 arasında ve standart sapma 3.73 ile 4.95 arasında değişmektedir. Db17 ana dalgacığında, 1. seviye katsayıları maksimum hata %19.97, ortalama hata %4.05 ve standart sapma 3.70 ile en iyi performansı göstermiştir. Ancak, daha yüksek seviyelerde hata oranları artmıştır; örneğin, 2. seviyede maksimum hata %28.33, 3. seviyede %42.24, 4. seviyede %44.29 ve 5. seviyede %44.23 olarak bulunmuştur. Db10 ana dalgacığında, 1. seviyede maksimum hata %38.69, ortalama hata %4.06 ve standart sapma 4.11 iken, daha yüksek seviyelerde hata oranları genel olarak daha yüksek kalmıştır. Diğer dalgacıklarda da benzer şekilde, daha yüksek seviyelerde maksimum hata oranlarının arttığı gözlemlenmiştir. Özetle, db18 ana dalgacığının 1. seviye katsayıları, diğer kombinasyonlara kıyasla en düşük hata oranları ve en yüksek doğruluk ile en iyi performansı sağlamaktadır. Bu sonuçlar, lokasyon tespiti açısından db18 ana dalgacığının 1. seviye katsayılarının kullanımının en uygun olduğunu göstermektedir.

Tablo 34’de, DWT yöntemi kullanılarak farklı güç seviyelerine sahip motorların OBE algoritması ile yapılan lokalizasyon sonuçları verilmiştir. Tablo, gerçek uzunluk, tahmini uzunluk, fider uzunluğu ve hata yüzdesi ile motorların etkinleştirildiği noktaların doğruluğunu değerlendirmektedir. 4 kW motorlar için, hata oranları %0.02 ile %5.12 arasında değişmekte olup, en düşük hata %0.02 ile 330 metre uzunlukta ve en yüksek hata %5.12 ile 245 metre uzunlukta gözlemlenmiştir. 7.5 kW motorlar için hata oranları %0.58 ile %4.80 arasında değişmekte olup, en düşük hata %0.58 ile 755 metre uzunlukta ve en yüksek hata %4.80 ile 1161 metre uzunlukta görülmüştür. 15 kW motorlar için hata oranları %0.58 ile %3.30 arasında olup, en düşük hata %0.58 ile 655 metre uzunlukta ve en yüksek hata %3.30 ile 773 metre uzunlukta bulunmuştur. 22 kW motorlar için hata oranları %0.09 ile %0.64 arasında olup, en düşük hata %0.09 ile 561 metre uzunlukta ve en yüksek hata %0.64 ile 315 metre uzunlukta gözlemlenmiştir. Bu sonuçlar, önerilen OBE algoritmasının yüksek doğrulukla motorların lokasyon tespitini yapabildiğini ve hata oranlarının genel olarak düşük olduğunu göstermektedir.

Tablo 33. Farklı ana dalgacıklar ve seviye detay katsayıları kullanılarak OBE algoritması ile maksimum hata, ortalama hata ve standart sapma değerlerinin belirlenmesi

Ana Dalgacık	Hata	1. Seviye	2. Seviye	3. Seviye	4. Seviye	5. Seviye
Db18	Maks. Hata	18.97	24.82	42.06	44.37	44.34
	Ortalama Hata	3.33	4.37	4.68	4.37	4.37
	Std. Sapma	3.22	3.73	4.65	4.86	4.95
Db17	Maks. Hata	19.97	28.33	42.24	44.29	44.23
	Ortalama Hata	4.05	4.61	5.19	5.14	5.23
	Std. Sapma	3.70	4.16	4.54	5.68	5.53
Db10	Maks. Hata	38.69	46.71	36.30	43.30	41.68
	Ortalama Hata	4.06	4.41	4.45	4.51	5.03
	Std. Sapma	4.11	4.12	4.45	5.02	5.02
Db7	Maks. Hata	24.20	42.18	31.10	44.67	36.58
	Ortalama Hata	3.77	4.14	4.08	5.03	5.43
	Std. Sapma	3.95	4.72	4.37	5.01	5.01
Db6	Maks. Hata	25.10	29.09	45.34	41.17	50.06
	Ortalama Hata	4.19	4.45	4.82	5.69	5.10
	Std. Sapma	3.86	4.09	4.25	4.69	7.65
Db5	Maks. Hata	29.83	41.83	50.06	56.08	86.71
	Ortalama Hata	4.18	4.19	5.02	5.06	5.06
	Std. Sapma	3.77	4.44	3.38	7.65	7.06
Db4	Maks. Hata	42.11	12.66	44.21	15.63	15.48
	Ortalama Hata	4.45	5.32	5.42	5.63	5.48
	Std. Sapma	4.24	4.78	4.79	5.59	4.97

Tablo 34. DWT yöntemi kullanılarak farklı güç seviyelerine sahip motorların OBE algoritması ile yapılan lokalizasyon sonuçları

Güç(kw)	Gerçek Uzunluk (m)	Tahmini Uzunluk (m)	Feeder Uzunluk (m)	Hata (%)
4	550	489.63	1226	4.92
4	330	329.79	1226	0.02
4	245	259.25	567	5.12
4	255	286.94	1226	2.60
4	30	44.31	1226	1.17
4	895	919.91	1226	2.78
7.5	342	386.25	1226	3.61
7.5	1322	1282.23	1226	2.97
7.5	540	559.14	1226	1.56
7.5	1161	1102.13	1226	4.80
7.5	755	762.83	1226	0.58
7.5	980	957.58	980	2.24
15	773	817.34	1342	3.30
15	205	224.16	1342	1.43
15	655	662.72	1342	0.58
15	430	416.11	1342	1.04
15	923	879.58	1342	3.24
22	561	559.82	1342	0.09
22	943	947.98	1342	0.37
22	315	306.43	1342	0.64
22	561	559.82	1342	0.09
22	943	947.98	1342	0.37

Tablo 35, FWHT yöntemi kullanılarak çeşitli modellerin doğrulama ve test aşamalarındaki RMSE, R^2 ve MAE değerlerini göstermektedir. En iyi performans, OBE algoritması tarafından sağlanmıştır. OBE algoritması, doğrulama aşamasında 81.03 RMSE, 0.95 R^2 ve 55.07 MAE; test aşamasında ise 76.52 RMSE, 0.96 R^2 ve 49.36 MAE değerleri ile en düşük hata oranlarına ve en yüksek doğruluk oranlarına ulaşmıştır. BAT modeli de oldukça iyi performans sergilemiş, doğrulama aşamasında 94.83 RMSE, 0.93 R^2 ve 63.06 MAE; test aşamasında ise 83.46 RMSE, 0.95 R^2 ve 53.70 MAE değerlerine ulaşmıştır. SEGPR ve MGPR modelleri de benzer şekilde yüksek doğruluk oranlarına sahiptir. SEGPR doğrulama aşamasında 94.14 RMSE, 0.94 R^2 ve 55.31 MAE; test aşamasında ise 86.72 RMSE, 0.93 R^2 ve 47.02 MAE değerlerine ulaşmıştır. MGPR ise doğrulama aşamasında 92.04 RMSE, 0.94 R^2 ve 53.64 MAE; test aşamasında ise 102.48 RMSE, 0.92 R^2 ve 47.01

MAE deęerleri ile performans göstermiřtir. Genel olarak, OBE algoritması, FWHT yntemi ile elde edilen zellikler zerinde en iyi performansı sergileyen model olarak ne çıkmaktadır.

Tablo 35. FWHT yntemi kullanılarak elde edilen lokalizasyon sonuları

Model	Doęrulama			Test		
	RMSE	R2	MAE	RMSE	R2	MAE
LN	4508.48	-139.39	2765.28	284310	-293254	251860
MT	130.41	0.88	87.39	107.3	0.92	72.41
CT	152.27	0.83	110.47	127	0.88	92.13
LSVM	190.05	0.74	125.23	174.45	0.78	114.16
QSVM	184.25	0.75	83.42	160.81	0.81	72.88
CSVM	185.9	0.75	87.11	157.84	0.82	73.9
FGSVM	171.43	0.79	115.23	148.43	0.84	97.38
MGSVM	149.87	0.84	103.34	138.48	0.86	94.74
CGSVM	233.41	0.61	169.48	228.59	0.62	164.44
BT	98.58	0.93	73.16	94.11	0.94	69.69
BAT	94.83	0.93	63.06	83.46	0.95	53.7
SEGPR	94.14	0.94	55.31	86.72	0.93	47.02
MGPR	92.04	0.94	53.64	102.48	0.92	47.01
EGPR	98.32	0.93	62.7	94.37	0.94	57.29
RQGPR	92.85	0.94	54.3	102.49	0.92	47.23
NNN	111.38	0.91	56.29	164.86	0.8	50.91
MNN	142.07	0.85	61.52	172.67	0.78	55.74
BNN	110.31	0.91	62.58	113.34	0.91	58.6
TNN	113.54	0.91	58.15	130.91	0.88	49.86
OBE	81.03	0.95	55.07	76.52	0.96	49.36

FWHT yntemi kullanılarak farklı g seviyelerine sahip motorların OBE algoritması ile yapılan lokalizasyon sonuları Tablo 36’da verilmiřtir. 4 kW motorlar iin hata oranları %1.94 ile %6.61 arasında deęiřmektedir. rneęin, 550 m uzunluęundaki bir hat lokasyonu iin tahmini uzunluk 489 m olup hata oranı %4.98’dir; 330 m uzunluęundaki bir hat lokasyonu iin tahmini uzunluk 411 m olup hata oranı %6.61’dir. 7.5 kW motorlar iin hata oranları %6.04 ile %16.07 arasında deęiřmektedir. rneęin, 895 m uzunluęundaki bir hat

lokasyonu için tahmini uzunluk 1019 m olup hata oranı %13.85'dir; 342 m uzunluğundaki bir hat lokasyonu için tahmini uzunluk 539 m olup hata oranı %16.07'dir. 15 kW motorlar için hata oranları %0.75 ile %9.59 arasında değişmektedir. Örneğin, 755 m uzunluğundaki bir hat lokasyonu için tahmini uzunluk 662 m olup hata oranı %6.93'dir; 205 m uzunluğundaki bir hat lokasyonu için tahmini uzunluk 215 m olup hata oranı %0.75'dir. 22 kW motorlar için hata oranları %0.52 ile %6.78 arasında değişmektedir. Örneğin, 430 m uzunluğundaki bir hat lokasyonu için tahmini uzunluk 418 m olup hata oranı %0.89'dir; 315 m uzunluğundaki bir hat lokasyonu için tahmini uzunluk 322 m olup hata oranı %0.52'dir.

Tablo 36. FWHT yöntemi kullanılarak farklı güç seviyelerine sahip motorların OBE algoritması ile yapılan lokalizasyon sonuçları

P(kw)	Gerçek Uzunluk (m)	Tahmini Uzunluk (m)	Hat Uzunluk	%Hata
4	550	489	1226	4.98
4	330	411	1226	6.61
4	245	234	567	1.94
4	255	185	1226	5.71
4	30	89	1226	4.81
7.5	895	1019	895	13.85
7.5	342	539	1226	16.07
7.5	1322	1226	1342	7.15
7.5	540	347	1226	15.74
7.5	1161	1087	1226	6.04
15	755	662	1342	6.93
15	980	886	980	9.59
15	773	803	1342	2.24
15	205	215	1342	0.75
15	655	583	1342	5.37
22	430	418	1342	0.89
22	923	835	1342	6.56
22	561	652	1342	6.78
22	943	904	1342	2.91
22	315	322	1342	0.52


Tablo 37’de, kaçak elektrik tüketimi yapan yüklerin üç farklı yöntem kullanılarak tahmin edilen lokalizasyon sonuçları verilmiştir. Öznitelik vektörleri, örüntü analizi yönteminde tek faz akım bilgisinden, DWT ve FWHT yöntemlerinde ise üç faz akım bilgisinden elde edilmiştir. Ortalama hata oranları, Örüntü analizi yöntemi için %4,09, DWT yöntemi için %3,33 ve FWHT yöntemi için %4,47 olarak belirlenmiştir. Bu sonuçlar, DWT yönteminin diğer yöntemlere göre daha doğru lokasyon tahmini sağladığını göstermektedir. Örneğin, 15 kW gücündeki bir yük için gerçek lokasyon 673 m iken, Örüntü analizi yöntemi ile tahmin edilen lokasyon 705.74 m ve hata oranı %2.44, DWT yöntemi ile tahmin edilen lokasyon 676.93 m ve hata oranı %0.29, FWHT yöntemi ile tahmin edilen lokasyon 701 m ve hata oranı %2.09 olmuştur. DWT yöntemi ile tahmin edilen lokasyonların hata oranları genellikle düşük olup, en düşük hata oranı %0.02 ile 4 kW gücündeki 330 m gerçek uzunlukta elde edilmiştir. FWHT yöntemi de bazı durumlarda kabul edilebilir performans göstermiş olsa da, DWT yöntemine göre genellikle daha yüksek hata oranlarına sahiptir. Örüntü analizi yönteminde ise bazı durumlarda yüksek hata oranları gözlemlenmiştir.

Tablo 37. Kaçak elektrik tüketimi yapan yüklerin tahmin edilen lokasyonlarının üç farklı yöntem kullanılarak karşılaştırılması


Güç (kw)	Gerçek (m)	Fider (m)	Örüntü Analizi		DWT Yöntemi		FWHT Yöntemi	
			Tahmin (m)	%Hata	Tahmin (m)	%Hata	Tahmin (m)	%Hata
22.00	35.00	1342.00	38.61	0.27	17.37	1.31	39.44	0.33
15.00	673.00	1342.00	705.74	2.44	676.93	0.29	701.00	2.09
7.50	550.00	1226.00	473.08	6.27	521.78	2.30	419.62	10.63
4.00	330.00	1226.00	445.76	9.40	329.79	0.02	410.95	6.60
4.00	980.00	980.00	984.01	0.41	1013.68	3.44	1013.81	3.45
22.00	35.00	1342.00	34.24	2.19	30.77	0.32	38.82	0.28
15.00	1178.00	1342.00	1134.20	3.26	1129.24	3.63	1099.50	5.85
7.50	315.00	1342.00	289.50	1.90	324.87	0.74	382.96	5.06
7.50	35.00	1342.00	36.32	3.78	47.87	0.96	58.26	1.73
15.00	1322.00	1342.00	1328.76	0.51	1320.89	0.08	1274.03	3.57
4.00	550.00	1226.00	462.50	5.75	489.63	4.92	489.41	4.94
15.00	1226.00	1226.00	586.69	5.09	1195.44	2.49	1221.75	0.35
15.00	895.00	895.00	818.72	8.54	967.87	8.14	1038.53	16.04
7.50	35.00	1342.00	710.93	3.28	47.87	0.96	58.26	1.73
7.50	844.00	859.00	835.44	1.16	848.50	0.52	883.93	4.65
4.00	1352.00	1342.00	528.41	1.51	1290.53	3.84	1323.71	1.36
15.00	561.00	1342.00	606.13	3.36	587.34	1.96	564.63	0.27

Üç faz akım verisi kullanılarak üç yöntemde de en iyi performans gösteren model tahminlerinin ve gerçek değerlerin karşılaştırılması Şekil 42’de gösterilmektedir. Örüntü analizi grafiği modelin tahmin edilen değerlerle gerçek değerler arasındaki ilişkiyi ortaya koyarken, bazı sapmalar ve hatalar göstermektedir. Bu durum, örüntü analizi yönteminin genel olarak iyi performans sergilediğini ancak bazı durumlarda hatalar yapabileceğini göstermektedir. DWT yöntemi grafiğinde, noktaların ideal tahmin çizgisine daha yakın ve düzenli bir şekilde dağılmış olduğu görülmektedir, bu da DWT yönteminin daha yüksek doğruluk sağladığını ve daha az hata yaptığını ifade etmektedir. FWHT yöntemi grafiği incelendiğinde, noktalar ideal tahmin çizgisine yakın bir şekilde dağılmış ancak bazı noktalar çizgiden daha fazla sapma göstermiştir. Bu durum, FWHT yönteminin genel performansının iyi olduğunu ancak bazı durumlarda sapmaların olabileceğini belirtmektedir.


Genellikle, DWT yöntemi en yüksek doğrulukla tahmin yaparken, FWHT yöntemi de yüksek performans sergilemekte ve örüntü analizine göre daha az hata yapmaktadır.



a)



b)



c)

Şekil 42. Test verisi üzerinde en iyi lokalizasyon sonucu veren topluluk yöntemlerinin (a) Örüntü Analizi (b) DWT Yöntemi c) FWHT Yöntemi sonuçları

3.1.3. Saha Çalışması

Saha çalışması için F1 fideri seçilmiştir. Bu fider hattı boyunca farklı zamanlarda ve lokasyonlarda 22 kw motorlar devreye alınmış ve fider başlangıç noktasından ölçüm devresiyle üç faz akım verisi toplanmıştır. Şekil 43’de, ölçüm bileşenleri ve veri örnekleme

devresinin montajlanması verilmiştir. Veri örnekleme devresinde motor aktivasyonunu doğru bir şekilde tespit etmek amacıyla, 10-bit çözünürlükte analog dijital dönüştürücüler bulunmakta ve 1.4 kHz'de örnekleme yapmaktadır. Şekil 44'de ölçülen verilerin kablosuz olarak iletildiği veri toplayıcısının montajı görülmektedir. Toplanan veriler, IPv6 bağlantısı üzerinden 4G/LTE baz istasyonu kullanılarak merkezi yönetim sunucusuna iletilmektedir.


Şekil 45, farklı mesafelerde (561 m, 655 m, 907 m ve 944 m) üç fazlı akım ölçümlerini göstermektedir ve tarımsal sulama motorlarının devreye girip çıkması sırasında meydana gelen akım dalgalanmalarını detaylı bir şekilde sunmaktadır. Motorlar ayrı ayrı devreye alınmış ve çok kısa bir süre çalıştırılarak fider ucundan ölçümler alınmıştır. Elde edilen ölçümler ön işleme adımıyla simülasyon veri penceresine uygun olarak düzenlenerek 2 sn akım penceresi haline getirilmiştir. Elde edilen veri penceresi DWT yöntemiyle eğitilen OBE modelinde test verisi olarak kullanılmıştır. Ia, Ib ve Ic faz akımları başlangıçta düşük genlikte olup, motorlar devreye girdiğinde genlikte ani bir artış gözlenmektedir. 0,3 saniyede motorun devreye girdiği ve bu noktadan sonra akımların belirgin bir şekilde artarak nominal değerine ulaştığı görülmektedir. Elde edilen grafikler simülasyon verileriyle uygun bir sonuç üretmektedir.



Şekil 43. Ölçüm bileşenlerinin ve veri örnekleme devresinin montajı



Şekil 44. Veri toplayıcısının montajı



Şekil 45. Farklı zamanlarda devreye giren sulama motorları için gerçek saha ölçümleri

DWT yöntemi kullanılarak en iyi sonucu veren OBE algoritmasının gerçek saha test verileri ile elde edilen maksimum hata, ortalama hata ve standart sapma değerleri Tablo 38’de verilmektedir. OBE algoritması kullanılarak yapılan analizlerde, farklı ana dalgacıklar ve seviye detay katsayıları kullanılarak elde edilen performans sonuçları değerlendirilmektedir. Tablo incelendiğinde, db18 ana dalgacığ kullanılarak yapılan dalgacık ayrıştırması sonrasında elde edilen 1. seviye katsayıları, %9.94 maksimum hata, %4.43 ortalama hata ve %3.92 standart sapma ile en iyi performansı sergilemiştir. Diğer dalgacıklar ve seviyelerle karşılaştırıldığında, db18 ana dalgacığının 1. seviye detay

katsayılarının hata oranlarının daha düşük olduğu görülmektedir. Örneğin, db17 ana dalgacığı için 1. seviye detay katsayılarında maksimum hata %30.74, ortalama hata %16.52 ve standart sapma %10.74 iken, db10 ana dalgacığı için bu değerler sırasıyla %45.01, %24.75 ve %17.98 olarak hesaplanmıştır. db18'in 2. seviye detay katsayılarında maksimum hata %40.57, ortalama hata %20.20 ve standart sapma %13.68 olarak hesaplanırken, 3. seviyede bu değerler sırasıyla %12.34, %7.13 ve %5.61 olmuştur. 4. ve 5. seviyelerde ise maksimum hata %26.55 ve %33.33, ortalama hata %17.20 ve %16.52, standart sapma ise %8.65 ve %11.63 olarak bulunmuştur. Bu veriler, db18 ana dalgacığının özellikle 1. seviye detay katsayılarının, diğer seviyelere ve diğer dalgacıklara göre daha iyi performans sergilediğini göstermektedir. Diğer ana dalgacıklar arasında db17, db10, db7, db6, db5 ve db4'ün performansları da değerlendirilmiştir. db17 ana dalgacığı için, 2. seviye detay katsayılarında maksimum hata %40.11, ortalama hata %26.32 ve standart sapma %18.86 olarak hesaplanmıştır. db10 ana dalgacığı için ise, 1. seviye detay katsayılarında maksimum hata %45.01, ortalama hata %24.75 ve standart sapma %17.98 olarak bulunmuştur. db7, db6, db5 ve db4'ün performansları da benzer şekilde, db18'in 1. seviye detay katsayılarına kıyasla daha yüksek hata oranları göstermiştir. Elde edilen sonuçlar, önerilen yöntemin gerçek saha verileri üzerindeki yüksek başarı oranını kanıtlamaktadır.

Tablo 38. Farklı ana dalgacıklar ve seviye detay katsayıları kullanılarak OBE algoritması ile maksimum hata, ortalama hata ve standart sapma değerlerinin belirlenmesi

Ana Dalgacık	Hata	1. Seviye	2. Seviye	3. Seviye	4. Seviye	5. Seviye
Db18	Maks. Hata	9.94	40.57	12.34	26.55	33.33
	Ortalama Hata	4.43	20.20	7.13	17.20	16.52
	Std. Sapma	3.92	13.68	5.61	8.65	11.63
Db17	Maks. Hata	30.74	40.11	10.20	23.40	15.63
	Ortalama Hata	16.52	26.32	7.45	12.41	8.17
	Std. Sapma	10.74	18.86	3.34	10.30	7.05
Db10	Maks. Hata	45.01	18.43	13.22	14.04	24.33
	Ortalama Hata	24.75	10.22	13.22	14.04	21.34
	Std. Sapma	17.98	7.28	12.05	5.12	21.34
Db7	Maks. Hata	33.31	22.21	46.42	19.99	26.81
	Ortalama Hata	13.16	11.19	25.54	10.34	15.62
	Std. Sapma	13.52	11.72	15.72	6.60	7.35
Db6	Maks. Hata	20.42	17.06	20.01	9.98	35.32
	Ortalama Hata	15.19	11.20	10.23	5.82	14.90
	Std. Sapma	8.06	6.83	6.79	4.33	14.53
Db5	Maks. Hata	22.99	37.91	22.67	20.56	25.95
	Ortalama Hata	10.59	19.57	9.91	17.28	17.28
	Std. Sapma	9.17	17.69	9.42	4.42	9.92
Db4	Maks. Hata	21.14	27.70	36.51	28.30	19.20
	Ortalama Hata	13.66	16.34	14.92	18.51	12.10
	Std. Sapma	7.89	12.60	17.94	10.69	7.05

Tablo 39’da saha ölçümleri kullanılarak elde edilen, tarımsal sulama amaçlı kaçak elektrik kullanımının tespit edildiği uzunluklar ve hata yüzdelerini vermektedir. Lokasyon tespitinde ortalama hata oranının %4,43 olması, önerilen yöntemin gerçek saha verileri üzerindeki yüksek başarı oranını göstermektedir.

Tablo 39. Saha ölçümleri kullanılarak elde edilen tarımsal sulama amaçlı kaçak elektrik kullanımına ait lokasyon uzunlukları ve hata yüzdeleri

Gerçek Uzunluk (m)	Tahmini Uzunluk (m)	Fider Uzunluk (m)	Hata (%)
561	610.98	1342	3.72
655	645.95	1342	0.67
907	773.57	1342	9.94
944	989.16	1342	3.37

3.2. Malatya Örneği ile İlgili Bulgular

3.2.1. Üç Faz Akım Verisi ile İlgili Bulgular

Üç faz akım bilgisi kullanılarak DWT yöntemiyle elde edilen sınıflandırma sonuçları Tablo 40’da verilmiştir. Sınıflandırma performansları incelendiğinde, FT, MT, CT, ELSVM, LSVM, QSVM, CSVM, MGSVM, CGSVM, BAT, NNN ve MNN modellerinin tümü 0.9964 doğruluk, 0.9964 hassasiyet, 0.996 duyarlılık ve 0.9964 F1 skoru ile en yüksek performansları göstermektedir. Bu modeller, tarımsal sulama motorlarının sınıflandırılmasında neredeyse mükemmel bir doğrulukla çalışmaktadır.

Tablo 40. DWT yöntemi kullanılarak elde edilen sınıflandırma sonuçları

Model	Doğruluk	Hassasiyet	Duyarlılık	F1-skore
FT	0.9964	0.9964	0.996	0.9964
MT	0.9964	0.9964	0.996	0.9964
CT	0.9964	0.9964	0.996	0.9964
LD	0.9945	0.9946	0.995	0.9946
ELR	0.9945	0.9945	0.995	0.9945
ELSVM	0.9964	0.9964	0.996	0.9964
GNB	0.9927	0.9928	0.993	0.9928
KNB	0.9782	0.9799	0.978	0.9791
LSVM	0.9964	0.9964	0.996	0.9964
QSVM	0.9964	0.9964	0.996	0.9964
CSVM	0.9964	0.9964	0.996	0.9964
FGSVM	0.9618	0.9664	0.962	0.9641
MGSVM	0.9964	0.9964	0.996	0.9964
CGSVM	0.9964	0.9964	0.996	0.9964
FKNN	0.9909	0.9911	0.991	0.991
MKNN	0.9891	0.9892	0.989	0.9891
COKNN	0.9782	0.9782	0.978	0.9782
CUKNN	0.9818	0.982	0.982	0.9819
WKNN	0.9927	0.9928	0.993	0.9928
BAT	0.9964	0.9964	0.996	0.9964
NNN	0.9964	0.9964	0.996	0.9964
MNN	0.9964	0.9964	0.996	0.9964
WNN	0.9945	0.9945	0.995	0.9945

Dağıtım hattında motorların devreye girdiği branşların sınıflandırma performansını değerlendiren çeşitli makine öğrenme modellerinin sonuçları Tablo 41’de gösterilmektedir. BAT modeli, 0.9764 doğruluk ve 0.9681 F1 skoru ile en yüksek performansı sergileyerek, motorların devreye girdiği branşların sınıflandırılmasında üstün bir başarı sağlamıştır. NNN ve MNN modelleri de yüksek doğruluk (0.9764 ve 0.9345) ve F1 skoru (0.9311 ve 0.9324) ile öne çıkmıştır. FT modeli 0.9236 doğruluk ve 0.9038 F1 skoru ile iyi bir performans sergilerken, LD) modeli de 0.9109 doğruluk ve 0.8926 F1 skoru ile başarılı sonuçlar elde etmiştir. QSVM ve CSVM modelleri, sırasıyla 0.8509 ve 0.8964 doğruluk ile yüksek performans göstermiştir. Ancak, ELR, ELSVM ve GNB gibi modeller, daha düşük doğruluk ve F1 skoru değerleri ile sınırlı performans sergilemiştir. Bu sonuçlar, BAT modelinin motorların devreye girdiği branşların sınıflandırılmasında en etkili model olduğunu, diğer modellerin ise daha sınırlı sınıflandırma yeteneklerine sahip olduğunu ortaya koymaktadır.

Tablo 41. Dağıtım sistemi fider branşı sınıflandırmasının sonuçları

Model	Doğruluk	Hassasiyet	Duyarlılık	F1-skore
FT	0.9236	0.9098	0.898	0.9038
MT	0.8055	0.8169	0.736	0.7741
CT	0.62	0.7582	0.427	0.546
LD	0.9109	0.8908	0.894	0.8926
ELR	0.5964	0.6864	0.411	0.5133
ELSVM	0.5418	0.5774	0.4	0.4726
GNB	0.5655	0.4988	0.427	0.4599
KNB	0.6273	0.6269	0.493	0.5222
LSVM	0.6909	0.7604	0.543	0.6338
QSVM	0.8509	0.8379	0.812	0.8219
CSVM	0.8964	0.8821	0.882	0.8822
FGSVM	0.61	0.7311	0.49	0.5868
MGSVM	0.6257	0.8251	0.488	0.6131
CGSVM	0.5964	0.7589	0.403	0.5267
FKNN	0.7891	0.7661	0.801	0.7832
MKNN	0.6273	0.6141	0.482	0.5102
COKNN	0.5673	0.5788	0.371	0.4522
CUKNN	0.6614	0.6223	0.463	0.5563
WKNN	0.7941	0.7787	0.788	0.7821
BAT	0.9764	0.9764	0.962	0.9681
NNN	0.9764	0.8862	0.877	0.9311
MNN	0.9345	0.9208	0.926	0.9324
WNN	0.9091	0.8978	0.892	0.895

Şekil 46'da, BAT algoritmasının kaçak yük ve dağıtım sisteminin fider kolu için test verisi üzerinde sınıflandırma performansını gösteren karışıklık matrisleri verilmiştir. İlk matris, kaçak yük sınıflandırmasını, diğeri dağıtım sisteminin fider kolu sınıflandırma sonuçlarını göstermektedir. Kaçak yük sınıflandırma matrisine göre, BAT algoritması beş sınıfta oldukça yüksek doğruluk oranlarına ulaşmıştır. Gerçek sınıf 1'den 5'e kadar olan tüm sınıflar için modelin tahminleri büyük ölçüde doğrudur: Sınıf 1'de 110 örneğin tamamı doğru sınıflandırılmış (%100 doğruluk), Sınıf 2'de 110 örneğin tamamı doğru sınıflandırılmış (%100 doğruluk), Sınıf 3'te 111 örnekten 110'u doğru sınıflandırılmış, sadece 1 örnek yanlış

sınıflandırılmış (%99.1 doğruluk), Sınıf 4'te 110 örnekten 109'u doğru sınıflandırılmış, sadece 1 örnek yanlış sınıflandırılmış (%99.1 doğruluk), ve Sınıf 5'te 110 örneğin tamamı doğru sınıflandırılmış (%100 doğruluk). Genel olarak, modelin tüm sınıflar için yüksek doğruluk (%99.6 doğruluk) ve düşük hata oranları (%0.4 hata) ile çalıştığı gözlemlenmektedir.

Dağıtım sisteminin fider kolu sınıflandırma matrisine göre, BAT algoritması üç sınıfta da yüksek doğruluk oranlarına ulaşmıştır: Sınıf 1'de 302 örnekten 296'sı doğru sınıflandırılmış, 6 örnek yanlış sınıflandırılmış (%98 doğruluk), Sınıf 2'de 150 örnekten 147'si doğru sınıflandırılmış, 3 örnek yanlış sınıflandırılmış (%98 doğruluk), ve Sınıf 3'te 98 örnekten 93'ü doğru sınıflandırılmış, 5 örnek yanlış sınıflandırılmıştır (%94.9 doğruluk). Bu matriste de genel olarak yüksek doğruluk oranları (%97.5 doğruluk) ve düşük hata oranları (%2.5 hata) dikkat çekmektedir. Her iki karışıklık matrisi de BAT algoritmasının yüksek performansını göstermektedir. Kaçak yük sınıflandırmasında %99.6 doğruluk oranı ve dağıtım sistemi fider kolu sınıflandırmasında %97.5 doğruluk oranı ile model, her iki görevde de neredeyse mükemmel sonuçlar vermektedir. Modelin hem yüksek hassasiyet hem de duyarlılık değerlerine sahip olması, yanlış pozitif ve yanlış negatif oranlarının düşük olduğunu ve sınıflandırmanın genel olarak güvenilir olduğunu ortaya koymaktadır. Bu sonuçlar, BAT algoritmasının kaçak elektrik kullanımının tespiti ve sınıflandırılması için uygun bir model olduğunu göstermektedir.

Gerçek Sınıf	1	110 20.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	110 20.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	110 20.0%	1 0.2%	0 0.0%	99.1% 0.9%
	4	0 0.0%	0 0.0%	0 0.0%	109 19.8%	1 0.2%	99.1% 0.9%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	109 19.8%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	99.1% 0.9%	99.1% 0.9%	99.6% 0.4%
		Tahmin Edilen Sınıf					


a)

Gerçek Sınıf	1	296 53.8%	2 0.4%	4 0.7%	98.0% 2.0%
	2	0 0.0%	147 26.7%	3 0.5%	98.0% 2.0%
	3	4 0.7%	1 0.2%	93 16.9%	94.9% 5.1%
		98.7% 1.3%	98.0% 2.0%	93.0% 7.0%	97.5% 2.5%
		Tahmin Edilen Sınıf			

b)

Şekil 46. BAT algoritmasının (a) kaçak tüketim yapan yük ve (b) dağıtım sisteminin fider branşı için sınıflandırma performansını gösteren karışıklık matrisleri

Şekil 47'deki ROC eğrileri, kaçak tüketim yapan yük sınıflandırması ve fider kolu sınıflandırması için BAT algoritmasının test verisi üzerindeki performansını göstermektedir. İlk ROC eğrisine göre, BAT algoritması yüksek bir AUC değerine (0.9921) sahiptir, bu da modelin çok iyi bir sınıflandırma performansı gösterdiğini ortaya koymaktadır. Çeşitli model çalışma noktaları (1, 2, 3) incelendiğinde, modelin doğru pozitif oranlarının yüksek ve yanlış pozitif oranlarının düşük olduğu görülmektedir. Özellikle 1 numaralı model çalışma noktası en yüksek AUC değerine (0.9921) sahip olup, diğer noktalar da oldukça yüksek AUC değerleri (0.9959 ve 0.9829) ile güçlü performans sergilemektedir. Bu sonuçlar, BAT algoritmasının kaçak tüketim yapan yüklerin tespitinde oldukça etkili olduğunu ve doğru sınıflandırma yapma kapasitesinin yüksek olduğunu göstermektedir. 2. ROC eğrisi fider branşı sınıflandırmasının performansını göstermektedir. Bu ROC eğrisine göre, BAT algoritması yine çok yüksek AUC değerlerine sahiptir. AUC değerleri sırasıyla 1, 1, 0.9989, 0.9943 ve 0.9955 olarak gözlemlenmiştir. Bu yüksek AUC değerleri, BAT algoritmasının fider kolu sınıflandırmasında neredeyse mükemmel bir performans gösterdiğini ve yanlış pozitif oranlarının çok düşük olduğunu ortaya koymaktadır. Model çalışma noktaları arasındaki küçük farklılıklar, her bir çalışma noktasının doğru pozitif oranlarını optimize ettiğini göstermektedir.



Şekil 47. BAT algoritmasının performansını gösteren a) kaçak tüketim yapan yük sınıflandırması için (b) fider kolu sınıflandırması için ROC eğrileri


Pilot sahada tarımsal sulamadaki yasadışı elektrik kullanımının lokalizasyonu problemine odaklanılmış ve çeşitli makine öğrenimi modellerinin performansı değerlendirilmiştir. Tablo 42’de DWT yöntemi kullanılarak elde edilen lokalizasyon sonuçları verilmiştir. OBE modeli en yüksek performansı sergilemiştir. Bu model, test edilen diğer tüm modellerden daha düşük hata ölçümleri (MAE: 33.54, RMSE: 52.15) ve yüksek R^2 değeri (0.96) ile öne çıkmaktadır. Ayrıca, ağaç tabanlı yöntemler (örneğin, BT, BAT) doğrusal olmayan ilişkileri modelleme yetenekleriyle dikkat çekerken, SVM modelleri düşük R-kare değerleri ve yüksek hata ölçümleriyle sınırlı kalmıştır. GPR modelleri orta düzeyde performans göstermiş olsa da, OBE algoritmasının üstünlüğü belirgin bir şekilde öne çıkmaktadır.

Tablo 42. DWT yöntemi kullanılarak elde edilen lokalizasyon sonuçları

Model	Doğrulama			Test		
	RMSE	R2	MAE	MAE	RMSE	R2
LN	2451	-85.98	1497.23	1526.71	2353.38	-79.44
MT	123.78	0.78	62.83	42.78	102.36	0.85
CT	169.73	0.58	113.06	88.88	136.44	0.73
LSVM	230.11	0.23	160.4	148.53	210.42	0.36
QSVM	288.14	-0.2	100.14	78.38	125.15	0.77
CSVM	1015.58	-13.93	122.04	77.38	147.03	0.69
FGSVM	225.73	0.26	160.32	146.54	212.61	0.34
MG SVM	200.12	0.42	135.6	121.12	181.45	0.52
CGSVM	256.99	0.04	184.65	179.21	251.4	0.08
BT	124.46	0.78	87.62	81.52	113.46	0.81
BAT	89.66	0.88	53.16	41.89	75.59	0.92
SEGPR	192.54	0.46	125.54	67.28	110.21	0.82
MGPR	129.58	0.76	81.66	68.31	111.39	0.82
EGPR	151.09	0.67	104.33	88.92	132.13	0.75
RQGPR	128.65	0.76	80.45	67.28	110.21	0.82
NNN	142.38	0.71	87.61	80.79	130.79	0.75
MNN	142.26	0.71	86.04	71.94	116.77	0.8
BNN	144.2	0.7	89.16	78.07	129.3	0.76
TNN	135.66	0.73	84.04	80.46	131.45	0.75
OBE	72.07	0.92	46.06	33.54	52.15	0.96

Lokalizasyon problemini çözmek için kullanılan OBE algoritmasının performansı Şekil 48’de gösterilmektedir. Grafikteki noktalar, gözlemlenen değerler ile modelin tahmin ettiği değerlerin uyumunu ortaya koymaktadır. Kusursuz tahmin çizgisi, modelin tahminlerinin gözlemlerle birebir örtüştüğü durumu temsil etmektedir. Gözlemlerin bu çizgiye ne kadar yakın olduğu, modelin doğruluğunu ve güvenilirliğini göstermektedir.

Grafikten de görüldüğü üzere, tahmin edilen cevaplar büyük ölçüde doğru cevaplarla örtüşmektedir. Bu durum, OBE algoritmasının kaçak elektrik kullanımının lokalizasyon probleminde yüksek bir performans sergilediğini ve doğru sonuçlar verdiğini göstermektedir.



Şekil 48. Model performansını gösteren tahmin edilen ve gerçek grafiği

Tablo 43’de 1.5 kW, 4 kW, 7.5 kW, 15 kW ve 22 kW güç tüketimleri için gerçek uzunluklar ile tahmin edilen uzunluklar karşılaştırılmış ve hat uzunluğu ile birlikte yüzdesel hata oranları hesaplanmıştır. OBE algoritması tüm test verisinde % 3.75 bir hata oranı elde etmiştir. Elde edilen sonuçlar, modelin tahminleri ile gerçek uzunluklar arasındaki uyumun oldukça yüksek olduğunu göstermektedir.

Tablo 43. DWT yöntemi kullanılarak farklı güç seviyelerine sahip motorların OBE algoritması ile yapılan lokalizasyon sonuçları

P(kw)	Gerçek Uzunluk (m)	Tahmini Uzunluk (m)	Hat Uzunluk	%Hata
1.5	298.00	310.02	1137.00	1.06
1.5	1137.00	1115.44	1137.00	1.90
1.5	562.00	605.49	593.00	7.33
1.5	405.00	394.74	1137.00	0.90
1.5	539.00	555.08	694.00	2.32
4	188.00	219.01	1137.00	2.73
4	983.00	894.00	1137.00	7.83
4	694.00	661.05	694.00	4.75
4	298.00	300.83	1137.00	0.25
4	1137.00	1150.29	1137.00	1.17
7.5	593.00	544.96	593.00	8.10
7.5	511.00	501.38	1137.00	0.85
7.5	640.00	706.88	694.00	9.64
7.5	188.00	207.44	1137.00	1.71
7.5	983.00	1000.99	1137.00	1.58
15	539.00	558.76	694.00	2.85
15	593.00	599.01	593.00	1.01
15	511.00	604.07	1137.00	8.19
15	640.00	630.42	694.00	1.38
15	188.00	214.47	1137.00	2.33
22	694.00	673.34	694.00	2.98
22	298.00	257.38	1137.00	3.57
22	1137.00	1125.95	1137.00	0.97
22	562.00	572.47	593.00	1.77
22	405.00	537.98	1137.00	11.70

Farklı ana dalgacıklar ve seviye detay katsayıları kullanılarak OBE algoritması ile maksimum hata, ortalama hata ve standart sapma değerleri, Tablo 44’de incelenmiştir. Elde edilen sonuçlara göre, her bir dalgacık fonksiyonu için maksimum hata, ortalama hata ve standart sapma değerleri hesaplanmıştır. Db18 dalgacık fonksiyonu ile en yüksek maksimum hata değerine 5. seviyede (47.78) ulaşırken, en düşük ortalama hata 1. seviyede (4.37) elde

edilmiştir. Bu dalgacık fonksiyonu genel olarak iyi performans göstermiştir, ancak bazı seviyelerde hata oranlarının yükseldiği gözlemlenmiştir. Db17 dalgacık fonksiyonu 3. seviyede en yüksek maksimum hata değerine (55.52) sahiptir. Ortalama hata değerleri ise genellikle düşük seviyelerde kalmış, en düşük ortalama hata 1. seviyede (4.12) gözlemlenmiştir. Db17'nin hata sapmalarındaki değişkenlik diğer fonksiyonlara göre daha yüksektir. Db10 dalgacık fonksiyonu, maksimum hata değerleri açısından diğer fonksiyonlara kıyasla daha düşük seviyelerde kalmış ve en yüksek hata 4. seviyede (46.49) görülmüştür. Ortalama hata değerleri arasında en düşük oran 1. seviyede (3.62) elde edilmiştir. Bu dalgacık fonksiyonu, hata sapmaları açısından da daha stabil bir performans sergilemiştir. Db7 dalgacık fonksiyonu, en yüksek maksimum hata değerine 3. seviyede (71.85) ulaşmıştır. Ortalama hata değerleri genellikle diğer fonksiyonlarla benzer seviyelerde kalmış ve en düşük ortalama hata 1. seviyede (3.67) gözlemlenmiştir. Bu dalgacık fonksiyonu, hata sapmalarının yüksek olduğu seviyelerde daha az stabil performans göstermiştir. Db6 dalgacık fonksiyonu 5. seviyede en yüksek maksimum hata değerine (77.28) ulaşmıştır. Ortalama hata değerleri arasında en düşük oran 1. seviyede (3.65) elde edilmiştir. Bu fonksiyon, özellikle yüksek seviyelerde büyük hata sapmaları göstermiştir. Db5 dalgacık fonksiyonu, maksimum hata değerleri açısından daha dengeli bir performans sergilemiş ve en yüksek hata 3. seviyede (47.1) gözlemlenmiştir. Ortalama hata değerleri genellikle diğer fonksiyonlarla uyumlu seviyelerde kalmış ve en düşük oran 2. seviyede (3.67) elde edilmiştir. Db4 dalgacık fonksiyonu ise 5. seviyede en yüksek maksimum hata değerine (52.25) ulaşmıştır. Ortalama hata değerleri açısından, en düşük oran 1. seviyede (3.66) gözlemlenmiştir. Bu fonksiyon da hata sapmalarının yüksek olduğu seviyelerde daha az stabil performans göstermiştir. Genel olarak, db10 dalgacık fonksiyonu 1.seviye katsayıları, düşük ortalama hata ve daha stabil hata sapmaları ile öne çıkmaktadır.

Tablo 44. Farklı ana dalgacıklar ve seviye detay katsayıları kullanılarak OBE algoritması ile maksimum hata, ortalama hata ve standart sapma değerlerinin belirlenmesi

Ana Dalgacık	Hata	1. Seviye	2. Seviye	3. Seviye	4. Seviye	5. Seviye
Db18	Maks. Hata	44.95	34.02	38.7956	40.26	47.78
	Ortalama Hata	4.37	4.36	4.7809	5.36	4.72
	Std. Sapma	5.13	4.81	4.8983	6.22	5.32
Db17	Maks. Hata	33.88	39.84	55.52	37.09	47.65
	Ortalama Hata	4.12	4.98	4.73	4.93	4.87
	Std. Sapma	4.5	5.29	5.64	5.01	5.32
Db10	Maks. Hata	32.13	33.39	35.32	46.49	33.81
	Ortalama Hata	3.62	4.94	3.77	4.99	5.11
	Std. Sapma	4.07	5.27	4.16	5.28	5.09
Db7	Maks. Hata	32.7	45.13	71.85	43.33	37.24
	Ortalama Hata	3.67	4.82	5.17	5.31	5.29
	Std. Sapma	4.39	5.47	6.65	5.71	5.41
Db6	Maks. Hata	34.5	55.64	43.18	38.7	77.28
	Ortalama Hata	3.65	4.62	4	4.76	5.67
	Std. Sapma	4.42	5.84	4.65	4.92	7.08
Db5	Maks. Hata	34.39	37.54	47.1	38.16	43.89
	Ortalama Hata	3.77	3.67	4.79	4.91	5.27
	Std. Sapma	4.36	4.27	5.01	5.14	5.9
Db4	Maks. Hata	33.99	35.65	50.67	48.43	52.25
	Ortalama Hata	3.66	3.74	4.39	5.04	5.36
	Std. Sapma	4.41	4.32	5.64	5.43	5.91

Önerilen OBE algoritması tabanlı kaçak yük sınıflandırması ve yer tespit sisteminin dağıtım sistemlerinde şebeke sorunlarını araştıran diğer çalışmalarla karşılaştırılması Tablo 45’de verilmiştir. Diğer çalışmalarla kıyaslandığında hem sınıflandırma hem de lokalizasyon doğruluğu açısından oldukça başarılı sonuçlar sunmaktadır. Sınıflandırma doğruluğu %93.21 olarak ölçülmüş ve bu oran, birçok diğer çalışmadan daha yüksek bir performans göstermektedir. Lokalizasyon doğruluğunda ise %96.98 (ort. hata, 3.02) ile tüm diğer çalışmalardan açık ara farkla öne çıkmaktadır. Sınıflandırma doğruluğu sonuçları önerilen yöntem ile üç faz, lokalizasyon doğruluğu sonuçları ise tek faz akım çalışmasından elde edilen sonuçlardır. Yapılan çalışmalar değerlendirildiğinde bu tezde önerilen yöntemin literatüre önemli bir katkı sunduğu anlaşılmaktadır.

Tablo 45. Performans Karşılaştırılması

Referanslar	Kullanılan Yöntem	Kapsam	Şebeke Sorunu	Veri	Sınıflandırma Doğruluğu (%)	Lokalizasyon Doğruluğu (%)
(Jindal, ve diğerleri, 2016)	Karar Ağacı, SVM	Sınıflandırma	Elektrik Hırsızlığı	Elektrik Tüketim Verisi	92,5	—
(Nabil, Ismail, Mahmoud, Shahin, & Qaraqe, 2018)	GRU	Sınıflandırma	Elektrik Hırsızlığı	Elektrik Tüketim Verisi	93	—
(Sapountzoglou, Raison, & Silva, 2019)	DY	Lokalizasyon	Kısa Devre Arızası	Gerilim	—	96,03
(Metaliya & Deshpande, 2021)	DY	Lokalizasyon	Elektrik Hırsızlığı	Gerilim	—	94
(Komolafe & Udofia, 2020)	DY	Lokalizasyon	Elektrik Hırsızlığı	Gerilim	—	94
(Duan, 2024)	Transformer -GAN	Sınıflandırma	Elektrik Hırsızlığı	Elektrik Tüketim Verisi	95,1	—
(Li ve diğerleri, 2022)	Derin Öğrenme	Sınıflandırma	Siber Saldırı	Gerilim	70	—
(Lepolesa, Achari, & Cheng, 2022)	Derin Öğrenme	Sınıflandırma	Elektrik Hırsızlığı	Elektrik Tüketim Verisi	91,8	—
Petrlik Azabache, ve diğerleri, 2022)	SVM	Sınıflandırma	Elektrik Hırsızlığı	Elektrik Tüketim Verisi	81	—
Tez çalışması	OBE	Sınıflandırma, Lokalizasyon	Elektrik Hırsızlığı	Akım	93,21	96,98

DY: Deterministik Yöntem

4. SONUÇLAR

Bu çalışma, Nesnelerin İnterneti (IoT) tabanlı veri toplama sistemlerini gerçek zamanlı makine öğrenimi algoritmalarıyla entegre ederek AGŞ’de kaçak tespitine yönelik yenilikçi bir yaklaşım sunmaktadır. Çalışmanın amacı, tarımsal sulama senaryolarında dağıtım şebekesine kaçak olarak bağlanan yüklerin tespit edilmesi, sınıflandırılması ve yerinin belirlenmesi yoluyla elektrik hırsızlığı oranını önemli ölçüde azaltmaktır. Bu amaçla Elazığ ve Malatya illerinde pilot bölgeler belirlenmiş ve gerçek dağıtım hattı parametreleri kullanılarak simülasyon sonuçları elde edilmiştir. İlk olarak, elektrik tüketim verilerinin gerçek zamanlı olarak izlenmesini sağlamak için bir mimari oluşturulmuştur. Önerilen sisteme entegre edilecek iki farklı tespit yöntemi önerilmiştir. İlk tespit yöntemi, akıllı sayaçlardan gelen veriler ile trafo toplam güç ölçümlerinin karşılaştırılmasıyla kaçak yükün devreye girdiği fider kolunu belirlemekte ve fiderden çekilen toplam güç ile fider sayaçlarından çekilen toplam güç arasındaki farkı hesaplayarak kaçak elektrik kullanımını tespit etmektedir. İkinci tespit yöntemi, her bir faz penceresinin tepe değerlerini hesaplayarak ve ardışık iki değer arasındaki farkın belirlenen sınır değerini aşması durumunda kaçak kullanım tespiti yapmaktadır. Elazığ bölgesinde seçilen pilot sahada yapılan çalışmanın sınıflandırma ve lokalizasyon sonuçları, fider başlangıcından ölçülen tek faz akım verisi ve üç faz akım verisi olmak üzere iki farklı giriş verisi kullanılarak elde edilmiştir. Üç farklı yöntem kullanılarak (Örüntü analizi, DWT ve FWHT) öznitelikler elde edilmiş ve bu yöntemlerin karşılaştırmalı analizi yapılmıştır. Bu yöntemlerle oluşturulan özellik matrisleri, makine öğrenimi algoritmaları için eğitim ve test verileri olarak kullanılmıştır. Makine öğrenimi algoritmaları, sınıflandırma ve lokalizasyon performansları açısından karşılaştırılmış olup, özellikle topluluk yöntemi algoritmalarının üstün performansı dikkat çekicidir. Önerilen OBE algoritmasında, performansı artırmak, doğru hiperparametreleri belirlemek ve en uygun model yapısını elde etmek için GSO optimizasyon yöntemi kullanılmıştır. Ayrıca gerçek saha ölçümleri alınmış ve önerilen modelin gerçek ölçümler üzerinde de yüksek performans gösterdiği belirlenmiştir. Malatya bölgesinde seçilen pilot sahada yapılan çalışmada da önerilen yöntemin başarısı kanıtlanmıştır. Sonuçlara göre, DWT yöntemi ile öznitelikler çıkartıldığında her iki pilot saha simülasyon sonuçlarında en iyi performansın elde edildiği gösterilmiştir. DWT yönteminin üstün başarısı hem sınıflandırma hem de lokalizasyon çalışması için geçerli

olmuştur. Özellikle, OBE algoritması sınıflandırma ve lokalizasyon sonuçlarında diğer makine öğrenimi algoritmalarına göre üstün performans sergilemiştir. Elazığ örneğinde gerçekleştirilen tek faz akım çalışmasında, sınıflandırma doğruluğu %90,83, lokalizasyon ortalama hata değeri ise %3,02 olarak tespit edilmiştir. Üç faz akım çalışmasında ise sınıflandırma doğruluğu %93,21, lokalizasyon ortalama hata değeri ise %3,33 olarak belirlenmiştir. Aynı sahada yapılan gerçek saha ölçümlerinde ise ortalama lokalizasyon hata değeri %4,43 olarak saptanmıştır. Malatya örneğinde gerçekleştirilen üç faz akım çalışmasında, yük sınıflandırmasında %99,64, branş sınıflandırmasında ise %97,54 doğruluk oranları elde edilmiş olup, ortalama lokalizasyon hata değeri %3,62 olarak bulunmuştur.

Literatürde, dağıtım hattına doğrudan temas yoluyla kaçak elektrik tüketen yüklerin belirlenmesine yönelik az sayıda çalışma bulunmaktadır. Mevcut deterministik yöntemler dinamik yük profilleri nedeniyle yetersiz kalmaktadır. Dağıtım hatlarındaki farklı iletken türleri ve dallanma yapıları, empedans tabanlı yöntemlerin etkinliğini azaltmaktadır. Bu çalışmada, yalnızca akım verileri kullanılarak karar destek sistemleri geliştirilmiş ve kablosuz IoT ağı ile makine öğrenimi teknikleri kullanılmıştır. Simülasyonlar, gerçek ağ parametreleriyle gerçekleştirilmiş ve yöntemin başarımı gerçek saha ölçümleriyle doğrulanmıştır. Gerçek saha ölçümleriyle yapılan bu çalışma, literatürdeki boşluğu doldurarak önemli bir katkı sunmaktadır. Tez çalışması, sinyal işleme teknikleri açısından özgün bir yaklaşım da sunmaktadır. Sınıflandırma ve lokalizasyon tespiti için üç farklı yöntem (Örüntü analizi, DWT, FWHT) ile sonuçlar alınarak karşılaştırılmaktadır. Bu değerlendirmeler, her bir yöntemin güçlü ve zayıf yönlerini kapsamlı bir şekilde inceleyerek, araştırmacılara hangi tekniklerin belirli durumlarda daha etkili ve verimli olacağı konusunda bilgi vermektedir. Böylelikle, gelecekte yapılacak çalışmaların doğru teknikleri kullanarak daha başarılı sonuçlar elde etmesine katkıda bulunmaktadır.

Elde edilen bulgular, makine öğrenimi, IoT ve sinyal işleme yöntemlerinin akıllı şebekelere entegrasyonunun önemini öne çıkarmaktadır. Bu sonuçlar, akıllı şebekelerde bu teknolojilerin bir arada kullanılmasının kritik bir rol oynadığını göstermektedir.

5. ÖNERİLER

Bu çalışma, AGŞ dağıtım ağlarında kaçak elektrik tespitine yönelik yenilikçi bir yaklaşım sunarak, IoT tabanlı veri toplama ve gerçek zamanlı makine öğrenme algoritmalarının entegrasyonunu ele almıştır. Tarımsal sulama senaryolarında dağıtım şebekesine yasadışı olarak bağlanan yüklerin tespiti, sınıflandırılması ve yerini tespit ederek elektrik hırsızlığı oranını önemli ölçüde azaltmak amaçlamaktadır. Örüntü analizi, DWT ve FWHT yöntemlerinin karşılaştırmalı analizi, her bir metodun güçlü ve zayıf yönlerini ortaya koymuştur. DWT yöntemiyle elde edilen öznitelikleri giriş verisi olarak kullanan OBE yöntemi, hem tek faz hem de üç faz akım çalışmalarında en başarılı sonuçları vermiştir. Bu bulgular, enerji kayıplarını azaltmaya ve dağıtım ağlarının güvenliğini artırmaya önemli katkılar sağlamaktadır. Sistemin sürekli öğrenme ve adaptasyon yeteneği, tespit doğruluğunu ve şebeke kararlılığını zamanla iyileştirmektedir.

- Gelecekteki araştırmalar, farklı yöntemlerin güçlü yönlerini birleştirerek daha iyi performans elde etmeyi amaçlayabilir. Örneğin, Örüntü analizi ile DWT yöntemlerinin entegrasyonu, manuel uzmanlık ve ileri frekans ayrışımının avantajlarını bir araya getirerek daha kapsamlı bir kaçak tespit sistemi oluşturabilir. Bu hibrit yaklaşım, her bir yöntemin tek başına kullanıldığındaki çeşitli sınırlamaları azaltabilir.
- Örüntü analizi yönteminde, otomatik örüntü tanıma teknikleri geliştirilebilir. Özellikle derin öğrenme modelleri, verilerden otomatik olarak ilgili örüntüleri tanımlamak ve çıkarmak için eğitilebilir. Bu, Örüntü analizi yönteminin ölçeklenebilirliğini ve tutarlılığını artırarak, büyük ölçekli ve çeşitli veri kümelerine daha uygulanabilir hale getirir.
- Yöntemlerin daha büyük ve daha çeşitli veri setlerinde, farklı anormallik türlerini ve değişen ağ koşullarını içerecek şekilde değerlendirilmesi, etkinliklerinin daha kapsamlı bir şekilde anlaşılmasını sağlayabilir. Bu aynı zamanda yöntemlerin gerçek dünya senaryolarında test edilmesini de içermelidir. Daha geniş bir veri seti, modellerin hassas ayar yapılmasına ve dayanıklılıklarının artırılmasına yardımcı olabilir.
- DWT ve FWHT yöntemlerinin parametrelerini hassas ayarlamak için gelişmiş optimizasyon tekniklerinin kullanılması, performanslarını daha da artırabilir.

Genetik algoritmalar, parçacık sürü optimizasyonu vb. optimizasyon yöntemleri, algoritmalar için en iyi yapılandırmaları bulmaya yardımcı olarak, doğruluğu ve verimliliği artırabilir.

- Dağıtım hattında farklı türdeki yükler (omik, kapasitif) devreye alındığında uygulanan yöntemlerin sınıflandırma ve lokalizasyon performansları değerlendirilebilir. Kaçak tüketim yapan bu tür yükleri belirlemek için deterministik yöntemler kullanılabilir ve sonuçlar tez çalışmasında önerilen yöntemle karşılaştırılabilir. Aynı çalışma için derin öğrenme algoritmalarının da sonuçları alınarak tez çalışmasında sunulan yöntemlerle karşılaştırmalı analizler verilebilir.
- Kaçak tespit sistemlerinin, güç dağıtım ağlarındaki diğer izleme ve kontrol sistemleri ile entegrasyonu, genel sistem güvenilirliğini ve performansını artırabilir. Bu, farklı sistemler arasında sorunsuz iletişim için arayüzlerin ve protokollerin geliştirilmesini içerebilir. Böyle bir entegrasyon, ağ izleme ve yönetiminde bütüncül bir yaklaşım sağlar, kaçak elektrik tüketimi dışında farklı anormalliklerin tespitine ve bunlara müdahale edilmesine olanak tanır.
- Akıllı sayaç verileri kullanılarak ileriye dönük tahmin modelleri geliştirilebilir. Bu modeller, olası hırsızlık girişimlerini tahmin ederek proaktif müdahalelere olanak tanır.
- Elektrik dağıtım hatlarının ve hırsızlık tespitinin coğrafi bilgi sistemleri (GIS) ile entegrasyonu, hırsızlıkların lokasyon bazlı analizi ve yönetimini kolaylaştırabilir. GIS tabanlı analizler, kaçak elektrik kullanımının daha hızlı ve etkin bir şekilde belirlenmesine yardımcı olabilir.
- Farklı tüketici gruplarının enerji tüketim profilleri analiz edilerek, normal ve anormal kullanım desenleri belirlenebilir. Bu segmentasyon, hırsızlık tespiti ve önlenmesi için daha hedefli ve etkili stratejiler geliştirilmesine yardımcı olabilir.
- Verilerin daha iyi anlaşılması ve analiz edilmesi için gelişmiş veri görselleştirme teknikleri kullanılabilir. Interaktif ve dinamik görselleştirme araçları, karar vericilere daha net ve anlaşılır bilgiler sunmaktadır.
- Şebeke üzerindeki çeşitli sensörler ve IoT cihazları ile entegre edilerek, daha detaylı ve kapsamlı veri toplama ve analiz yapılabilir. Bu cihazlar, anlık veri sağlayarak daha hassas tespit ve müdahale mekanizmalarının geliştirilmesine olanak tanır.

6. KAYNAKLAR

- Abdulwahid, A. H. (2019). *A New Concept of an Intelligent Protection System Based on a Discrete Wavelet Transform and Neural Network Method for Smart Grids* (s. 1-6). 2nd International Conference of the IEEE Nigeria Computer Chapter (NigeriaComputConf).
- Achaal, B., Adda, M., Berger, M., Ibrahim, H., & Awde, A. (2024). Study of smart grid cyber-security, examining architectures, communication networks, cyber-attacks, countermeasure techniques, and challenges. *Cybersecurity*, 7, 10.
- Ahmed, M., Khan, A., Ahmed, M., Tahir, M., Jeon, G., Fortino, G., & Piccialli, F. (2022). Energy theft detection in smart grids: Taxonomy, comparative analysis, challenges, and future research directions. *IEEE/CAA J. Autom. Sinica*, 9(4), 578–600.
- Alasali, F., AlMajali, A., Abudayyeh, M., Aldeiri, B., El-Naily, N., & Zarour, E. (2023). 11th International Conference on ENERGY and ENVIRONMENT (CIEM). *Enhancing Cyber-Physical Threat Assessment in Power Distribution Networks*, 1-5.
- Ali, A., Mokhtar, M., & Shaaban, M. F. (2022). Theft Cyberattacks Detection in Smart Grids Based on Machine Learning. (s. 1-4). 5th International Conference on Communications, Signal Processing, and their Applications (ICCSPA).
- Ali, S., Yongzhi, M., & Ali, W. (2023). Prevention and Detection of Electricity Theft of Distribution Network. *Sustainability*, 15, 4868.
- Alromih, A., J Clark, A., & Gope, P. (2021). *Electricity theft Detection in the presence of prosumers using a cluster-based multi-feature detection model* (s. 339–345). Aachen, Germany: Proceedings of the 2021 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm).
- Appiah, S. Y., Akowuah, E. K., Ikpo, V. C., & Dede, A. (2023). Extremely randomised trees machine learning model for electricity theft detection. *Machine Learning with Applications*, 12, 100458.
- Arif A, A. T. (2022). Towards efficient energy utilization using big data analytics in smart cities for electricity theft detection. s. 100285.
- Babar, Z., Jamil, F., & Haq, W. (2022). Consumer's perception towards electricity theft: A case study of Islamabad and Rawalpindi using a path analysis. *Energy Policy*, 169, 113189.
- Bhusal, N., Gautam, M., & Benidris, M. (2021). Detection of Cyber Attacks on Voltage Regulation in Distribution Systems Using Machine Learning. *IEEE Access*, 9, 40402-40416.

- Bian, J., Wang, L., Scherer, R., Woźniak, M., Zhang, P., & Wei, W. (2021). Abnormal Detection of Electricity Consumption of User Based on Particle Swarm Optimization and Long Short Term Memory With the Attention Mechanism. *IEEE Access*, 9, 47252-47265.
- Biswas, P. P., Cai, H., Zhou, B., Chen, B., Mashima, D., & Zheng, V. W. (2020). Electricity Theft Pinpointing Through Correlation Analysis of Master and Individual Meter Readings. *IEEE Transactions on Smart Grid*, 11(4), 3031-3042.
- Budu, K. (2014). Comparison of Wavelet-Based ANN and Regression Models for Reservoir Inflow Forecasting. *Journal of Hydrologic Engineering*, 19(7), 1385.
- Buzau, M. M., Tejedor-Aguilera, J., Cruz-Romero, P., & Gómez-Expósito, A. (2019). Detection of Non-Technical Losses Using Smart Meter Data and Supervised Learning. *IEEE Transactions on Smart Grid*, 10(3), 2661-2670.
- Caporuscio, M., Dupuis, A., & Löwe, W. (2023). Data-Driven GroundFault Location Method in Distribution Power System with Distributed Generation.
- Cárdenas, A. A., Amin, S., Schwartz, G., Dong, R., & Sastry, S. (2012). A game theory model for electricity theft detection and privacy-aware control in AMI systems. (s. 1830-1837). Allerton: 2012 50th Annual Allerton Conference on Communication, Control, and Computing.
- Chandel, P., & Thakur, T. (2019). Smart Meter Data Analysis for Electricity Theft Detection using Neural Networks. *Advances in Science, Technology and Engineering Systems Journal*, 4(4), 161--168.
- Chu, Z., Cui, X., Zhai, X., Liu, S., Qiu, W., Waseem, M., . . . Lin, Z. (2022). Anomaly detection and clustering-based identification method for consumer-transformer relationship and associated phase in low-voltage distribution systems. *Energy Conversion and Economics*, 3(6), 392-402.
- Dasgupta, K., Padmanaban, M., & Hazra, J. (2017). Data Driven Energy Theft Localization in a Distribution Network. *IET Generation, Transmission & Distribution*, 11(11), 2831-2839.
- Deng, R., Zhuang, P., & Liang, H. (2017). CCPA: Coordinated Cyber-Physical Attacks and Countermeasures in Smart Grid. *IEEE Transactions on Smart Grid*.
- Duan, J. (2024). Deep learning anomaly detection in AI-powered intelligent power distribution systems. *Frontiers in Energy Research*, 12.
- Düzgün, B. (2018). Türkiye Elektrik İletim ve Dağıtım Şebekesinin Enerji Verimliliğinin Değerlendirilmesi ve 2023 Projeksiyonları. doi:10.2339/politeknik.389604
- El-Toukhy, A. a., Srivastava, G., Fouda, M., & Alsabaan, M. (2023). Electricity Theft Detection Using Deep Reinforcement Learning in Smart Power Grids. *IEEE Access*, 1-1.

- Engelbrecht, J., Hancke, G. P., & Osifeko, M. O. (2019). Design and Implementation of an Electrical Tamper Detection System. *IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society*, 1, 2952-2957.
- EPDK. (2023, Kasım 6). *Sektör Raporları*. <https://www.epdk.gov.tr/Detay/Icerik/4-14475/2023-yili-sektor-raporlari-yayinlanmistir> adresinden alındı
- Farid, S., Iltaf, N., & Afzal, H. (2023). *Electricity Theft Detection Via Deep Learning* (s. 79-86). International Conference on Communication Technologies (ComTech).
- Fei, K., Li, Q., Zhu, C., Dong, M., & Li, Y. (2022). Electricity frauds detection in Low-voltage networks with contrastive predictive coding. *International Journal of Electrical Power & Energy Systems*, 137, 107715.
- Gabriel, R., Matthes, J., Keller, H. B., & Hagenmeyer, V. (2019). *Detection and Localization of Manipulated Smart Meters Using Super State Hidden Markov Models* (s. 1-7). 2019 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm).
- Gökalp, Z., & Çakmak, B. (2013). Kuraklık ve Tarımsal Su Yönetimi. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*(4), 1-11.
- Gunduz, M., & Das, R. (2024). Smart Grid Security: An Effective Hybrid CNN-Based Approach for Detecting Energy Theft Using Consumption Patterns. *Sensors*, 24 (4), 1148.
- Gunturi, S., & Sarkar, D. (2021). Ensemble machine learning models for the detection of energy theft. *Electr. Power Syst. Res.*, 192, 106904.
- Gupta, S. (2014). Wavelet Based Techniques for Speckle Noise Reduction in Ultrasound Images. *Int. Journal of Engineering Research and Applications*, Gupta, Sheifali.
- Handique, M., & Das, Q. K. (2019). Design and Simulation of Electricity Theft Detection in Radial Distribution System. *ADB U Journal of Electrical and Electronics Engineering*, 3(2), 44--49.
- Haq, U. E., Pei, C., Zhanga, R., Jianjunb, H., & Ahmad, F. (2023). *Electricity-theft detection for smart grid security using smart meter data: A deep-CNN based approach*, 9, s. 634-643.
- Hasan, J., Rahman, S., Islam, S., & Yusuf, J. (2023). Data Driven Energy Theft Localization in a Distribution Network. *2023 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD)*, 388-392.
- Hodson, T. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *15*, 5481-5487. doi:10.5194/gmd-15-5481-2022
- Hussain, D. a. (2016). *Methods and Techniques of Electricity Thieving in Pakistan* (Cilt 4). Journal of Power and Energy Engineering. doi:10.4236/jpee.2016.49001

- IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines. (2015). *IEEE Std C37.114-2014 (Revision of IEEE Std C37.114-2004)*, 1-76.
- Jain, A., & Khan, S. (2019). Impact of Voltage Fluctuations on Electrical Equipment: A Review. *International Journal of Electrical Power & Energy Systems*, 104, 31-45.
- Janthong, S., Chalermmyanont, K., & Duangsoithong, R. (2023). *Comparison of Feature Extraction Methods for Classifying Energy Theft and Defective Meters in Automatic Meter Reading* (s. 49-53). International Electrical Engineering Congress (iEECON).
- Jayamaha, D. K., Lidula, N. W., & Rajapakse, A. D. (2019). Wavelet-Multi Resolution Analysis Based ANN Architecture for Fault Detection and Localization in DC Microgrids. *IEEE Access*, 7, 145371-145384.
- Jiang, C., Xu, Y., Jiang, J., & Zhang, Z. (2022). Detection and localization of power theft based on CNN-LSTM algorithm. *2022 IEEE Conference on Telecommunications, Optics and Computer Science (TOCS)*, 837-840.
- Jindal, A., Dua, A., Kaur, K., Singh, M., Kumar, N., & Mishra, S. (2016). Decision Tree and SVM-Based Data Analytics for Theft Detection in Smart Grid. *IEEE Transactions on Industrial Informatics*, 12(3), 1005-1016.
- Jokar, P., Arianpoo, N., & Leung, V. (2016). Electricity theft detection in AMI using costumers' consumption patterns. *IEEE Trans. Smart Grid*, 7, 216–226.
- Kang, L., Shang, Y., Zhang, M., & Liao, L. (2022). Research on monitoring technology of power stealing behavior in bitcoin mining based on analyzing electric energy data. *Energy Reports*, 8, 1183-1189.
- Kara, Y., & Aksu, A. (2023). Tüketicilerde Kaçak Elektrik Kullanımının Akıllı Sayaç Verisi Üzerinden Gradyan Artırmalı Karar Ağacı Tabanlı Makine Öğrenmesi Yöntemleriyle Tespiti. *Journal of Investigations on Engineering & Technology*, 6(1), 1-12.
- Kawoosa, A., Prashar, D., Faheem, M., Jha, N., & Khan, A. A. (2023). Using machine learning ensemble method for detection of energy theft in smart meters. *IET Generation, Transmission & Distribution*, 17.
- Khan, N., Raza, M., Ara, D., & Bouzguenda, B. (2023). A deep learning technique Alexnet to detect electricity theft in smart grids. *Frontiers in Energy Research*, 11, 1287413.
- Kim, J. Y., Sun, Y. G., Sim, I., Kim, D. I., & Wang, X. (2019). Detection for Non-Technical Loss by Smart Energy Theft With Intermediate Monitor Meter in Smart Grid. *IEEE Access*, 7, 129043-129053.
- Komolafe, M., & Udofia, M. K. (2020). Komolafe, Mayowa, Olusegun and Udofia, Monday, Kingsley. *SciencePG*, 5(2), 41-49.
- Leite, B., & Mantovani, S. (2018). Detecting and locating non-technical losses in modern distribution networks. *In IEEE Transactions on Smart Grid 2018*, 9(2), 1023-1032.

- Lepolesa, L. J., Achari, S., & Cheng, L. (2022). Electricity Theft Detection in Smart Grids Based on Deep Neural Network. *IEEE Access*, 10, 39638-39655.
- Li, Q., Zhang, J., Zhao, J., Ye, J., Song, W., & Li, F. (2022). Adaptive Hierarchical Cyber Attack Detection and Localization in Active Distribution Systems}. *IEEE Transactions on Smart Grid*, 13(3), 2369-2380.
- Liao, C., Ten, C.-W., & Hu, S. (2013). Strategic FRTU Deployment Considering Cybersecurity in Secondary Distribution Network. *IEEE Transactions on Smart Grid*, 4(3), 1264-1274.
- Lin, G., Feng, H., Feng, X., Wen, H., Li, Y., Hong, S., & Ni, Z. (2021). Electricity Theft Detection in Power Consumption Data Based on Adaptive Tuning Recurrent Neural Network. *Frontiers in Energy Research*.
- Liu, Y., Liu, T., Sun, H., Zhang, K., & Liu, P. (2020). Hidden Electricity Theft by Exploiting Multiple-Pricing Scheme in Smart Grids. *IEEE Transactions on Information Forensics and Security*, 15, 2453-2468.
- Long, H., Wu, Z., Fang, C., Gu, W., Wei, X., & Zhan, H. (2020). Cyber-attack Detection Strategy Based on Distribution System State Estimation. *Journal of Modern Power Systems and Clean Energy*, 8(4), 669-678.
- Luya, L. E., & Angelo Pedrasa, M. (2019). *Detecting and Estimating Amount of Energy Theft in the Distribution Network Using Linear Regression* (s. 1-6). 2019 9th International Conference on Power and Energy Systems (ICPES).
- Madabhushi, S., & Dewri, R. (2023). A survey of anomaly detection methods for power grids. *Springer*, 22(6), 1799–1832.
- Markovska, M., Gerazov, B., Zlatkova, A., & Taskovski, D. (2023). *Electricity Theft Detection Based on Temporal Convolutional Networks with Self-Attention* (s. 1-5). 30th International Conference on Systems, Signals and Image Processing (IWSSIP).
- McElwee, S. (2018). *Probabilistic Clustering Ensemble Evaluation for Intrusion Detection*.
- Metaliya, A., & Deshpande, A. (2021). Electricity theft detection scheme using energy loss and voltage estimation in distribution network. 31-40.
- Mohajer, F., & Sadeh, J. (2022). Accurate fault location method for distribution network in presence of DG using distributed time-domain line model. *IET Generation, Transmission & Distribution*, 16(7), 1305-1318.
- Mokarim, A., Gaggero, G. B., & Marchese, M. (2023). *Evaluation of the Impact of Cyber-Attacks Against Electric Vehicle Charging Stations in a Low Voltage Distribution Grid* (s. 1-7). IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm).

- Mutlag, W. a. (2020). Feature Extraction Methods: A Review. *Journal of Physics: Conference Series*, 1591, 012028. doi:10.1088/1742-6596/1591/1/012028
- Nabil, M., Ismail, M., Mahmoud, M., Shahin, M., & Qaraqe, K. (2018). *Deep recurrent electricity theft detection in AMI networks with random tuning of hyper-parameters* (s. 740–745). Beijing, China: In Proceedings of the 2018 24th International Conference on Pattern Recognition (ICPR).
- Najafzadeh, M., & Gholami, M. (2022). *Methods of identifying unauthorized customers in cryptocurrency mining of distribution networks-a review* (s. 1-8). Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS).
- Neethu, A., & Angel, T. (2017). *Smart fault location and fault classification in transmission line* (s. 339-343). IEEE International Conference on Smart Technologies and Management for Computing, Communication, Controls, Energy and Materials (ICSTM).
- Okumus, H. (2022, Kasım). *Development of a fault location device in rural distribution networks*.
- Okumuş, H., & Nuroglu, F. (2019). Wavelet Based Fault Detection and Classification Algorithm for a Real Distribution Feeder. *EMITTER International Journal of Engineering Technology*, 7.
- Oprea, S., & Adela, B. (2022). Feature engineering solution with structured query language analytic functions in detecting electricity frauds using machine learning. *Scientific Reports*, 12, 3257.
- Passerini, F., & Tonello, A. M. (2019). Smart Grid Monitoring Using Power Line Modems: Anomaly Detection and Localization. *IEEE Transactions on Smart Grid*, 10(6), 6178-6186.
- Pereira, J., & Saraiva, F. (2020). A Comparative Analysis of Unbalanced Data Handling Techniques for Machine Learning Algorithms to Electricity Theft Detection. *2020 IEEE Congress on Evolutionary Computation (CEC)*, 1-8.
- Petrlik Azabache, I., Lezama, P., Rodriguez, C., Inquilla, R., Reyna-González, J., & Esparza, R. (2022). Electricity Theft Detection using Machine Learning. *International Journal of Advanced Computer Science and Applications*, 13.
- Raza, H., Imran, K., Khattak, A., Ulasyar, A., & Ilyas, A. (2021). *Strategy to detect quantify and locate power theft in a distribution network*. Karachi, Pakistan: 6th International Electrical Engineering Conference.
- Sapountzoglou, N., Raison, B., & Silva, N. (2019). *Fault Detection and Localization in LV Smart Grids* (s. 1-6). IEEE Milan PowerTech.
- Sebastian, P., & D'Sa, P. A. (2015). *A Neural Network based power quality signal classification system using wavelet energy distribution* (s. 199-204). International Conference on Technological Advancements in Power and Energy (TAP Energy).

- Senemmar, S., & Zhang, J. (2021). *Deep Learning-based Fault Detection, Classification, and Locating in Shipboard Power Systems* (s. 1-6). IEEE Electric Ship Technologies Symposium (ESTS).
- Sharma, G., Mahela, O. P., Kumar, M., & Kumar, N. (2018). Detection and Classification of Transmission Line Faults Using Stockwell Transform and Rule Based Decision Tree. (s. 1-5). International Conference on Smart Electric Drives and Power System (ICSEDPS).
- Sim, K., Lee, G., & Shin, Y.-J. (2023). Detection and Location of Electricity Theft via Convolutional Neural Network in Distribution System. *2023 IEEE Power & Energy Society General Meeting (PESGM)*, 1-5.
- Souza, J. A., & Gomes, P. R. (2020). Challenges and Solutions for Voltage Stability in Smart Grids. *Renewable and Sustainable Energy Reviews*, 122, 109724.
- Souza, M., Pereira, J., Alves, G., de Oliveira, B., Melo, I., & Garcia, P. (2020). Detection and identification of energy theft in advanced metering infrastructures. *Electric Power Systems Research*, 182, 106258.
- Sreerama, R., & Swarup, K. S. (2017). *Detection, localization and fault diagnosis using PetriNets for smart power distribution grids* (s. 596-600). 7th International Conference on Power Systems (ICPS).
- Takiddin, A., Ismail, M., & Serpedin, E. (2022). *Detection of Electricity Theft False Data Injection Attacks in Smart Grids* (s. 1541-1545). 30th European Signal Processing Conference (EUSIPCO).
- Tanyıldızı, E., & Demirtaş, F. (2019). *Hiper Parametre Optimizasyonu Hyper Parameter Optimization* (s. 1-5). Ankara: 2019 1st International Informatics and Software Engineering Conference (UBMYK).
- Ullah, A., Javaid, N., Samuel, O., Imran, M., & Shoaib, M. (2020). *CNN and gru based deep neural network for electricity theft detection to secure smart grid* (s. 1598–1602). Limassol, Cyprus: In: Proceedings of the 2020 International Wireless Communications and Mobile Computing (IWCMC).
- URL-1. (2023, Ekim 10). Northeast Group LLC: <https://northeast-group.com/research-catalogue/> adresinden alındı
- URL-2. (2024, Ağustos 15). Hyperparameter Optimization in Classification Learner App: <https://www.mathworks.com/help/stats/hyperparameter-optimization-in-classification-learner-app.html> adresinden alındı
- URL-3. (2024, Ağustos 15). Mathworks: <https://www.mathworks.com/help/wavelet/ref/wavedec.html> adresinden alındı
- URL-4. (2024, Mayıs 01). Discrete walsh hadamard transform: <https://www.mathworks.com/help/signal/ug/41> adresinden alındı

- URL-5. (2023, Ekim 14). Asynchronous machine: <https://www.mathworks.com/help/sps/powersys/ref/asynchronousmachine.html> adresinden alındı
- Uvais, M. (2020). *Controller based power theft location detection system* (s. 111-114). Gorakhpur, India: International Conference on Electrical and Electronics Engineering (ICE3).
- Vujovici, Z. (2021). Classification Model Evaluation Metrics. *12*, 599-606.
- Wasnik, P. P., Phadkule, N. J., & Thakur, K. D. (2019). *Fault detection and classification based on semi-supervised machine learning using KNN* (s. 79-83). International Conference on Innovative Trends and Advances in Engineering and Technology (ICITAET).
- Wei, L., Sundararajan, A., Sarwat, A., Biswas, S., & Erfan, I. (2017). A distributed intelligent framework for electricity theft detection using benford's law and stackelberg game. *2017 Resilience Week (RWS)*, (s. 5-11).
- Yang, Y., Song, R., Xue, Y., Zhang, P., Xu, Y., Kang, J., & Zhao, H. (2022). A Detection Method for Group Fixed Ratio Electricity Thieves Based on Correlation Analysis of Non-Technical Loss. *IEEE Access*, *10*, 5608-5619.
- Yu, J., Cheng, H., Zhang, J., Li, Q., Wu, S., Zhong, W., . . . Ma, P. (2022). CONGO²: Scalable Online Anomaly Detection and Localization in Power Electronics Networks. *IEEE Internet of Things Journal*, *9*(15), 13862-13875.
- Žarković, M., & Dobrić, G. (2024). Artificial Intelligence for Energy Theft Detection in Distribution Networks. *Energies*, *17*(7).
- Zhang, C., Wang, Z., Liu, L., Li, G., & Li, H. (2023). *{Electricity-Theft Detection Based on Optimized Deep Learning Model in Smart Grid}* (s. 1494-1499). 6th International Conference on Energy, Electrical and Power Engineering (CEEPE).
- Zhang, J. E., Wu, D., & Boulet, B. (2021). *Time Series Anomaly Detection for Smart Grids: A Survey* (s. 125-130). IEEE Electrical Power and Energy Conference (EPEC).
- Zheng, Z., Yang, Y., Niu, X., Dai, H., & Zhou, Y. (2018). Wide and deep convolutional neural networks for electricity-theft detection to secure smart grids. *IEEE Trans. Ind. Inform.*, *14*, 1606–1615.
- Zideh, M. J., Chatterjee, P., & Srivastava, A. K. (2024). Physics-Informed Machine Learning for Data Anomaly Detection, Classification, Localization, and Mitigation: A Review, Challenges, and Path Forward. *IEEE Access*, *12*, 4597-4617.

ÖZGEÇMİŞ

Önder CİVELEK, İlköğrenimini Kutlugün Köyü İlköğretim Okulu, orta öğrenimini Cudibey Ortaokulunda, lise öğrenimini ise Trabzon Lisesi'nde tamamladı. 2002 yılında 1 yıl ingilizce hazırlık öğrenimi gördükten sonra Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde lisans programına başladı ve 2007 yılında mezun oldu. Ve aynı yıl Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans öğrenimine başladı. Yüksek lisans tezini 2018 yılında tamamladı. Bu süreç içerisinde 10 yıl Türk Telekom Trabzon Bölge Müdürlüğünde uzman ve yönetici olmak üzere farklı pozisyonlarda çalıştı. 2018 yılı şubat ayı itibari ile Karadeniz Teknik Üniversitesi Trabzon MYO'da öğretim görevlisi olarak görev yapmaktadır. Yabancı dil olarak iyi seviyede ingilizce bilmektedir.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

1. Ö. CİVELEK Et Al. , "Detection and classification of unauthorized use of irrigation motors in agricultural irrigation," Turkish Journal of Electrical Engineering and Computer Sciences , vol.32, no.4, pp.605-622, 2024

Proje

1. 7220360 Proje numaralı TÜBİTAK 1507 Kobi Ar-Ge Başlangıç Destek Programı “ Makine Öğrenimi Algoritmaları Kullanılarak Kaçak Elektrik Takibi Ve Kontrol Sisteminin Gerçekleştirilmesi ”