

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DAĞITIK ÜRETİM GÜÇ SİSTEMLERİNDE GELİŞTİRİLMİŞ
OYLAMA MODELİ TABANLI ARIZA TESPİTİ VE
SINIFLANDIRMASI**

DOKTORA TEZİ

Fevzeddin ÜLKER

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik Bilim Dalı

TEMMUZ 2023

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DAĞITIK ÜRETİM GÜÇ SİSTEMLERİNDE GELİŞTİRİLMİŞ
OYLAMA MODELİ TABANLI ARIZA TESPİTİ VE
SINIFLANDIRMASI**

DOKTORA TEZİ

Fevzeddin ÜLKER

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik Bilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Ahmet KÜÇÜKER

TEMMUZ 2023

Fevzeddin ÜLKER tarafından hazırlanan “Dağıtık Üretim Güç Sistemlerinde Geliştirilmiş Oylama Modeli Tabanlı Arıza Tespiti ve Sınıflandırması” adlı tez çalışması 10.07.2023 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektrik Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

- Jüri Başkanı :** **Prof. Dr. Ertan YANIKOĞLU**
Sakarya Üniversitesi
- Jüri Üyesi :** **Dr. Öğr. Üyesi Ahmet KÜÇÜKER (Danışman)**
Sakarya Üniversitesi
- Jüri Üyesi :** **Prof. Dr. Ali Fuat BOZ**
Sakarya Uygulamalı Bilimler Üniversitesi
- Jüri Üyesi :** **Doç. Dr. Gökay BAYRAK**
Bursa Teknik Üniversitesi
- Jüri Üyesi :** **Dr. Öğr. Üyesi Burhan BARAKLI**
Sakarya Üniversitesi

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “DAĞITIK ÜRETİM GÜÇ SİSTEMLERİNDE GELİŞTİRİLMİŞ OYLAMA MODELİ TABANLI ARIZA TESPİTİ VE SINIFLANDIRMASI” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(10/07/2023).

Fevzeddin ÜLKER

TEŐEKKÜR

Tez alıőmam esnasında her zaman gece gndz kıymetli bilgi, birikim ve tecrbeleri ile bana yol gsteren ve destek olan danıőman hocam Dr. Öğr. Üyesi Ahmet KÇKER'e, öneri ve yorumlarıyla alıőmama destek olan hocalarım Prof. Dr. Ertan YANIKOĐLU, Do. Dr. Gkay BAYRAK ve Elektrik Elektronik MhendisliĐi Blmndeki tm hocalarım ve alıőma arkadaőlarım teőekkr ederim.

Doktora tez sreci boyunca bana duygusal destek ve moral veren kıymetli ve pek muhterem anneme, babama ve abime teőekkrlerimi sunarım.

Fevzeddin LKER

İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	vii
İÇİNDEKİLER	ix
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxv
1. GİRİŞ	1
1.1. Akıllı Şebeke	2
1.2. Dağıtık Üretim	3
1.3. Mikroşebeke	9
1.4. Dağıtık Enerji Üretim Kaynaklarının Güç Dağıtım Sistemine Entegrasyonu Sonucu Oluşan Koruma Problemleri	12
1.4.1. Kör koruma (koruma mesafesinin azalması) durumu	13
1.4.2. Yanlış açma durumu	13
1.5. Literatür Araştırması	14
1.5.1. Koordinasyon problemlerine yönelik çözüm yöntemleri	14
1.5.2. DEÜK'lerin kısıtlanmasına dayalı çözüm yöntemleri	16
1.5.3. Mevcut koruma yapılarına dayalı çözüm yöntemleri	17
1.5.3.1. Gerilim tabanlı koruma rölesi	18
1.5.3.2. Simetrik bileşen tabanlı koruma rölesi	18
1.5.3.3. Diferansiyel koruma rölesi	19
1.5.3.4. Mesafe koruma rölesi	20
1.5.3.5. Aşırı akım koruma rölesi	21
1.5.4. Adaptif koruma yöntemleri	22
1.5.5. Çok etmenli sistemler tabanlı koruma yöntemleri	26
1.5.6. Yapay zekâ destekli koruma yöntemleri	27
1.6. Tezin Amacı	31
2. ARIZA TESPİT VE SINIFLANDIRMASINA YÖNELİK SİNYAL İŞLEME TEKNİKLERİ VE ÖZELLİK ÇIKARIMI	35
2.1. Fourier Dönüşümü	35
2.2. Kısa Zamanlı Fourier Dönüşümü	36
2.3. Dalgacık Dönüşümü	36
2.4. Özellik Setinin Elde Edilmesi	44
3. TOPLULUK ÖĞRENME MODELLERİ VE ÖNERİLEN OLASILIKSAL AĞIRLIKLI OYLAMA MODELİ	57
3.1. Topluluk Öğrenme Modeli Topolojileri	59

3.2. Topluluk Öğrenme Yöntemleri	60
3.2.1. Torbalama (Bagging)	60
3.2.2. Artırma (Boosting)	61
3.2.3. İstifleme (Stacking)	61
3.2.4. Oylama (Voting)	62
3.3. Ağırlıksız Oylama Modeli	62
3.3.1. Çoğunluk tabanlı oylama modeli (Hard voting)	63
3.3.2. Olasılıksal tabanlı oylama modeli (Soft voting)	63
3.4. Ağırlıklı Oylama Modeli (Weighted Voting)	65
3.5. Oylama Modelleri Hakkında Yapılan Literatür Çalışmaları	66
3.6. Önerilen Olasılıksal Ağırlıklı Oylama Modeli	67
3.6.1. Önerilen oylama modelinde (OAOM) kullanılan temel öğrenciler ve bu öğrencilere ait parametrelerin belirlenmesi	69
3.6.1.1. Önerilen oylama modelinde kullanılan temel öğrenciler	70
3.6.1.2. Temel öğrencilere ait sınıflandırma parametrelerin ayarlanması	74
3.6.2. Eğitim aşaması	74
3.6.2.1. Çeşitlilik	75
3.6.2.2. Genelleme	76
3.6.2.3. K-katlı çapraz doğrulama	76
3.6.3. Eğitim aşamasında doğrulama setlerinden elde edilen Fskor ve ortalama mutlak hata değerlerinin elde edilmesi	78
3.6.4. Eğitim performansından elde edilen verilere göre ağırlık matrisinin oluşturulması	79
3.6.5. Eğitilen her bir öğrenci modele test setinin sunulması ve doğruluğu bilinmeyen ilk sınıf etiketlerinin elde edilmesi	80
3.6.6. Her bir öğrenci model için test örneklerinin sınıflarına ait sonsal olasılıksal dağılımlarının oluşturulması	81
3.6.7. Temel öğrencilere ait ağırlık katsayılarının belirlenmesi	82
3.6.8. Eğitim performansı ve olasılıksal katkı ile oluşturulan ağırlık matrisinin gösterimi ve nihai sınıf etiketinin belirlenmesi	82
4. TEST SİSTEMİ VE DAĞITIK ENERJİ ÜRETİM KAYNAKLARININ MODELLENMESİ	85
4.1. Yenilenebilir Dağıtık Enerji Üretim Kaynaklarının Modellenmesi	88
4.1.1. Fotovoltaik panel modeli	88
4.1.2. Rüzgâr türbini sistemi	90
4.2. Dağıtık Enerji Üretim Kaynaklarına İlişkin Kontrol Modelleri	92
4.2.1. Yenilenebilir dağıtık enerji üretim kaynaklarının DC-DC dönüştürücü kontrol modeli	92
4.2.2. Batarya DC-AC evirici kontrol modeli	93
4.2.3. Yenilenebilir dağıtık enerji üretim kaynaklarının DC-AC evirici kontrol modeli	94
4.3. Arızalı ve Arızalı Olmayan Olası Senaryoların Oluşturulması	95
4.4. Arızalı ve Arızalı Olmayan Verilerin Gürültülü Şekilde Elde Edilmesi	97
5. BULGULAR	99
5.1. Sınıflandırma Sürecine Dair Değerlendirme Ölçütleri	99
5.2. Arıza Tespiti ve Sınıflandırmasına İlişkin Ön Hazırlık	101
5.3. Arıza Tespiti ve Sınıflandırmasına Yönelik Performans Analizi	102
5.3.1. Önerilen OAOM'nin gürültülü veriler altında temel sınıflandırıcılar ile karşılaştırılması	102

5.3.2. Gürültülü veriler altında önerilen OAOM'nin oylama modelleri ile karşılaştırılması	106
5.3.3. Önerilen OAOM ile arızalı/arızalı olmayan durumlara ait normal ve gürültülü veri setleri için performans analizi	111
5.3.4. Önerilen OAOM'nin üç ve dört temel sınıflandırıcıdan oluşma durumuna göre performans analizi	114
5.3.5. Farklı sayıda özellik setleri ile hazırlanan eğitim ve test setlerinin önerilen oylama modeli (OAOM) üzerindeki performans analizi	114
5.3.6. Arıza tespit ve sınıflandırmasına yönelik kullanılan oylama modellerinin istatistiksel analizi	115
5.4. Bilinen Veri Setleri ile Önerilen Oylama Modelinin Doğruluğunun Test Edilmesi.....	117
5.5. Diğer Çalışmalarla Karşılaştırma	119
6. SONUÇLAR VE ÖNERİLER	121
KAYNAKLAR	125
ÖZGEÇMİŞ.....	145

KISALTMALAR

AAK	: Arıza akımı kısıtlayıcısı
AAR	: Aşırı akım rölesi
ADD	: Ayrık dalgacık dönüşümü
ATSP	: Arıza tespit ve sınıflandırma problemi
ATŞŞ	: Arıza tespit ve sınıflandırma şeması
AUC	: Eğri altında kalan alan (Area under the curve)
CERTS	: Elektrik Güvenilirliği Teknoloji Çözümleri Konsorsiyumu (Consortium for Electric Reliability Technology Solutions)
CHP	: Birleşik ısı ve güç tesisi (Combined Heat and Power)
ÇÇA	: Çoklu çözünürlük analizi
ÇÖM	: Çoklu öğrenme modelleri
DEÜK	: Dağıtık enerji üretim kaynakları
DG	: Dağıtık üretim (Distributed Generation)
ETC	: Ekstra ağaçlar sınıflandırıcısı (Extra Trees Classifier)
FD	: Fourier dönüşümü
FFA	: Faz faz arızası
FFTA	: Faz faz toprak arızası
FFFTA	: Faz faz faz toprak arızası
KEEL	: Knowledge Extraction based on Evolutionary Learning
KZFD	: Kısa zamanlı fourier dönüşümü
MAE	: Ortalama mutlak hata (Mean Absolute Error)
MCC	: Matthews korelasyon katsayısı (The Matthews correlation coefficient)
MLP	: Çok katmanlı algılayıcı (Multi-Layer Perceptron)
OAOM	: Olasılıksal ağırlıklı oylama modeli
OS	: Ortalama sıralama (Average Ranking)
TKK	: Tekrar kapamalı kesici
PMU	: Phasor measurement units
RF	: Rastgele orman (Random Forest)
SDD	: Sürekli dalgacık dönüşümü

SNR	: Sinyal gürültü oranı (Signal to Noise Ratio)
SS	: Standart sapma
SVM	: Destek vektör makinaları (Support Vector Machines)
TFTA	: Tek faz toprak arızası
TÖY	: Topluluk öğrenme yöntemleri
UCI	: University of California Irvine
VS	: Veri seti
YEK	: Yenilenebilir enerji kaynakları
YSA	: Yapay sinir ağları
WT	: Dalgacık dönüşümü (Wavelet Transform)

SİMGELER

a	: Ölçek
$a_{j,k}$: j. seviye ve k. lokasyondaki yaklaşıklık katsayısı
b	: Öteleme
$d_{j,k}$: j. seviye ve k. lokasyondaki detay katsayısı
FN	: Model tarafından yanlış şekilde tahmin edilen yanlış sınıf sayısı
FP	: Model tarafından yanlış şekilde tahmin edilen doğru sınıf sayısı
F_{1z}	: Detay katsayılarının mutlak maksimum karşılığı
F_{2z}	: Detay katsayılarının mutlak ortalama karşılığı
F_{3z}	: Detay katsayılarının entropi karşılığı
F_{4z}	: Detay katsayılarının varyans karşılığı
$h(n)$: Alçak geçiren filtre bankası
HV_m	: Hard voting yöntemi ile m. test örneğine ait nihai sınıf etiketi
$g(n)$: Yüksek geçiren filtre bankası
j	: Dalgacık ayrıştırma seviyesi
pr_{ij}	: i. sınıflandırıcı tarafından j. test örneğine karşılık tahmin edilen etiket
L	: Sınıflandırıcı/Öğrenici model sayısı
$M1$: Olasılıklar toplamı tabanlı oylama modeli
$M2$: Olasılıklar çarpımı tabanlı oylama modeli
$M3$: Olasılıklar maksimumu tabanlı oylama modeli
$M4$: Olasılıklar minimumu tabanlı oylama modeli
$M5$: Çoğunluk tabanlı oylama modeli
$M6$: Ağırlıklı oylama modeli
P_{noise}	: Gürültü gücü seviyesi
P_{sig}	: Sinyal gücü seviyesi
SV_m	: Soft voting yöntemi ile m. test örneğine ait nihai sınıf etiketi
S_{jk}	: j. sınıf etiketi ve k. sınıflandırıcının OAOM'ye ait nihai ağırlık ifadesi
TN	: Model tarafından doğru şekilde tahmin edilen yanlış sınıf sayısı
TP	: Model tarafından doğru şekilde tahmin edilen doğru sınıf sayısı

TABLO LİSTESİ

Sayfa

Tablo 1.1. Dağıtık üretim teknolojilerinin güç seviyeleri [17].	7
Tablo 3.1. Olasılıksal tabanlı oylama model çeşitleri.	65
Tablo 3.2. Temel öğrencilere ait model parametreleri.	75
Tablo 4.1. Transformör parametreleri.	85
Tablo 4.2. Dağıtık enerji üretim kaynaklarının kapasiteleri.	87
Tablo 4.3. Yük parametreleri.	87
Tablo 4.4. Hat parametreleri.	88
Tablo 4.5. Güneş paneli karakteristikleri.	88
Tablo 4.6. Rüzgâr türbini karakteristikleri.	91
Tablo 4.7. Olası arızalı senaryolar [128].	96
Tablo 4.8. Olası arızalı olmayan senaryolar [128].	96
Tablo 5.1. Karışıklık matrisi gösterimi.	100
Tablo 5.2. Önerilen OAOM'nin öğrenci modeller ile karşılaştırılması.	104
Tablo 5.3. OAOM'nin farklı oylama modelleri ile karşılaştırılması.	107
Tablo 5.4. Her bir etiket için karşılaştırmalı performans analizi.	112
Tablo 5.5. Friedman ve Finner Post Testi.	116
Tablo 5.6. Gerçek veri setleri.	117
Tablo 5.7. Önerilen OAOM'nin farklı veri setlerindeki performans analizi.	118
Tablo 5.8. Farklı çalışmalarla karşılaştırma.	120

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Klasik elektrik güç sistemi altyapısı [4].	2
Şekil 1.2. Türkiye yenilenebilir enerji üretim dağılımı [13].	4
Şekil 1.3. Avrupa yenilenebilir enerji üretim dağılımı [13].	4
Şekil 1.4. Küresel boyutta enerji kaynaklarının üretim dağılımı [14].	5
Şekil 1.5. Dağıtık üretim teknolojilerinin sınıflandırılması [15].	6
Şekil 2.1. Çoklu çözünürlük analiz görünümü [128].	39
Şekil 2.2. Farklı ayrıştırma seviyeleri için detay ve nihai yaklaşıklık katsayılarının seviyelerini gösteren frekans aralıkları [129].	39
Şekil 2.3. a) Fourier dönüşümü b) Kısa zamanlı fourier dönüşümü c) Dalgacık dönüşümü [130].	40
Şekil 2.4. Ayrık dalgacık dönüşümünün işleyişi.	40
Şekil 2.5. db4 alçak geçiren filtre katsayılarının dağılımı.	42
Şekil 2.6. db4 yüksek geçiren filtre katsayılarının dağılımı.	42
Şekil 2.7. db10 alçak geçiren filtre katsayılarının dağılımı.	43
Şekil 2.8. db10 yüksek geçiren filtre katsayılarının dağılımı.	43
Şekil 2.9. Özellik çıkarım aşaması [128].	46
Şekil 2.10. AG arızasında her bir faza ait 9. ve 10. ayrıştırma seviyeleri için detay katsayılarının dağılımı.	49
Şekil 2.11. AG arızası için her bir faza ait özelliklerin dağılımı.	50
Şekil 2.12. AB arızasında her bir faza ait 9. ve 10. ayrıştırma seviyeleri için detay katsayılarının dağılımı.	51
Şekil 2.13. AB arızası için her bir faza ait özelliklerin dağılımı.	52
Şekil 2.14. BCG arızasında her bir faza ait 9. ve 10. ayrıştırma seviyeleri için detay katsayılarının dağılımı.	53
Şekil 2.15. BCG arızası için her bir faza ait özelliklerin dağılımı.	54
Şekil 2.16. ABCG arızasında her bir faza ait 9. ve 10. ayrıştırma seviyelerine ait detay katsayılarının dağılımı.	55
Şekil 2.17. ABCG arızası için her bir faza ait özelliklerin dağılımı.	56
Şekil 3.1. Paralel şekilde gerçekleşen öğrenme modeli [147].	59
Şekil 3.2. Seri şekilde gerçekleşen öğrenme modeli [147].	60
Şekil 3.3. Topluluk öğrenme modellerinin sınıflandırılması [149].	61
Şekil 3.4. Çoğunluk tabanlı oylama modelinin mimarisi.	63
Şekil 3.5. Olasılıksal tabanlı oylama modelinin mimarisi.	64
Şekil 3.6. Ağırlıklı oylama modelinin mimarisi.	66
Şekil 3.7. Önerilen oylama modeline (OAOM) ait tasarım diyagramı [128].	69
Şekil 3.8. K-katlı çapraz doğrulama.	77
Şekil 4.1. Test sistemi [128].	86
Şekil 4.2. Dağıtık enerji üretim kaynaklarına ait DC-DC dönüştürücü modeli.	92
Şekil 4.3. Yenilenebilir DEÜK'lere ait evirici kontrol modeli.	95

Şekil 4.4. Üç fazlı akım sinyallerinin normal (gürültüsüz) görünümü	97
Şekil 4.5. Üç fazlı akım sinyallerinin SNR 40 dB gürültü seviyesindeki görünümü	97
Şekil 4.6. Üç fazlı akım sinyallerinin SNR 30 dB gürültü seviyesindeki görünümü	98
Şekil 4.7. Üç fazlı akım sinyallerinin SNR 20 dB gürültü seviyesindeki görünümü	98
Şekil 5.1. Arıza tespiti ve sınıflandırması için önerilen model diyagramı	102
Şekil 5.2. Doğruluk ölçütü altında önerilen OAOM'nin temel sınıflandırıcılar ile karşılaştırılması.	103
Şekil 5.3. Kesinlik ölçütü altında önerilen OAOM'nin temel sınıflandırıcılar ile karşılaştırılması.	105
Şekil 5.4. Fskor ölçütü altında önerilen OAOM'nin temel sınıflandırıcılar ile karşılaştırılması.	105
Şekil 5.5. 70-30 oranında bölünmüş veri seti altında önerilen OAOM ve oylama modellerinin karşılaştırılması.	109
Şekil 5.6. 60-40 oranında bölünmüş veri seti altında önerilen OAOM ve oylama modellerinin karşılaştırılması.	109
Şekil 5.7. 50-50 oranında bölünmüş veri seti altında önerilen OAOM ve oylama modellerinin karşılaştırılması.	110
Şekil 5.8. Farklı oranlarda bölünmüş veri setleri üzerinde önerilen OAOM ve oylama modellerinin performans sıralaması.	111
Şekil 5.9. Farklı sayılarda temel sınıflandırıcılardan oluşturulmuş OAOM yapılarının doğruluk performansı açısından karşılaştırılması.	114
Şekil 5.10. Farklı ayırıştırma seviyelerinden oluşturulmuş özellik setlerine bağlı olarak OAOM yapısının doğruluk performansı açısından karşılaştırılması.....	115

DAĞITIK ÜRETİM GÜÇ SİSTEMLERİNDE GELİŞTİRİLMİŞ OYLAMA MODELİ TABANLI ARIZA TESPİTİ VE SINIFLANDIRMASI

ÖZET

Mevcut elektrik güç sisteminde enerji talebinin artması ve fosil yakıtların sınırlı olması, enerji piyasasının serbestleşmesi, ekonomik ve çevresel kaygıların etkileri sonucunda, yenilenebilir ve yenilenemeyen enerji kaynaklarını içeren dağıtık üretim fikri popülerlik kazanmıştır. Dağıtık Enerji Üretim Kaynakları (DEÜK) güç sistemine dahil edilmesiyle pasif durumdan aktif duruma geçiş gerçekleşmiştir. Aktif duruma geçişle birlikte doğal olarak güç sistemindeki akımın yönü tek yönlü durumdan çift yönlü duruma dönüşmüştür.

Güneş panelleri ve rüzgâr türbinleri gibi yenilenebilir enerji kaynaklarının dağıtım şebekesine entegrasyonu, çift yönlü güç akışına ve arıza akımının genliğinin değişmesine neden olmuştur. Arıza akımı, DEÜK'lerin kapasitesinden, tipinden, sayısından ve konumundan etkilenebilir. Diğer yandan, yenilenebilir DEÜK'ler kesintili güç üretim karakteristiğine sahiptir, böylece tüketici tarafında da olası yük talebi belirsizliğine yol açabilmektedir. Bu bilgiler ışığında, DEÜK'lere sahip böyle bir güç sisteminde, yük paylaşımında, korumada ve kontrolde karmaşıklık mümkündür. Güç akışındaki çift yönlülük ile arıza akımı seviyesindeki değişiklik, koruma cihazları arasındaki koordinasyonun kaybolmasına ve sonuç olarak güç sisteminin güvenilirliğine yol açtı. Bu nedenle arıza tespiti ve sınıflandırmasında problemlerin çıkması kaçınılmazdır.

Arıza tespiti ve sınıflandırması için makine öğrenmesi modellerinin kullanımı üzerine birçok çalışma yapılmıştır. Ancak sınıflandırmada en zorlu problemlerden biri, her probleme ait veri setini doğru bir şekilde öğrenebilen genel bir sınıflandırıcının ortaya çıkmamış olmasıdır. Ayrıca sınıflandırıcıların veri setinin tamamını öğrenmesi gibi bir durum da söz konusu değildir. Farklı sınıflandırıcılar, bir veri kümesinin farklı alt uzaylarında farklı performans veya hata eğilimi gösterebilir. Dolayısıyla herhangi bir probleme yönelik optimale yakın bir sınıflandırıcı model oluşturulması, topluluk öğrenme modeli ile sağlanabilmektedir.

Literatürde yer alan topluluk öğrenme modelinin bir yöntemi olan oylama modelleri ile ilgili olarak ağırlıklı oylama modelinde sınıflara ait olasılıksal katkılar ve sınıflara ait performanslar sonuçları dikkate alınmamıştır. Diğer yandan ağırlıksız oylama modellerinde özellikle olasılıksal tabanlı oylama modelinde ise sınıflandırıcıların eğitim aşamasına dair performansları dikkate alınmamıştır. Literatürdeki araştırmalara göre, bildiğimiz kadarıyla arızasız/arızalı durumların tespiti ve çeşitli arıza türlerinin sınıflandırılmasıyla ilgili çoklu sınıflandırıcılardan oluşan olasılıksal ağırlıklı oylama modelinin kullanıldığı herhangi bir çalışma yapılmamıştır. Yukarıdaki açıklamalardan esinlenerek bu tez konseptinde olasılıksal ağırlıklı oylama modeli (OAOM) tabanlı arıza tespit ve sınıflandırma şeması (ATSS) önerilmiştir. Bu tez çalışmasında yukarıda bahsedilen oylama modellerinin zayıf yönleri ele alınarak önerilen oylama modeli

(OAOM) ile arıza tespiti ve sınıflandırma performansının geliştirilmesi hedeflenerek literatüre katkı sağlanmıştır.

Önerilen modelin çalışma prensibi, eğitim performansına dayalı sınıf katkılarına ve test seti ile sınıf başına olasılıklara dayanmaktadır. Eğitim aşamasında elde edilen doğrulama metriği (ortalama mutlak hata) ve Fskor ile modelin tahmin gücünü ve dengesiz sınıf dağılımını dikkate almaktadır. Test setindeki herhangi bir örneğin sınıf etiketi, eğitim aşamaları ve eğitim sonrası test setine ait sınıflandırıcıların sınıflarından elde edilen olasılıksal katkılarla elde edilir. Önerilen OAOM modelinin diğer oylama modellerine göre katkısı; ağırlıksız oylama modellerine ait olasılıksal tabanlı oylama yöntemlerinden olan olasılıklar toplamı tabanlı oylama yöntemi, ağırlıklandırılmış olasılıkların toplamı şekline dönüşmüştür ve ağırlıklar ağırlık matrisinden seçilerek elde edilmiştir.

Sinyaldeki ani değişimleri tespit edebilmek için örneklerin yapısal olarak detaylı bir şekilde yorumlanması gerekmektedir. Bu nedenle, sinyalin çekirdeğini temsil eden daha anlaşılır ve basitleştirilmiş bilgileri çıkarmak için özellik çıkarımı gerekmektedir. Bu tez çalışmasında özellik çıkarımı için kullanılan sinyal işleme yöntemi ayrık dalgacık dönüşümüdür. Dalgacık dönüşümü, çok çözünürlüklü zaman-frekans alanında saf sinyalin kesin özelliklerini sağlar. Kullanılan ana dalgacık fonksiyonu (db10) ve dalgacık ayrıştırma seviyeleri 9 ve 10'dur. 9. ayrıştırma seviyesi 11th ve 13th harmonik bileşenlerini, 10. ayrıştırma seviyesi ise 5th, 7th ve 9th harmonik bileşenlerini içerir. Bu tez kapsamında DEÜK'lerden oluşan güç dağıtım sistem modeline farklı tipte arızalar (tek faz toprak arızaları; AG, BG, CG, faz-faz arızaları; AB, BC, CA, faz-faz toprak arızaları; ABG, BCG, CAG, üç faz toprak arızası ABCG) uygulanmıştır.

Tanımlayıcı özellik fonksiyonları, bu arıza durumlarıyla ilgili dalgacık ayrıştırma seviyelerine ilişkin detay katsayılarına uygulanır. Bu tezde temel olarak 4 farklı özellik kullanılmıştır. Ancak 2 farklı dalgacık ayrıştırma seviyesi olduğu için 8 öznelik ve 3 farklı faz olduğu için toplam 24 özellik çıkarılmıştır. Bu özellikler, detay katsayılarının mutlak maksimumu, detay katsayılarının mutlak ortalaması, varyans ve entropidir.

Arıza tespiti ve sınıflandırması için önerilen olasılıksal ağırlıklı oylama modelinin (OAOM) ve destek vektör makinesi (SVM), ekstra ağaç sınıflandırıcı (ETC), rastgele orman (RF) ve çoklu katman algılayıcısı (MLP) içeren temel sınıflandırıcıların performanslarını değerlendirmek için kapsamlı bir karşılaştırmalı performans analizi yapılmıştır.

İlk olarak önerilen olasılıksal ağırlıklı oylama modeli (OAOM) ve bu modeli oluşturan temel öğrencilerin/sınıflandırıcıların arıza tespiti ve sınıflandırma performansları değerlendirilmiştir. Bu amaçla kapsamlı bir karşılaştırmalı performans analizi yapılmıştır. Önerilen OAOM ve makine öğrenimi yöntemlerinin farklı veri kümelerindeki performanslarını analiz etmek ve karşılaştırmak için doğruluk, duyarlılık, kesinlik, Fskor ve eğrinin altındaki alan (AUC) dahil olmak üzere çeşitli değerlendirme ölçütleri kullanılmıştır. ATSS'de önerilen OAOM yapısının farklı veri kümeleri (normal ve gürültülü veriler) üzerinde klasik öğrenme modellerinden daha yüksek performans gösterdiği görülmüştür. Sınıflandırıcıların genelleştirme kabiliyetini doğrulamak için, gürültüsüz veri seti üzerine toplamsal beyaz Gauss gürültüsü eklenir. Bu gürültü seviyeleri SNR 20 dB, SNR 30 dB ve SNR 40 dB'dir.

İkinci uygulamada, önerilen OAOM'nin etkinliği, ilgili arıza tespiti ve sınıflandırmasında literatürdeki oylama makinesi öğrenme modelleri kullanılarak

değerlendirilmiştir. 6 tür oylama modeli vardır: olasılıklar toplamı, olasılıklar çarpımı, olasılıklar maksimumu, olasılıklar minimumu, çoğunluk ve ağırlıklı. Bu modellerin performansı hem normal hem de gürültülü veri setleri üzerinde incelenmiştir.

Üçüncü uygulamada, önerilen OAOM'nin tahmin gücünü veya genelleme yeteneğini doğrulamak için eğitim-test veri kümeleri üzerinde kapsamlı bir analiz yapıldı. İlgili hata tespiti ve sınıflandırma problemi 70-30, 60-40 ve 50-50 gibi oranlarda farklı eğitim-test setlerine dönüştürülmüştür. Bu değerlendirme ile farklı oranlara sahip test setleri üzerinde OAOM'nin diğer oylama modellerine göre en yüksek genelleme yeteneğine sahip olduğu gözlenmiştir.

Dördüncü uygulamada, normal ve gürültülü veri setleri için her bir arızalı (10 farklı arıza türü) ve arızasız duruma ait (toplamda 11 etiketli) OAOM'nin arıza tespiti ve sınıflandırmasına yönelik performans analizinin gerçekleştirilmiştir.

Beşinci uygulamada, farklı sayıda temel sınıflandırıcılardan oluşan önerilen OAOM yapılarının doğruluk kriteri açısından performans etkinliği incelenmiştir. 4 sınıflandırıcıdan oluşan OAOM yapısının, 3 sınıflandırıcıdan oluşan OAOM yapısına göre daha başarılı olduğu ortaya çıkmıştır. Ayrıca sınıflandırıcı çeşitliliği kavramının topluluk öğrenme modeli için önemi vurgulanmıştır.

Altıncı durumda, 9. dalgacık ayrıştırma seviyesi (11th ve 13th harmonik bileşenleri) ve 10. dalgacık ayrıştırma seviyesi (5th, 7th ve 9th harmonik bileşenleri) için ayrı ayrı yeni bir özellik seti oluşturularak yeni arıza tespiti ve sınıflandırma problemlerine yönelik önerilen OAOM'nin performansı analiz edilmiştir. 9. ve 10. dalgacık ayrıştırma seviyelerine ait ayrı özellik setlerinin OAOM'deki arıza tespit ve sınıflandırma verimliliği incelenmiştir. Burada yeni duruma ait özellik setleri hem normal (gürültüsüz) hem de SNR 20 dB oranına sahip gürültülü veri setleri şeklinde oluşturulmuştur. SNR 20 dB'deki özellik setlerine ait arıza tespiti ve sınıflandırmasında, 9. ayrıştırma seviyesindeki özellik setinin, 10. ayrıştırma seviyesindeki özellik setine göre daha başarılı olduğu görülmüştür.

Yedinci uygulamada, arıza tespiti ve sınıflandırması için kullanılan oylama modellerinin performans sonuçlarına bağlı olarak istatistiksel analiz gerçekleştirilmiştir. OAOM'nin diğer oylama modellerine üstünlüğü Friedman ve Finner post hoc testleri ile araştırılmıştır. Sonuçlardan oylama modelleri arasında anlamlı sonuç veren ve kabul edilebilirliği tespit edilen modelin OAOM olduğu görülmüştür.

Son uygulamada ise tez çalışmasında kullanılan arıza tespit ve sınıflandırmasına yönelik oluşturulan veri seti dışında uluslararası platformlarda kabul görmüş farklı özelliklere sahip veri setleri kullanılarak önerilen OAOM ve farklı oylama modellerini değerlendirme ölçütleri (doğruluk, kappa ve Matthews Korelasyon Katsayısı (MCC)) ile karşılaştırılarak performans değerlendirmesi yapılmıştır. Elde edilen sonuçlardan OAOM yapısının etkinliğinin diğer oylama modellerine karşı doğrulandığı görülmüştür.

IMPROVED VOTING MODEL BASED FAULT DETECTION AND CLASSIFICATION IN DISTRIBUTED GENERATION POWER SYSTEMS

SUMMARY

As a result of the increase in energy demand and limited fossil fuels in the current electrical power system, as well as the liberalization of the energy market, and the effects of economic and environmental concerns, the idea of distributed generation, which includes renewable and non-renewable energy sources, has gained popularity. With the inclusion of Distributed Energy Generation Resources (DEGR) in the power system, transition from passive state to active state has been occurred. With the transition to the active state, it naturally changed the direction of current in the power system from one-direction to bi-direction.

The integration of renewable energy sources such as solar panels and wind turbines into the distribution grid has resulted in bi-directional power flow and a change in the amplitude of the fault current. The fault current can be affected from the capacity, type, number, and location of DEGRs. On the other hand, renewable DEGRs have an intermittent power generation characteristic, thus leading to potential load demand uncertainty on the consumer side. In such a power distribution system with DEGRs, complexity in load sharing, protection, and controlling is possible. The variation in the level of the fault current, together with the bi-directional in the power flow, led to the loss of coordination between the protection devices and, as a result, the reliability to the power system. Thus, it is inevitable that problems will arise in fault detection and classification.

Many studies have been conducted on the use of machine learning models for fault detection and classification. However, one of the most challenging problems in classification is the lack of a general classifier that can correctly learn the data set for each problem. In addition, it is not possible for the classifiers to learn the entire data set. Different classifiers may show different performance or error proneness in different subspaces of a dataset. Therefore, the composing of a near-optimal classifier model for any problem can be achieved with the ensemble learning model.

Regarding the voting models, which is a method of the ensemble learning model in the literature, the results of the probabilistic contributions and performances of the classes are not taken into account in the weighted voting model. On the other hand, in the unweighted voting models, especially in the probabilistic based voting model, the performance of the classifiers regarding the training phase is not taken into account. According to the studies in the literature, to the best of our knowledge, there has been no study using the probabilistic weighted voting model consisting of multiple classifiers for the fault detection and classification. Encouraged by the above-explanation, a fault detection and classification scheme (FDCS) has been proposed in this thesis concept. FDCS is based a probabilistic weighted voting model (PWVM) includes multiple diverse learning models. The contribution of the proposed OAOM

model compared to other voting models is that the sum of probabilities based voting method, which is one of the probabilistic-based voting methods of unweighted voting models, has turned into the sum of weighted probabilities and the weights are formed by choosing from the weight matrix.

The working principle of proposed model relies on training performance-based class contributions and per-class possibilities with test set. The validation metric (mean absolute error) and F-score obtained in the training stage can be improved the model's prediction power and imbalanced class distribution. A class label of any sample in test set is achieved with the training stages, and probabilistic contributions achieved from classes of classifiers.

To detect sudden changes in the signal, samples need to be interpreted in detail structurally. Therefore, feature extraction is required to extract more understandable and simplified information representing the core of the signal. The signal processing method used for feature extraction is discrete wavelet transform in this thesis study. Wavelet transform ensures definitive properties of pure signal in the multiresolution time-frequency domain. The used mother wavelet function and wavelet levels are db10 ve level 9-10. The frequency components of the 9th wavelet decomposition level include the 11th and 13th harmonic components, while the frequency components of the 10th wavelet decomposition level include the 5th, 7th, and 9th harmonic components. In this sense, 9 and 10 have been chosen as wavelet decomposition levels. Different types of faults (single-phase ground faults; AG, BG, CG, two-phase faults; AB, BC, CA, two-phase ground faults; ABG, BCG, CAG, three-phase ground fault ABCG) were applied to the model of power distribution system with DEGRs created within the scope of this thesis.

The descriptive feature functions are applied to detail coefficients pertaining to wavelet decomposition levels related to these fault states. In this thesis, basically 4 different features were used. However, since there are 2 different wavelet levels, there are 8 features and 3 different phases, a total of 24 features are extracted. These features are absolute maximum of detail coefficients, absolute average of detail coefficients, variance, and entropy.

A comprehensive comparative performance analysis was conducted to evaluate the performance of the proposed probabilistic weighted voting model (PWVM) and the basic classifiers, which include support vector machine (SVM), extra trees classifier (ETC), random forest (RF), and multi-layer perceptron (MLP), for fault detection and classification.

Firstly, the proposed probabilistic weighted voting model (PWVM) and the base learners/classifiers that formed this model have been evaluated their performance in fault detection and classification. For this purpose, a comprehensive comparative performance analysis was carried out. To analyze and compare performances of the proposed PWVM and machine learning methods on different datasets, the various evaluation metrics including the accuracy, sensitivity, precision, F-score, and area under the curve (AUC) have been utilized. It has been seen that the proposed PWVM structure in FDCS has higher performance than classical learning models on different datasets (normal and noisy data). To confirm generalization capability of the classifiers, additive white Gaussian noise is contributed over dataset with noise-free. These noise levels are SNR 20 dB, SNR 30 dB, and SNR 40 dB.

In the second case study, the efficiency of the proposed PWVM was evaluated by using the voting machine learning models in the literature in the relevant fault detection and classification. There are 6 types of voting models: sum of probabilities, product of probabilities, maximum of probabilities, minimum of probabilities, majority, and weighted. The performance of these models on both normal and noisy datasets was investigated.

In the third case study, to verify the predictive power or generalization ability of the proposed PWVM, a comprehensive analysis was performed on the training-test datasets. The related fault detection and classification problem into different training-test sets with ratios such as 70-30, 60-40, and 50-50. With this evaluation, it was seen that PWVM had the highest generalization ability compared to other voting models on test sets with different ratios.

In the fourth case study, it was performed a performance analysis related to fault detection and classification of PWVM of each faulted (10 different fault types) and no-faulted conditions (11 class labels in total) for normal and noisy datasets.

In the fifth case study, the performance efficiency of the proposed PWVM structures formed from different numbers of base classifiers in terms of accuracy criterion was investigated. It turned out that the PWVM structure consisting of 4 classifiers is more successful than the PWVM structure consisting of 3 classifiers. In addition, the importance of the concept of classifier diversity for the ensemble learning model was emphasized.

In the sixth case study, a new feature set is created separately for the 9th wavelet decomposition level (11th, and 13th harmonic components) and the 10th wavelet decomposition level (5th, 7th, and 9th harmonic components), and the performance of the proposed PWVM was analyzed for the new fault detection and classification problem. The performance analysis was examined for the case of classifying the PWVM structure only with the feature set belonging to 9th wavelet decomposition level and for classifying only with the feature set belonging to the 10th wavelet decomposition level. Here, the PWVM structure of normal (noiseless) dataset, and noisy datasets with SNR 20 dB of ratio is tested. In this analysis, it was seen that the feature set of 9th decomposition level had a better success in classifying the feature set at SNR 20 dB than the feature set of 10th decomposition level.

In the seventh case study, statistical analysis was carried out depending on the performance results obtained from the voting models used for fault detection and classification. The superiority of PWVM over other voting models was investigated by Friedman and Finner post hoc tests. From the results, it was seen that among the voting models, the model that gave meaningful results and was found to be acceptable was PWVM.

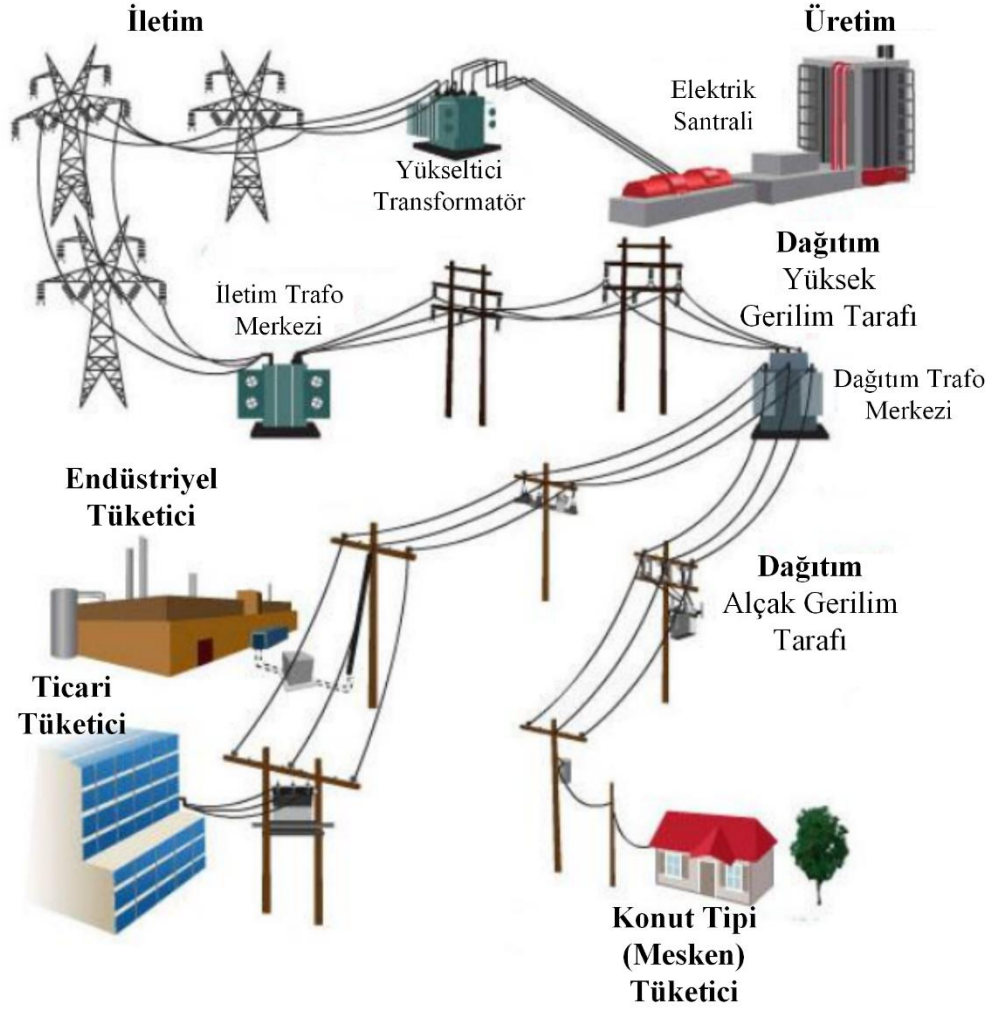
Finally, apart from the fault detection and classification dataset used in thesis study, performance evaluation was made by comparing the proposed PWVM and different voting methods with the evaluation metrics (accuracy, kappa, and Matthews Correlation Coefficient (MCC)), using datasets with different characteristics accepted in international platforms. It was observed from the obtained results that the efficiency of the PWVM structure was validated against other voting models.

1. GİRİŞ

Klasik elektrik güç sistemi üretim, iletim ve dağıtım sistemleri olmak üzere üç bölümden oluşmaktadır. Üretim tesislerinden üretilen elektrik enerjisi, yükseltici transformatörler ile enterkonnekte iletim sistemlerine taşınır ve daha sonra bir dizi transformatörler ile dağıtım şebekesi tarafına gerilim seviyesi düşürülerek son tüketicilere ulaştırılır [1].

Nükleer, termik veya hidroelektrik santralleri gibi büyük üretim tesisleri şehir merkezinden uzak bir lokasyonda konumlandırılmıştır. Üretim santrallerinde üretilen elektrik enerjisi en az kayıpla uzun iletim hatları boyunca taşınabilmesi amacıyla üretim noktasındaki yükseltici transformatör ile gerilim seviyesi yükseltilir. İletim hatları ile orta gerilim (OG) dağıtım trafo merkezine iletilir ve OG dağıtım trafo merkezinde gerilim seviyesi düşürülür. Daha sonra, son tüketicilerin elektrik enerjisini kullanabileceği şekilde alçak gerilim (AG) dağıtım trafo merkezindeki transformatör ile gerilim seviyesi düşürülür. Kırsal veya şehir merkezi dışında radyal sistemde ve kentsel alanlarda şebeke sisteminde olan dağıtım sistemleri, genellikle herhangi bir üretim olmadan çalışacak şekilde tasarlanmıştır [2]. Dağıtım şebeke yapıları radyal ve ring şeklinde olabilmektedir. İletim hatları dağıtım şebekesinde kullanılan model diyagramından farklı olarak ağ şeklinde yapıya sahiptir.

Zamanla dünya nüfusundaki artış ve yaşam kalitesinin yükselmesiyle birlikte enerji tüketiminde de artışlar meydana gelmektedir. Mevcut enerji üretim santrallerinin çalışması fosil yakıt tabanlı kaynaklara bağlı şekilde gerçekleşmektedir. Ancak zamanla enerji talebinde artış olması durumunda fosil yakıtların kullanımı ile ilgili sorunlarla karşılaşabileceği öngörülmektedir. Bu sorunlar üretim açısından, mevcut enerji rezervlerinin tükenme riski olması ve çevresel açıdan, sera gazlarının çevreye salınımının artmasıdır [3].



Şekil 1.1. Klasik elektrik güç sistemi altyapısı [4].

Bunların yanında enerji talebindeki artış ve eski bir şebeke altyapısına sahip olmasından dolayı Şekil 1.1. ile gösterilen klasik güç sistem altyapısının yenilenmesi, yeni klasik güç üretim merkezlerinin kurulması ya da iletim hatların ve transformatörlerin desteklenmesi gibi faaliyetler maliyet açısından sıkıntı oluşturabileceği öngörülmektedir. Bu sebeplerden dolayı güç sistem altyapısında köklü bir değişime gidilmesi kaçınılmaz görülmektedir.

1.1. Akıllı Şebeke

Mevcut elektrik şebekeleri, temelde fosil yakıtlara dayalı olarak çalışması, eski bir altyapıya sahip olması, sınırlı fonksiyonel özelliklere sahip olması ve ek olarak iletim hatlarının sık arızalara maruz kalması gibi sıkıntılarla karşı karşıyadır. Bu bağlamda konvansiyonel elektrik güç sistemleri, çevresel kaygıları hafifletmek, devlet teşviklerini ele almak ve tüketici taleplerine yanıt vermek için sürekli ve hızlı

değişikliklerle karşılaşmıştır. Mevcut güç sisteminin “geliştirilmiş güvenilirlik ve sürdürülebilirlik” kavramlarıyla donatılması gerekliliği ortaya çıkmıştır [5]. Şebeke ve tüketiciler arasındaki iki yönlü haberleşme ve iletim hatlarındaki algılama özellikleri mevcut şebekenin akıllı bir şebekeye dönüşmesinde büyük pay sahibi olmuştur. Bunların yanında akıllı şebeke konseptini daha etkili kullanabilmek için günümüz elektrik şebekesine gelişmiş sayaç altyapısı, dağıtık otomasyon ve dağıtık enerji üretim kaynaklarının entegrasyonu öngörülmektedir [6]. Tüm bu fikirlerin bütünleşmesi sonucunda, bilgi ve haberleşme altyapısı bünyesinde, enerji tedarikçileri ve tüketiciler arasında akıllı üretim ve tüketim faaliyetlerinin gerçekleştirilmesi beklenmektedir.

Akıllı şebeke fikri ile gelişmiş algılama, haberleşme ve kontrol teknolojileri kullanılarak kendi kendini iyileştirebilmesi, yüksek güvenilirlik ve güç kalitesi sağlayabilmesi, siber saldırılara karşı dayanıklı olması ve çok yönlü güç akışıyla çalışması amaçlanmıştır [7, 8]. Akıllı şebekeden beklenen faydalar kısaca aşağıda sıralanmıştır [9];

- Daha verimli enerji iletimi
- Güç kesintilerine karşı hızlı müdahale edilmesi
- Şebeke sisteminin işletme ve bakım maliyetlerinin azalması sonucunda tüketiciler için daha düşük güç maliyetlerine yol açması
- Elektrik fiyatlarının düşürülmesine de yardımcı olacak azaltılmış pik talep
- Büyük ölçekli yenilenebilir enerji sistemlerinin artan entegrasyonu
- Yenilenebilir enerji sistemlerini içeren güç üretim sistemlerine sahip tüketicilerin daha iyi entegrasyonun sağlanması
- Geliştirilmiş güvenlik


1.2. Dağıtık Üretim

İletim ve dağıtım şebekeleri, büyük güç santrallerinde elektrik üretimi ve tüketicilerin pasif rolü göz önünde bulundurularak geliştirilmiştir [10]. Ancak mevcut güç sisteminde karşılaşılan sorunlar dikkate alındığında enerji pazarının serbestleşmesi, ekonomik ve çevresel kaygı etkileri sonucunda dağıtık enerji üretim kaynağı (DEÜK) gündeme gelmiştir [11]. Bunun yanı sıra, küresel iklim kaygısı, artan güç talebi, daha fazla esneklik ihtiyacı, yaşlanan şebeke altyapısı ve enerji üretimi kaynaklarını


çeşitlendirme ihtiyacı dağıtık enerji üretim kaynağı fikrini şekillendirmiştir. Yukarıda belirtilen itici etmenlere ilaveten merkezi üretim odaklı mevcut güç sistemindeki aksaklıklar, altyapının eskimiş olması, altyapının bakım onarım maliyetleri, iletim ve dağıtım hatlarındaki güç kayıplarının olması diğer yandan da gelişmiş ülkelerin yenilenebilir enerji kaynakları (YEK) kullanımına yani dağıtık enerji üretim kaynaklarına olan ilgiyi daha da artırmıştır [12].

Türkiye’de ve Avrupa’da üretilen yenilenebilir enerji üretiminin yıllara göre dağılımları Şekil 1.2-1.3’te görülmektedir. Buradan çıkarılacak sonuç; 2013 yılından 2022 yılına kadar olan süreçte yenilenebilir enerji kaynaklarına olan ilginin arttığıdır.

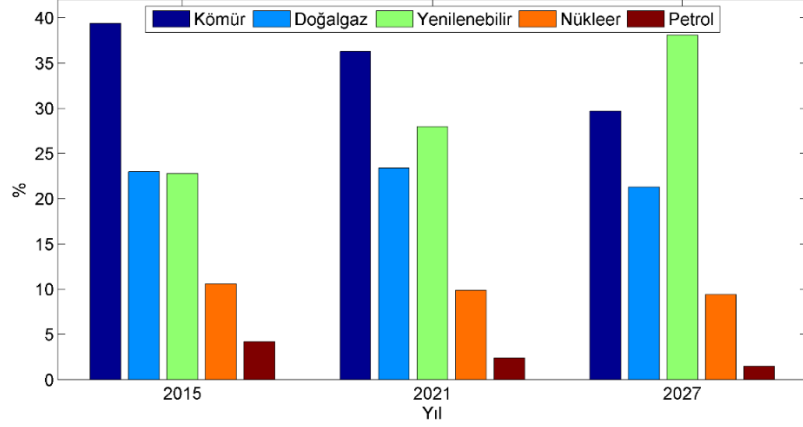
Şekil 1.4’te Küresel boyutta 2015, 2021 ve 2027 yıllarındaki yenilenebilir enerji kaynakları ile üretilen elektrik enerjisinin diğer enerji kaynakları ile olan yüzdeleri verilmiştir.



Şekil 1.2. Türkiye yenilenebilir enerji üretim dağılımı [13].



Şekil 1.3. Avrupa yenilenebilir enerji üretim dağılımı [13].



Şekil 1.4. Küresel boyutta enerji kaynaklarının üretim dağılımı [14].

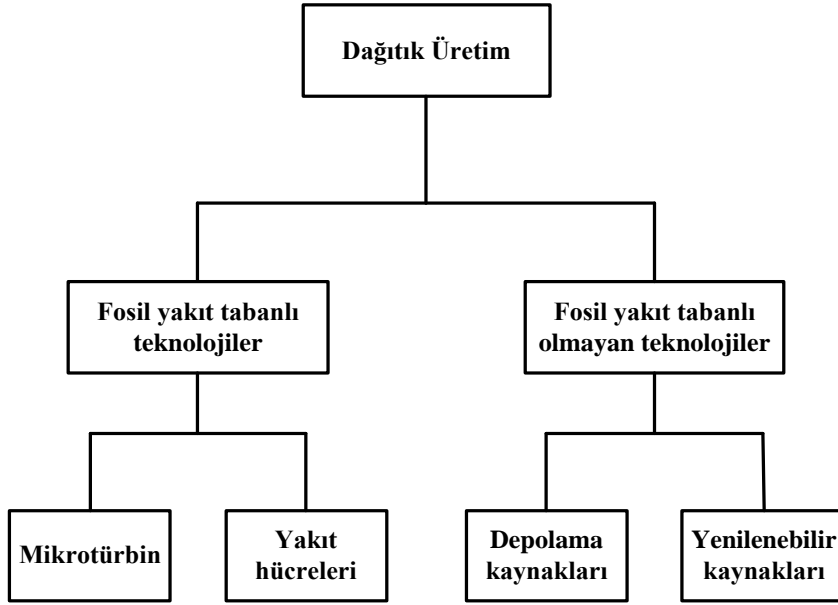
Ayrıca 2027 yılında yenilenebilir enerji kaynaklarının üretim yüzdesi, fosil yakıt kaynağı olan kömürden yüksek olacağı öngörülmektedir.

Dağıtık üretim teknolojilerinin fosil yakıt tabanlı ve fosil yakıt tabanlı olmayan şekilde sınıflandırılması Şekil 1.5’te gösterilmiştir.

Dağıtık üretim (Distributed Generation-DG) terminolojisinin farklı şekilde tanımlanmaları El-Khattam ve ark. tarafından gerçekleştirilen çalışmada belirtilmiştir [15];

- “Dispersed generation” terimi Kuzey Amerika’da dağıtık üretim
- “Embedded generation” terimi Güney Amerika’da gömülü üretim
- “Decentralized generation” terimi Avrupa ve bazı asya şehirlerinde dağıtık üretim olarak ifade edildiği belirtilmiştir.

Pepermans ve ark. tarafından dağıtık üretim, genel anlamda küçük ölçekli elektrik üretimi olarak ifade edilmiştir. Dağıtım şebekesine bağlanan küçük ölçekli üretim birimleri, dağıtık üretimin bir parçası olarak vurgulanmıştır [16]. Yukarıdaki tanımlamaya benzer olarak dağıtık üretim; yük yakını veya tüketici sayacı tarafında kurulan üretim birimleri şeklinde ifade edilmiştir. Tüm bu fikirleri kapsayacak şekilde Ackermann ve ark. tarafından dağıtık üretim; tüketici sayacı tarafı veya dağıtım şebekesine doğrudan bağlanan elektrik güç üretim kaynağı olarak tanımlanmıştır [17].



Şekil 1.5. Dağıtık üretim teknolojilerinin sınıflandırılması [15].

Enerji alanında organizasyonlar/kurumlar: Elektrik Enerjisi Araştırma Enstitüsü, Uluslararası Büyük Elektrik Sistemleri Konseyi (CIGRE), Elektrik ve Elektronik Mühendisleri Enstitüsü tarafından dağıtık üretim tanımı sırasıyla [16, 17]:

1. 'DG, birkaç kW'tan 50 MW'a kadar küçük üretim birimleri ve/veya tipik olarak müşteri yüklerinin veya dağıtılmış enerji kaynakları olarak dağıtım ve alt iletim trafo merkezlerinin yanına yerleştirilmiş enerji depolama cihazları olarak tanımlanır.'
2. 'DG, genellikle dağıtım şebekesine bağlı olan ve merkezi olarak planlanmayan veya dağıtılmayan, maksimum kapasitesi 50-100 MW olan tüm üretim birimleri olarak tanımlanır.'
3. 'DG, bir güç sistemindeki hemen hemen her noktada ara bağlantıya izin verecek şekilde merkezi üretim tesislerinden yeterince küçük olan tesislerden elektrik üretimi olarak tanımlanır.'
4. 'DG, tüketici tarafında hizmet vermek ve aynı zamanda dağıtık bir şebekeye destek sağlamak için dağıtım gerilim seviyesinde şebekeye bağlanan bir tür üretim tesisi olarak tanımlanır'.

Dağıtık enerji üretim kaynaklarının yüklenme oranları yerel olarak çalışma koşulları açısından değişebileceğinden dolayı dağıtık üretim tanımlanmasında yüklenme/üretim kapasiteleri baz alınmayacağı belirtilmiştir [17]. Bu bağlamda farklı ölçeklerdeki

dağıtık enerji üretim kaynaklarının güç seviyeleri açısından sınıflandırılması Tablo 1.1’de gösterilmiştir.

Tablo 1.1. Dağıtık üretim teknolojilerinin güç seviyeleri [17].

Dağıtık üretim büyüklüğü	Güç seviyeleri
Mikro ölçekli dağıtık üretim	1 Watt < 5 kW
Küçük ölçekli dağıtık üretim	5 kW < 5 MW
Orta ölçekli dağıtık üretim	5 MW < 50 MW
Büyük ölçekli dağıtık üretim	50 MW < ~300 MW

Dağıtık enerji üretim kaynaklarının güç sistemlerinde kullanımı ile küçük ölçekli birleşik ısı ve güç tesisi (CHP-combined heat and power) uygulamalarının yaygınlaşması sağlanmıştır. Ayrıca, tüketiciye yakın dağıtık üretimin varlığı, son tüketicilere iletilen enerjinin güç kalitesini ve güvenilirliğini artırabileceği de öngörülmektedir. Genel olarak, DEÜK’ün güç sistemine entegrasyonu sonucu başlıca üç faydası; CHP yoluyla artan enerji verimliliği, azaltılan karbon emisyonları ve iyileştirilmiş güç kalitesi ve güvenilirlik, ancak bunların yanında azaltılmış hat kayıpları ve şebeke altyapı bünyesinde genişlemenin ertelenmesi gibi diğer birçok fayda vardır [16, 18-20]:

1. Elektrik piyasalarının serbestleştirilmesi
2. Elektrik sektöründeki etmenlerin değişen piyasa koşullarına esnek bir şekilde cevap verilmesinin sağlanması.
3. Güvenilirliğin ve güç kalitesinin gelişmesi
4. Maliyet azalması ve yüksek verimlilikle küresel enerji tüketiminde önemli katkı sağlaması
5. İletim ve dağıtım hattı kapasitelerinin artırılması
6. İletim ve dağıtım altyapılarına gecikmeli yatırım sonucu elektrik maliyetlerinden tasarruf sağlanması
7. Şebeke operatörlerinin talep cevabına karşılık güç üretebilme kabiliyetine sahip olmalarından dolayı frekans düşmesinin dengelenmesi

Dağıtık enerji üretim kaynaklarının güç sistemi üzerinde olumlu etkileri olduğu gibi olumsuz etkileri de olabilmektedir. Dağıtık enerji üretim kaynaklarının oluşturabileceği potansiyel sıkıntılar aşağıda belirtilmiştir:

Yenilenebilir enerji kaynaklarının doğası gereği kesintili güç üretim çıkışına sahip olabilmektedir. Örneğin; güneş panellerinin bulutlu havada çıkış gücünün azalması sonucu güç üretim-tüketim dengesini sağlamada sıkıntı oluşturabilmektedir. Daha yüksek gerilim değişimleri ve farklı reaktif güç gereksinimleri gibi dağıtım şebekelerinde teknik etkilere sahiptir [21].

Dağıtık üretim tesislerinden elektrik şebekesine aktarılan güç miktarı, güç sistemi operatörleri için potansiyel olarak zorluklar oluşturabilmektedir. Bu zorluklar; gerilim dalgalanması, ters güç akışı ve güç elemanların aşırı ısınmasıdır [12]. Yüke ya da transformatöre bağlanacak yenilenebilir DEÜK'lerin güç değişimlerine ve buna bağlı olarak istenmeyen gerilim değişimlerine sebep olabileceği de belirtilmiştir [11].

Dağıtık enerji üretim kaynakları tarafından şebekeye enjekte edilen ve kontrol edilemeyen gücün güç sistem bileşenlerinde aşırı yüklenme yapması sonucu aşırı ısınma ile kullanım sürelerinin azalmasına yol açabileceği belirtilmiştir [12, 22].

Iweh ve ark. tarafından dağıtık enerji üretim kaynaklarının alçak gerilim (AG) seviyesindeki bir şebekede oluşturacağı etkiler ile ilgili olarak güç dalgalanmalarının, istenmeyen gerilim değişimine neden olabileceği ve bu durumda, özellikle enerji tüketiminin az olduğu koşullar altında gerilim seviyesinde belirgin bir artışın olacağı buna ek olarak yüksek sayıda yenilenebilir enerji kaynaklarının güç sistemine entegrasyonu sonucu gerilim seviyesindeki değişimin daha da kötü olacağı belirtilmiştir [12].

Loulia ve ark. alçak gerilim radyal şebeke fiderlerine yüksek oranda dağıtık enerji kaynakları yerleşimi sonucu gerilim ihlali olabileceğini çalışmasında vurgulamıştır. Gerilimi belirli sınırlar içerisinde tutmak ve dağıtık üretim kaynaklarını yüksek verimli bir şekilde işletebilmek için AG fiderlerinin sonlarına DEÜK'lerin yerleştirilmesinin daha uygun olacağı belirtilmiştir [23].

Dağıtık enerji üretim kaynaklarının dağıtım şebekesine konuşlandırılması, dağıtım şebekesinin çalışmasını etkileyebileceği ve bu üretim kaynakları planlı bir şekilde yerleştirilmediği durumda güç dağıtım sistemine ait kayıpları, işletme maliyetlerini

artırabileceği ve dağıtım şebekesinin istikrarlı çalışmasını etkileyebileceği de belirtilmiştir [18, 24].

AG şebekelerinde dağıtık üretiminin giderek yaygınlaşmasıyla birlikte gerilim sorunları; kurulu gücün ve YEK tabanlı enerji üretiminin artmasında en büyük engel haline gelmektedir [10].

Baran ve ark. yaptıkları çalışmada yüksek oranda DEÜK'lerin (fotovoltaik sistemler) dağıtım şebekesinde yer almasıyla hem sistem korumasında hem de gerilim profili üzerinde etkileri olduğu sonucuna varmışlardır [25].

Coster ve ark. yaptıkları araştırmada DEÜK'lerin dağıtım şebekesine bağlanması ile gerilim kontrolünün, şebeke korumasının ve arıza akım seviyesinin etkileneceğini belirtmişlerdir [26].

DEÜK'ler dağıtım şebekesinde yer bulmaları sonucunda güç sistemi pasif konumdan aktif konuma gelmiştir. Bu durum çift yönlü güç akışının olmasına ve hem şebeke planlaması hem de dağıtım şebekesi planlaması açısından zorluk getirmiştir [22, 26].

1.3. Mikroşebeke

Çok sayıda DEÜK'lerin güç sisteminde oluşturacağı etkiler analiz edildiğinde potansiyel olarak bu kaynakları güç sistem ağında güvenli ve verimli bir şekilde çalıştırma ve kontrol etmenin güç sistem tasarımcıları açısından zorluk oluşturacağı belirtilmiştir [19]. Bunun karşılığında DEÜK'leri klasik güç sisteminden farklı şekilde merkezi konumda olmadan uyumlu bir biçimde koordine edebilmek, şebeke üzerindeki kontrol yükünü azaltabilmek ve bu dağıtık enerji üretim kaynaklarından maksimum seviyede faydalanabilmek için mikroşebekeler tarafından kısmen ele alınabilir.

Lasseter ve ark. tarafından mikroşebeke, lokal alana ısı ve güç sağlayabilme kabiliyetini barındırması ve aynı zamanda kontrol edilebilme özelliği ile yük ve dağıtık enerji kaynaklarından oluşan küçük ölçekli bir güç sistemi olarak tanımlanmıştır [27].

Mikroşebeke hem şebeke tarafı hem de tüketici tarafı açısından değerlendirilir [27]:

Şebeke açısından mikroşebeke; güç sisteminin kontrol edilebilir küçük bir parçası olarak değerlendirilir. Örneğin güç sistemine ait küçük bir parça olan mikroşebeke, iletim sistemlerini destek olmak amacıyla saniyeler içerisinde yanıt verebilen tek bir dağıtılabılır yük olarak kontrol edilmesidir.

Müşteri açısından mikroşebeke; tüketicilerin özel ihtiyaçlarını sağlamak, lokal güvenilirliği artırması, fider hat kayıplarını azaltması, lokal gerilimleri desteklemesi, atık ısıyı kullanarak artan verimliliği sağlaması, gerilim düşümünü düzeltmesi veya kesintisiz güç kaynağı işlevlerini sağlaması açısından tasarlanabilir.

Mikroşebeke yaklaşımını klasik güç sisteminden ayıran temel kavram; üretim kaynaklarının küçük olması, tüketicilere yakın olarak yerleştirilmesi ve dağıtılmasıdır. Sharkh ve ark. mikroşebekenin temel özelliğini, lokal elektrik üretimi sayesinde mikroşebekenin güç ihtiyacının karşılanması olarak belirtmişlerdir [28].

Cagnano ve ark. özellikle değişken ve öngörülemeyen yenilenebilir enerji kaynağı tabanlı DEÜK'lerin alçak ve orta gerilim dahil olmak üzere dağıtım şebekelerine entegrasyonu için mikroşebekelerin uygun bir çözüm yöntemi olduğu belirtilmiştir. Bu üretim kaynakların güç sisteminde yer bulmasını kolaylaştırmıştır [29]. Diğer yandan üretim kapasitesi olarak öngörülemeyen bu üretim kaynaklarının olması mevcut güç üretim ve tüketim talebi arasındaki değişimleri karşılama adına enerji depolama elemanlarına olan ihtiyacı çıkarmıştır. Sistemde beklenmedik değişimlerde güç üretim ve tüketim dengesizliğinin olması durumunda enerji ihtiyacının karşılanması için enerji depolama elemanlarından faydalanılması gerekmektedir [30].

Mikroşebekelerin en büyük etkisi, son müşterilere daha yüksek güvenilirlikli ve daha iyi güç kalitesinde enerjinin sağlanmasıdır. Ayrıca, mikroşebekeler talep gücün yüksek olduğu zamanlarda kullanım için dağıtılabılır şekilde güç sağlaması, dağıtım sistem kapasitenin büyümesini erteleyerek ya da önleyerek lokal dağıtım şebekesine ek faydalar sağlayabilir [30].

En az bir dağıtım üretim kaynağı ve yük içeren mikroşebeke, elektrik dağıtım sisteminde planlanmış adalanmış güç sistemleri oluşturabilir. Mikroşebeke sistemi, minimum zaman zarfında oluşan elektrik kesintisi ile güç sistem alanından ayrılabilir veya güç sistemine yeniden bağlanabilir [30].

Mikroşebekelerin işletimi birkaç temel teknolojik elemanlardan oluşur: Bunlar DEÜK, enerji depolama elemanları, ara bağlantı anahtarları ve kontrol sistemleridir [28, 30].

Mikroşebekenin güç ve enerji dengesi kabul edilen sınırlar içerisinde kontrol edilmesi gerekir. Burada üç önemli kriter bulunmaktadır: gerilim, frekans ve güç kalitesidir [28].

Bir mikroşebekenin kontrolü, güç dengesi ve enerji depolama sorunu ile yakından bağlantılıdır [28].

Dağıtık enerji üretim kaynaklarının mikroşebekeye entegrasyonu güç elektroniği elemanları sayesinde gerçekleşmektedir. Bu elemanlar ile dağıtık üretim kaynakları tarafından üretilen güç; elektrik güç sisteminde kullanılabilir şekilde (şebeke gerilimi-frekansı ile uyumlu şekilde) dönüştürülür [30, 31].

Dağıtık enerji üretim kaynaklarının evirici arayüzü ile şebekeye bağlantısı uluslararası standartlarda kabul edilmiş sınırlar içerisinde olması gerekir. IEEE 1547 standartında “Dağıtık kaynakların elektrik güç sistemlerine bağlantısı için IEEE standardı” başlıklı çalışmada, DEÜK’lerin optimum güç faktöründe işletilmesi, diğer yandan şebekeye aktarılan akımın toplam harmonik yüzdesine ait gereken sınırlar belirtilmiştir [32].

Bu yapıların ortaya çıkmasının temelinde tüketicilere güvenilir ve istenilen güç kalitesinde enerji sağlanmasıdır [33]. Diğer yandan dağıtım sistemine mikroşebekelerin entegrasyonu kararlılık, kontrol, enerji paylaşımı ve koruma gibi konularda zorluk çıkarmıştır [34].

Güç sistemine DEÜK’lerin katılması ile pasif yapı durumundan aktif yapı durumuna geçilmiştir. Aktif yapı durumuna geçilmesiyle klasik güç sistemindeki akım yönünün tek yönde olmaktan çıkıp çift yönlü duruma geçmiştir. Güç akışındaki çift yönlülük ve arıza akımı seviyesindeki değişim, koruma araçları arasındaki koordinasyon bozukluğuna ve bunların sonucu olarak güç sistemine olan güvenilirliğin azalmasına yol açmıştır [35, 36]. Arıza akım seviyesinin değişimini etkileyen unsurlardan biri DEÜK’lerin türü yer almaktadır [37]. Örneğin; inverter tabanlı DEÜK’ün arıza akım değeri nominal akımın yaklaşık 2 katına kadar kısıtlama yaptığı bilinmektedir [38]. Bu durumda ise ada çalışma modunda kullanılan inverter tabanlı DEÜK’ler, arıza esnasında arıza akımını kısıtlamaları sonucunda klasik koruma elemanları ile koruma yapılmasını imkânsız duruma getirmiştir [39]. DEÜK türü önemli olduğu gibi DEÜK sayısı, kapasitesi ve arızanın gerçekleşme yeri de arıza akım seviyesindeki değişimi gösteren önemli etkenlerdir [37, 40-41].

Eğer arızanın gerçekleşme yeri DEÜK’ün ve şebekenin arkasında olma durumunda hem şebekeden hem de DEÜK’ten arıza akım katkısının gelmesi ile toplam arıza akımı artacaktır. Toplam arıza akımına şebekeden gelen arıza katkısının azalması ile şebekenin önündeki arızayı tespit edememesine ve röle koordinasyonu problemlerine

neden olabilmektedir. DEÜK'ün güç sistemine katılması ile arıza empedansının azalmasına yol açabilir ve böylece düşük çıkış empedansına sahip inverter tabanlı DEÜK'lerde yüksek seviyede arıza akımına yol açabilir [42].

Dağıtık enerji üretim kaynakları mevcut elektrik güç dağıtım sisteminde yer almasıyla koruma koordinasyon problemlerine, bununda en belirgin örnekleri; kör koruma problemi ve yanlış açma gibi koruma sorunlarını ortaya çıkarmıştır [43, 44]. Belirtilen sorunlarla ilgili detaylı bilgiler daha sonraki bölümde detaylı olarak verilecektir.

1.4. Dağıtık Enerji Üretim Kaynaklarının Güç Dağıtım Sistemine Entegrasyonu Sonucu Oluşan Koruma Problemleri

Klasik elektrik dağıtım şebekesinin koruma yapıları, radyal şebeke modeline göre tasarlanmıştır. Bu koruma yapıları; tekrar kapamalı kesici (TKK), sigorta ve ters zaman karakteristiğine sahip aşırı akım röle (AAR)'lerden oluşmaktadır. Tipik bir enerji dağıtım sisteminin koruma yapısı, arızaya en yakın olan koruma cihazının önce çalıştığı ve çalışmazsa yedek korumanın önceden belirlenmiş bir zaman gecikmesinden sonra çalıştığı zaman veya akım koordinasyon ilkesine dayanmaktadır.

Klasik radyal sistemler, AAR ve sigorta ile korunurken ağ yapıya sahip dağıtım sistemleri yönlü AAR ile korunmaktadır. Ancak dağıtık enerji üretim kaynakların dağıtım şebekesine katılmasıyla koruma koordinasyonu olumsuz anlamda etkilenmiştir [45]. DEÜK ünitelerinin dağıtım sistemine entegrasyonu, kısa devre akımlarının hem seviyesini hem de yönünü etkiler ki bu durum seçici olmayan koruma eylemlerine yol açabilmektedir [46].

DEÜK'ler; tek kaynaklı ya da tek yönlü güç akışına sahip dağıtım şebekesinde yer alması sonucu dağıtım şebekesini çok kaynaklı çift yönlü güç akışına dönüştürmüştür. Bu ise olası koordinasyon kaybına yol açmasına ve mevcut koruma cihazlarının öngörülemeyen çalışma sürelerine sebebiyet vermiştir [47].

DEÜK'ler elektrik dağıtım şebekesine katılması sonucu DEÜK'lerin tahmin edilemeyen arıza akım katkısından dolayı tekrar kapamalı kesici – sigorta arasındaki koordinasyonun bozulabileceği belirtilmiştir. Koordinasyon kaybı sonucu geçici arızalar kalıcı arızalara dönüşebileceği de belirtilmiştir.

Naiem ve ark. tarafından DEÜK'ler güç dağıtım sisteminde yer alması sonucu tekrar kapamalı kesici – sigorta koordinasyonu üzerindeki etkileri analiz edilmiştir. Bu söz

konusu koordinasyonun devam etme ya da bozulma durumunu sınıflandırmak için bir çalışma gerçekleştirilmiştir [48]. Ancak dağıtım şebekelerine DEÜK'lerin eklenmesi ile arıza akım seviyesindeki değişime, çift yönlü güç akışının olmasına, koruma araçları arasında röle-röle ve sigorta-TKK gibi eleman çiftlerinde koordinasyon bozukluğuna yol açmıştır.

Brahma ve Girgis yaptıkları çalışmada yüksek oranda DEÜK'lerin dağıtım şebekesinde olmaları durumunda sigorta ve TKK arasındaki koruma koordinasyonun muhtemelen bozulacağını ve bu durumun klasik TKK'lar ile düzeltilemeyeceğini belirtmiştir [49].

1.4.1. Kör koruma (koruma mesafesinin azalması) durumu

Röleler belli bir mesafeyi korumak için kullanılır. Rölenin koruma uzaklığı; minimum toparlanma akımı ile belirlenmektedir. DEÜK'ün olması, AAR'nin koruma mesafesini azaltmaktadır. Böylece arızalı hattın tespit edilememesini yol açmaktadır. Bu durumda eşdeğer empedans artar ve bu da aynı arıza direnci için arıza akımını azaltır. Aynı şekilde DEÜK güç enjekte etmesi durumunda da rölenin koruma mesafesi azalır [50]. DEÜK'lerin arıza akımına olan katkılarından dolayı, şebekenin toplam arıza akımına olan katkısı azalacaktır. Bu azalma, muhtemelen röle tarafından kısa devre akımının tespit edilememesine neden olacaktır, çünkü şebekeden gelen kısa devre akımı asla toparlanma akım seviyesine ulaşamayacaktır [51, 52].

Burada bir çıkarımda bulunulursa DEÜK'lerin arıza akımına olan katkılarının artması koruma sistemlerinin hassaslığını doğrudan etkilemekte ve dolayısı ile güvenilirliği de etkilemektedir.

1.4.2. Yanlış açma durumu

Yanlış açma, DEÜK'e bağlı fidere bitişik olan üst taraftaki hatta arıza olması durumunda meydana gelmektedir. DEÜK'ten gelen arıza akımının toparlanma akımını aşması durumunda asıl arıza akımı temizlenmeden önce sağlam olan hattın sistemden ayrılmasına neden olabilmektedir [42, 52]. Bu ise başlangıçta bahsedilen koruma sorunlarından seçicilik problemine kapsamaktadır. Bu durum özellikle aşırı akım rölesi ile korunan uzun fider hattına sahip olan zayıf şebekelerde yanlış açma ile sonuçlanabilmektedir. Böyle bir durumda hattın sonunda bulunan rölelerin küçük toparlanma akımı değerine ayarlanması gerektiği belirtilmiştir.

1.5. Literatür Araştırması

Araştırmacılar tarafından DEÜK'lerin meydana getirdiği koruma problemlerini mevcut koruma yapıları ile nasıl bir çözüm üretileceği önemli bir konuyu oluşturmuştur. Bu üretim kaynaklarının mevcut koruma yöntemleri üzerindeki etkileri detaylı bir şekilde analiz edilerek çözüm üretilmesi gerekliliği ortaya çıkmıştır. Literatürde DEÜK'lerin dağıtım şebekesi içerisinde yer almasıyla oluşacak koruma problemlerine yönelik çözüm yöntemleri aşağıdaki gibi listelenmiştir:

- Koordinasyon problemlerine yönelik çözüm yöntemleri
- DEÜK'lerin kısıtlanmasına dayalı çözüm yöntemleri
- Mevcut koruma yapılarına dayalı çözüm yöntemleri
- Adaptif koruma yöntemleri
- Çok etmenli sistemler tabanlı koruma yöntemleri
- Yapay zekâ destekli koruma yöntemleri

1.5.1. Koordinasyon problemlerine yönelik çözüm yöntemleri

Klasik koruma sistemlerindeki amaç; minimum elektrik kesintilerine maruz kalma ile tüketicilere maksimum hizmet sunabilmektir. Koruma sistemlerindeki koordinasyonun sağlanması; arızaya en yakınındaki koruma cihazının arızayı izole etmesi ile gerçekleşmektedir. Aşırı akım rölelerine akım-zaman ayarlaması yapılarak seçicilik gerçekleştirilmekteydi. Ancak DEÜK'ler güç sistemine dahil olması ile seçiciliğin sağlanması imkânsız hale gelmektedir. Örneğin; arızanın olduğu hattın bitişik tarafındaki sağlam hattın güç sisteminden ayrılma ihtimali bulunmaktadır. Diğer bir taraftan ise arızanın şebeke ile DEÜK arasında olması durumunda DEÜK'lerin ayrılma durumunun gerçekleşme olasılığı vardır. Bunlara çözüm olarak rölenin toparlanma akımını değiştirilmesi öngörülmüştür ama bu ise koruma altındaki hattın daha az seçiciliğe sahip olmasına yol açabilmektedir.

Çalışma modu değişikliği hakkında; şebekeye bağlı çalışmanın ada çalışmaya göre koordinasyon aralığının daha yüksek olduğu belirtilmiştir. Arıza akımındaki bu yüksek orandaki değişim koordinasyon problemine neden olacağı belirtilmiştir [53]. Bundan dolayı koruma ayar değerlerinin değişmesi yerine yönlü aşırı akım rölesi kullanımı ile seçiciliğin sağlanabileceği belirtilmiştir [54].

Fazanehrafat ve ark. dağıtım sisteminde DEÜK'leri yerleştirerek koruma aracının (sigorta-kesici) koordinasyon üzerindeki etkisini araştırmıştır. Koruma koordinasyonun sağlanması için eklenen DEÜK'lerin boyutu ve fidere bağlanma yerinin önemi vurgulanmıştır [40].

Haron ve ark. mikroşebekede oluşabilecek arıza durumunda güvenliğin, esnekliğin ve koruma araçları arasında koordinasyonun sağlanmasına yönelik olarak yeni bir koruma yöntemi sunmuştur. Bu yöntemde 3 farklı koruma yöntemi; aşırı akım rölesi, yönlü aşırı akım rölesi ve diferansiyel röle birlikte kullanılmıştır. Yapılan çalışma ile en küçük arızalı bölgenin sistemden ayrılması sağlanmıştır [55].

Naiem ve ark. tarafından koruma koordinasyonunda DEÜK'ün etkilerini araştırmak için yeni bir yöntem geliştirilmiştir. Bu yöntem 2 aşamalıdır. Birinci aşaması; sisteme DEÜK eklenme seviyesi ve arıza yerinin değişmesi ile koruma koordinasyon durumunun değerlendirilmesi; ikinci aşamada ise koruma koordinasyonun iyileştirilmesi: bunun için ise 2 tane yardımcı çözüm bulunmaktadır. Bunlardan birincisi; en iyi DEÜK yerinin tespit edilmesi ve diğeri ise TDS (zaman gecikme ayarı) ile TTK ayarlarının değiştirilmesidir. Önerilen yöntem ile koordinasyon kaybının gerçekleştiği durum için önemli ölçüde iyileştirme yapılmıştır [48].

Chaitusaney ve ark. sigorta-TKK arasındaki koordinasyon eksikliğinden kaynaklı güvenilirlik kaybını ele almıştır. Koordinasyon sorununu çözmek için DEÜK üretim kapasitesine ait eşik değerinin belirlenmesi için bir araştırma yapılmıştır [56].

Martinez ve ark. dağıtım şebekesinde DEÜK'ün etkilerini araştırmıştır. DEÜK'ten dolayı sigortadan geçen arıza akımı artarken şebeke akımında azalma meydana geldiği ve sonuç olarak sigorta ile TTK arasında koordinasyon kaybı olduğu belirtilmiştir. Bu sorunun çözümü sigortanın akım zaman eğrisinin değiştirilmesi ile gerçekleştirilmiştir. TTK üzerinden geçen akımın azalması ile seçicilik kaybına sebep olmuştur. Bu duruma çözüm olması için yeni akım-zaman eğrisi seçilmesi ya da küçük DEÜK'leri sisteme bağlamakla çözümleneceği belirtilmiştir. DEÜK'ten dolayı arızalı hatta bitişik olan diğer hattın koruma cihazında istenmeyen açma olayının gerçekleşebileceğinden bahsedilmiştir. Bu sorunun çözümü ise arıza olmayan hatta koruma cihazı olarak yönlü aşırı akım rölesinin kullanılabilmesi belirtilmiştir [57].

Adel ve ark. DEÜK'lere sahip radyal dağıtım sistemlerinde uygun sigortalar-tekrar kapamalı kesici (TKK) koordinasyonunu sağlamak için uyarlamalı dijital röleye dayalı

bir koruma yöntemi uygulamıştır. DEÜK varlığındaki dağıtım şebekesinde kalıcı olmayan arızalarda gerçekleşen koordinasyon kaybı yani sigortanın TKK'dan önce çalışma durumuna çözüm olması için TKK ve sigortaya ait arıza akımlarının değerine bağlı olarak TDS değeri değiştirilerek TKK'nın sigortadan önce çalışması sağlanmıştır. Böylece sigorta-TKK arasındaki koordinasyonun sağlandığı tespit edilmiştir [58].

Viawan ve ark. yüksek oranda DEÜK'ün dağıtım sistemine katılması ile koruma koordinasyonundaki etkilerini görmüş ve bu etkileri azaltmak için 3 aşamadan oluşan koruma yapısı tasarlamıştır. Bu çalışmada arızanın olduğu hatta DEÜK sistemden ayrılır. Böylece ilgili hatta bulunan AAR koruma aracının çalışmasına sebep olacak akım akmaya başlar. Arızanın olmadığı hatta bulunan DEÜK'lerin oluşturduğu yüksek arıza akımı, ilgili hatta bulunan koruma aracının çalışmasına neden olabilir. Bu önerilen yapı ile koordinasyon kaybının önüne geçilmiştir [59].

Shah ve ark. koordinasyon kaybı sorununu çözmek için TKK ve sigorta üzerinden geçen akımların oranına bağlı olarak zaman skala ayarı değiştirilmesi ile yeni bir adaptif röle tasarlamıştır. Böylece TKK-sigorta arasındaki eksen ayarlanmış ve OTKK eğrisi kaydırılarak koordinasyon sağlanmıştır [60].

1.5.2. DEÜK'lerin kısıtlanmasına dayalı çözüm yöntemleri

Bu bölüm iki kısımdan oluşmaktadır. Bunlardan birincisi arıza sırasında DEÜK'lerin sistemden ayrılması diğeri ise arıza akım kısıtlayıcısının kullanılmasıdır.

IEEE 1547 standartlarına göre gerilim ve frekansta bozucu bir durum olması durumunda belirli bir zamandan sonra güç sisteminden DEÜK'lerin ayrılmasını öngörmektedir. Bu şekilde DEÜK'lerin ayrılması ile güç sistemi tekrar radyal yapıya dönüşümü sağlanarak sistemin onarılması sağlanacaktır. Bu yöntemin en önemli sonuçlarından biri arıza esnasında arıza akımına DEÜK'lerin katkı yapmasını önlemektir. Bununla ilgili olarak yapılan bir çalışmada; arıza gerçekleşmesi durumunda mevcut radyal dağıtım şebeke yapısını bozmadan TKK-sigorta arasındaki koordinasyonu sağlamak amacıyla hızlı güç elektroniği anahtarlama elemanları kullanarak herhangi bir TKK işlem yapmadan önce sistemde yer alan DEÜK'lerin dağıtım şebekesinden ayrılması sağlanmıştır [61]. Bu yöntem uygulanış şekli bakımından basit bir yöntemdir. Mevcut koruma sistemi üzerinde değişiklik yapılmasına gerek kalmaz. Ancak pratikte arıza olması durumunda sistemdeki tüm

DEÜK'lerin ayrılması; ani gerilim düşümü ve kararsızlık gibi problemlere sebep olabilmektedir.

Mikroşebekede her iki çalışma modunda farklı arıza akım seviyelerinin olması, koruma sistemleri için karar vermekte zorlayıcı bir etken oluşturmaktadır. Bundan dolayı, şebeke moddan ada moda geçiş veya tam tersi durumları oluşturan farklı şebeke topolojileri için harici arıza akımı kısıtlayıcı geliştirilmiştir. DEÜK'lerden kaynaklı arıza akımının azaltılmasına yönelik arıza akım kısıtlayıcısı (AAK)'nın kullanılması, mevcut koruma cihazlarında ayarlar değiştirilmeden yapılmaktadır. Böylece koruma cihazları arasındaki koordinasyonun bozulmaması sağlanmış olmaktadır.

Tang ve ark. AAK'nın DEÜK'lerin arıza akımına olan katkısını, geçici durum kararlılığını/sınırlarını ve en son olarak da röle koordinasyon problemi üzerine etkilerini araştırmıştır. Yapılan çalışma ile AAK'nın röle koordinasyonunda iyileştirme yapıldığı belirtilmiştir [62].

El-Khattam ve ark. mevcut güç sistemine DEÜK'lerin eklenmesi ile yönlü aşırı akım rölelerden kaynaklı koordinasyon problemini çözmek için arıza akım kısıtlayıcı yöntemini öne sürmüştür. Bu problemin çözümü; arıza esnasında mevcut röle ayarlarını modifiye etmeden veya DEÜK'leri sistemden ayırmadan gerçekleştirilmiştir. Tasarlanan AAK yöntemi ile arıza esnasında DEÜK'lerin arıza akımına olan katkılarının sınırlandırılması ve yönlü AAR'lere ait koordinasyonlarının sağlanması gerçekleştirilmiştir [63].

Choudhary ve ark. yanlış açma ve kör koruma problemleri gibi koruma koordinasyon sorunlarına çözüm olması için süper yarı iletken akım kısıtlayıcısı ve aşırı akım rölesi ile kullanılarak bir çalışma yapmıştır. Yapılan çalışmanın sonucu anormal durumlardaki arıza akımının azaltıldığı ve AAR'lerin koordinasyonun sağlandığını göstermiştir [64].

1.5.3. Mevcut koruma yapılarına dayalı çözüm yöntemleri

Bu bölümde mevcut koruma yapılarına dayalı çözüm yöntemleri hakkında yapılan literatür çalışmaları ile ilgili bilgiler verilecektir.

1.5.3.1. Gerilim tabanlı koruma rölesi

Bu fikir ilk kez Al-Nassari tarafından atılmıştır. Mikroşebekedeki çıkış gerilimlerini abc/dq dönüşüm yöntemi ile sabit bileşenli eksen takımları elde edilir. Sistemde arıza olması durumunda gerilim sinyalindeki bozucu durum d-q değerleri ile saptanır. Bu şekilde arızanın tespiti gerçekleşir. Akım sinyali yerine gerilim sinyali kullanılması ile arıza akımındaki değişimler önlenmiş olmaktadır [65].

Başka bir çalışmada ise ada çalışma modunda inverter tabanlı DEÜK'lerin oluşturduğu mikroşebekede arızanın tespiti için verilen karar, temel gerilimin pozitif bileşenine dayalıdır. Bu şekilde arıza lokasyonu ve türünü belirlemek için kullanılmaktadır [38].

Al-Nassari tarafından inverter çıkış geriliminin harmonik bilgisi tabanlı bir koruma yöntemi önerilmiştir. İnverter arayüzlü DEÜK'ler, arıza sırasında dağıtım şebekesine harmonik bileşenleri enjekte etme açısından uygun bir kaynak olduğu ve bununla ilgili olarak tasarlanan yöntemle inverter uç gerilimlerine ait THD sürekli izlenir ve arıza sırasında önceden belirlenen değeri aşması durumunda inverterin devre dışı kalması gerçekleşmektedir [66].

Kısa iletim hatların her iki ucunda bulunan röleler arasında küçük gerilim düşümü farklarının olması, gerilim değişiminin azalması nedeniyle yanlış açma sonucu koruma işleyişinde sıkıntılara yol açabildiği belirtilmiştir. Ek olarak bu koruma rölesi hakkında yapılan çalışmalarda park dönüşümlerindeki yüksek hesaplama karmaşıklığı, yüksek empedans arızaları ve yüksek sayıda DEÜK'lerin olma durumları gerilim tabanlı koruma yöntemlerini olumsuz yönde etkilediği bahsedilmiştir [67].

1.5.3.2. Simetrik bileşen tabanlı koruma rölesi

Lassater ve Nikkhajoei tarafından farklı koruma bölgelerinden oluşan mikroşebeke sisteminde faz-toprak ve faz-faz arızaları için simetrik bileşen tabanlı bir koruma yöntemi önerilmiştir. Dengesiz yüklerde negatif ve sıfır akım bileşenleri ortaya çıkması ve bu durumda arıza tespiti diferansiyel koruma yöntemi ile gerçekleştirilmemektedir. Simetrik akım bileşenleri yöntemi ile arızalı durum-dengesiz yüklenme ayrımı tespit edilebilmektedir. Faz-toprak ve faz-faz arızaları için sırasıyla sıfır bileşen ve negatif bileşen özelliklerinden yararlanılmıştır. Bu yöntemle dengesiz yüklenme durumları altında istenmeyen açma emrinin önüne geçilmiştir [68].

Simetrik bileşen tabanlı koruma yöntemi ile ilgili olarak Nikkhajoei ve ark. çalışmalarında haberleşme bağlantısı kullanmamıştır. Ayrıca tek faz toprak ve iki faz arızalarına (TFTA ve FFA) karşı tam koruma sağlamışlar. Ancak, üç fazlı ve yüksek empedanslı arızalar dikkate alınmamıştır.

1.5.3.3. Diferansiyel koruma rölesi

Zeineldin ve ark. inverter tabanlı DEÜK'lerin arıza akımını kısıtlaması ve bunun koruma araçları tarafından tespitinin yapılamaması nedeniyle düşük arıza akımını algılayabilen diferansiyel koruma rölesini önermişlerdir [69].

Conti ve ark. yüksek sayıda inverter arayüzlü DEÜK'lerin olduğu mikroşebekede şebeke yapısının değişmesi ile klasik yöntemlerle arızanın algılanmasının zor olduğunu belirterek mevcut koruma yöntemlerinin yenilikçi koruma yöntemleri ile birleştirilmesini öngörmüşlerdir. Özellikle arıza akımının azaldığı durumlarda arıza tespitinin üstesinden gelmek ve koordinasyon sorunu yaşamamak için diferansiyel koruma yöntemi önerilmiştir. Bu çalışma ile ilgili geleneksel aşırı akım röleleri ve mevcut haberleşme bağlantısı kullanılmasından dolayı ekonomik olduğu, ancak yükler dengesiz olması durumunda önerilen koruma yönteminin etkisiz olduğundan bahsedilmiştir [70].

Sortomme ve ark. haberleşme birimine sahip dijital rölelerin oluşturduğu bir koruma yöntemi sunmuştur. Her bir fiderde ana korumayı sağlayan diferansiyel koruma yöntemi kullanılması ile yüksek empedans arızalarının tespitinde hızlı bir şekilde işlem yapılmasını ve arızanın temizlenmesini sağlamıştır [71].

Dewadasa ve ark. negatif ve sıfır dizisine sahip diferansiyel koruma elemanları, toprak arızalarının korunmasında ve yüksek empedans arızalarında (düşük arıza akımına sahip dengesiz durumlar için) daha hassas olduğu belirtilmiştir. İlgili çalışmada aşırı akım ve düşük gerilim tabanlı koruma araçlarının yedek koruma yöntemi olarak kullanılabileceği söylenmiştir. Sadece AAR kullanılması ile ada durumundaki arıza akımlarını tespit etmek zor olduğundan ve arıza akımının azalması ile sonuçlanan gerilim düşümüne yönelik düşük gerilim tabanlı koruma elemanın kullanılması gerekliliğinden bahsedilmiştir. Ayrıca diferansiyel rölenin ana korumayı sağlamak için haberleşme birimine ihtiyaç olduğu hem şebeke hem de ada modunda çalışabildiği ve röle ayarları değişmeden arızaların tespit edildiğinden bahsedilmiştir [72].

Diferansiyel korumanın devre topolojisi ve işlevi bakımından aşırı akım rölesi ve mesafe rölesine göre en uygun tercih olacağı belirtilmiştir [53].

Kar ve ark. mikroşebekeler için veri madenciliği modeline dayalı bir diferansiyel koruma şeması sunmuştur. Arızalı ve arızasız olaylar arasında sınıflandırma yapmak için kural tabanlı karar ağacı ve farklı diferansiyel özellikler kullanılmıştır. Özellik seti; verici ve alıcı uç arasındaki gerilim, frekans, faz açısı, aktif güç, reaktif güç, gerilim ve akıma ait negatif bileşen değerlerine ait değişim oranındaki farklarından oluşturulmuştur [73].

Gashteroodkhani ve ark. tarafından derin inanç ağları (Deep Belief Network - DBN) tabanlı akım diferansiyel koruma şeması önerilmiştir. Clark ve zaman-zaman (Time Time - TT) dönüşümü, arızalı fiderin her iki ucundan elde edilen mevcut dalga formlarından özellik çıkarımı için kullanılmıştır. Diferansiyel özellikleri, üretken bir Boltzmann makine tabanlı DBN'yi eğitmek ve test etmek için kullanılmıştır [74].

Bu koruma yöntemi ile ilgili dezavantajlar; haberleşme biriminin yetersiz/başarısız kalması, ölçümlerin senkronize olmaması, DEÜK'lerin bağlanma/ayrılması ve dengesiz yüklenmelerin olmasıdır. Diferansiyel parametreler örnekleme farkına çok duyarlı olduğu ve bu nedenle; veri senkronizasyon uyumsuzluğu durumunda arızayı ayırt etme performansının büyük ölçüde etkilendiği bildirilmiştir [67, 75].

1.5.3.4. Mesafe koruma rölesi

Dewasada ve ark. tarafından hem şebeke hem de ada çalışma modları için etkin şekilde arıza tespitinde kullanılabilen bir koruma yöntemi sunulmuştur. Özellikle eviricilerin arıza akımını kısıtlamaları sonucunda oluşan koruma sorununu admittans rölelerin kullanılması ile giderilmiştir. Bu işlem gerçekleştirilirken hattın admittansına bağlı olarak ters zaman karakteristiği işlemi gerçekleştirilmiştir [76].

Uthitsunthom ve ark. tarafından yapılan çalışmada şöyle bir sonuca varılmıştır: birden fazla dağıtık üretim kaynağının bulunduğu güç sisteminde mesafe rölesi; diğer koruma cihazlarının ayarlarına ait hesap karmaşıklığını giderdiği belirtilmiştir [77].

Huang ve ark. tarafından önerilen koruma yapısı; empedans ölçümüne dayalı olarak iki farklı koruma yönteminin birleşiminden oluşmaktadır. İlk koruma yönteminde anlık olarak senkronize edilmiş bilgiler yardımı ile arızanın gerçekleşmesinin tespiti sağlanırken ikinci koruma yönteminde kullanılan ters zaman karakteristik ile

koordinasyon sağlanmıştır. Bu çalışmada dikkat çeken özellik; DEÜK'ün kapasitesinden, türünden ve çalışma modlarından bağımsız olmasıdır [78].

Mesafe rölesinin ana avantajı; ada moda geçilmesi durumunda arıza akımından etkilenmediği vurgulanmıştır. Sakıncaları ise arıza empedansından dolayı ölçülen empedans değerinde hata olması durumunda iç beslenmeden dolayı korunabilecek mesafenin azalması ve açma zamanının olması gerekenden uzun sürede olması, harmonik ve transientlerden kaynaklı hatalar olmasıdır. Arıza noktası ile ölçüm noktası arasında yer alan DEÜK'lerin bulunması; doğru ölçüm alınmamasına neden olabildiği ve bu ise performansı etkileyebileceği bildirilmiştir. Kısa hat uzunluğa sahip dağıtım şebekelerine uygulandığında empedans değerleri, arızanın tespit edilmesinde zorluk çıkardığı ileri sürülmüştür [67, 75].

1.5.3.5. Aşırı akım koruma rölesi

YG tarafında gerçekleşen arızalarda rölelerin ana bölgedeki arızayı tespit edemediği belirtilmiştir. Bunun için yönlü aşırı akım rölelerin kullanımı önerilmiştir [53].

Bin ve ark. optik Ethernet aracılığı sayesinde trafo merkezindeki ölçüm araçları ile mikroşebeke elemanları arasında koruma ve kontrol biriminden oluşan yeni bir yapı sunmuştur. Tasarlanan yapı aldığı kararlara bağlı olarak hesaplama ve analiz gerçekleştirilir ve daha sonra yapılması istenen işlemler için Ethernet aracılığı ile ilgili devre kesici ve kontrol birimlerine gönderilir [79].

Zamani ve ark. mikroişlemci tabanlı rölelerden oluşan şebeke ve ada modlarında çalışabilen bir koruma yöntemi geliştirmiştir. Bu yöntemi üstün kılan özellikler; haberleşmeye ve adaptif koruma araçlarına ihtiyaç duyulmamasıdır. Daha da dikkat çekici olan bir özellik ise; önerilen yöntem arıza akım değerinden, çalışma modundan ve DEÜK türünden bağımsız olmasıdır [80].

Oureilidis ve ark. simetrik ve asimetrik hat arızaları için arızanın tespiti ve temizlenmesi ile ilgili olarak yeni bir kontrol yöntemi sunmuştur. Bu çalışmada dikkat çeken özellikler; herhangi bir haberleşme kanalının ve arıza tespitinde doğrudan empedans ölçümünün kullanılmamasıdır. Arıza noktasına en yakın olan kısmen daha fazla akım enjekte ederek koruma cihazları arasında seçicilik sağlanmış olmaktadır [81].

Genel olarak aşırı akım röleleri uygun maliyetli olabildiği ancak koordinasyondan kaynaklı sıkıntı ve bunu halletmek için haberleşme birimine ihtiyaç duyulduğu bu ise

güvenilirlik problemine neden olabileceği belirtilmiştir. Çift yönlü güç akışı ve düşük arızanın olduğu durumların gözlemlenebildiği ve bu durum aşırı akım rölelerini etkisiz hale getirebileceği bahsedilmiştir [67, 75].

1.5.4. Adaptif koruma yöntemleri

Dağıtık üretim kaynaklarının güç sisteminde ve farklı şebeke topolojilerinin olması durumlarında koruma sistemlerinin yenilenmesi ve çok fonksiyonlu olması gerekliliği belirtilmiştir. Çok fonksiyonlu özellik ile her ne zaman şebeke yapısında ya da çalışma modunda değişiklik olması durumlarında otomatik olarak koruma ayarlarını değiştirebilme sağlanmaktadır [42]. Bunu yapabilmek için güvenilir haberleşme birimine ve hızlı veri sağlama sistemine ihtiyaç duyulmaktadır. Veri işleme ünitesi rölenin yeni ayar değerlerini hesaplayarak kontrol birimine gönderir.

Ada çalışma modunda bozucu bir durumdan kaynaklı ortaya çıkan farklı seviyelerdeki arıza akımının ciddi gerilim düşümlerine sebep olduğu ve bunun sonucunda farklı arıza akım değerlerine yönelik farklı açma ayarları modifiye edilerek kullanılmaktadır [82].

Ada çalışma modunda arıza olması durumunda ciddi gerilim sıkıntısı oluşmaktadır. Bu durumda arıza tespiti sadece gerilim ölçümü ile yapılamamaktadır. Buna çözüm olması için Tumilty ve ekibi gerilim kısıtlı aşırı akım koruma tekniğini önermiştir. Kısa devre olduğunda gerilimdeki azalma çok ciddi olduğu için daha düşük akım değerine sahip eşik değeri seçimi ile yapılmaktadır. Bu ise akım zaman eğrisinin aşağıya doğru kaymasına ve böylece açma zamanının azalmasına sebep olacaktır. Aşırı yüklenme durumlarında gerilim düşümü az olduğu için açma zamanı daha uzun olacaktır [83].

Bhrama ve ark. tarafından dağıtım şebekesinde yüksek oranda DEÜK olması durumunda klasik tekrar kapamalı kesici ile sağlanamayan koordinasyon problemine çözüm olması için mikroişlemci-tabanlı tekrar kapamalı kesici tasarımı önerilmiştir. Koordinasyon sağlanması için DEÜK sayılarının çeşitlilik durumu göz önüne alınarak farklı TKK eğrilerinin kullanıcı tarafından önceden hazır olması gerekliliğine ve farklı çalışma durumları için uygun eğrinin seçilmesi ile koordinasyon sağlanabileceği söylenmiştir. Kısacası kullanıcıya mevcut çalışma durumuna göre istediği çalışma eğrisini seçme hakkı verilmektedir. Önerilen mikro işlemci tabanlı röle; çok fonksiyonlu, esnek ve çalışma koşullarına bağlı olarak adaptif özelliklere sahiptir [49].

Bhrama ve ark. tarafından dağıtım sistemine yüksek oranda DEÜK olması durumunda koruma koordinasyonunda DEÜK etkileri araştırılmıştır. Veri toplama sisteminden gelen şebeke bilgileri merkezi bilgisayarda depolanır, işlemden geçirilir ve sistemdeki haberleşme birimine sahip olan ilgili koruma araçlarına emir gönderilir. Devre kesicileri ve TKK'lar haberleşme birimleri ile donatılmıştır ve bunlar merkezi bilgisayar ile çevrimiçi izlenebilmektedir. Arıza tespiti, Thevenin eşdeğer devresi hesaplanarak gerçekleştirilmektedir. Şebekede bulunan her bir kaynak gerilim kaynağı ve ona seri bir Thevenin empedansından oluşmaktadır. Sistem, bölgelere kesici ile ayrılmıştır. Önerilen koruma yapısı; arızanın tespit edilmesi, ilgili arıza bölgenin tanımlaması ve ilgili bölge ve DEÜK'leri ayırmak için kesicilere sinyal gönderilmesi ve sonunda sistemin onarılmasından oluşmaktadır [84].

Oudalov ve ark. adaptif koruma yapısını; koruma ayarlarının mikroşebeke çalışma durumuna göre mikroşebeke merkezi denetleyicisi tarafından periyodik olarak güncellendiği ve önceden hesaplanmış bilgilere sahip merkezi bir mimariye dayandığından bahsetmiştir. Dijital röle ve gelişmiş iletişim altyapısı kullanan yeni bir adaptif mikroşebeke koruma sistemi önerilmiştir. [85].

Han ve ark. tarafından gerçek zamanlı olarak arıza gerilim ve akım bileşenlerini kullanarak sistemin ve mikroşebekenin empedansını hesaplama tabanlı otomatik şekilde çalışan anlık AAR tasarlanmıştır. Ana şebeke ile mikroşebeke empedanslarını karşılaştırarak röle çalışma eğrileri güncellenmiştir [86].

Schaefer ve ark. gerçek zamanlı klasik koruma sistemi ve gerçek zamanlı olmayan adaptif koruma sisteminden oluşan bir koruma algoritması tasarlamıştır. Gerçek zamanlı koruma ünitesi, gerçek zamanlı olarak şebeke bilgisini izler ve açma sinyali gerekiyorsa işlem yapar. Gerçek zamanlı olmayan koruma ünitesi ise rölelerin açma eğrilerinin seçiciliğini sağlamak için tahmini bilgi kullanır. Her bir şebeke durumu için dağıtık enerji yönetim sistemi, rölelerin açma eğrini tahmin eder ve gerekli bilgiyi röleye gönderir. Eğer röleye gönderilen bilgi belirlenen sınırlar içerisinde değilse dağıtık enerji yöntemi tarafından reddedilir. Bu koruma rölesi ile ilgili çıkarımlar; sigortaların mikroişlemci tabanlı röleler ile değiştirilmeye ihtiyaç duyması, uzun mesafeler arasında yüksek hızda bilgi alışverişini sağlayacak haberleşme birimine ihtiyaç olması ve haberleşme biriminin maliyet açısından yüksek olmasıdır [87].

Ustun ve ark. adaptif koruma yöntemini, merkezi koruma birimi ile şebeke yapısını denetleyerek bilgileri güncelleme işlemini sürdürülmesini kapsamlı haberleşme yapısı ile gerçekleştirmiştir. DEÜK'lerin bağlanma ya da ayrılma durumlarına karşılık rölelerin açma zaman eğrileri oluşturulur. Röle ve DEÜK'ler, merkezi işlemci birimi (Central Processing Unit - CPU)'ne haberleşme birimi ile birbirine bağlanmıştır. DEÜK'lerin yeni durumlarına bağlı olarak CPU, röle zaman eğrisini günceller. Bu tasarımda her bir DEÜK ve röle, CPU'ya bağlanmak için kapsamlı haberleşme birimine ihtiyaç duyar. Sistem yapısında değişiklik olma durumunda yeni açma karakteristiklerinin hesaplanması için CPU-işlemci arasında hızlı bilgi alışverişi olması gerekliliği bildirilmiştir [88].

Dang ve ark. tarafından her iki çalışma modunda çalışabilecek mikroşebekeler için sıfır bileşen tabanlı adaptif koruma yöntemi sunulmuştur. Koruma yöntemi 3 adımda incelenmiş: çalışma modu tespiti, arıza tespiti ve koruma koordinasyonu. Sıkıntılar: röle hassasiyet sorunu (sıfır bileşen akımı için doğru eşik değerinin seçimi) ve çalışma hızının düşük olmasıdır [34].

Khederzadeh ve ark. adaptif bir koruma yöntemi sunmuştur. Önerilen yöntemde her iki çalışma modu için çevrim dışı hesaplama yapılır ve rölelere koruma ayarları yüklenir. Ada çalışma modunda bir arıza olması durumunda röle ayarları otomatik olarak yeni röle değerine kaydırılır. Bu yöntem ile karmaşıklık olmadan AAR'ler aracılığıyla düşük arıza akım seviyesi tespiti sağlanmış olmaktadır [89].

Turan ve ark. aşırı akım ve kısa devre durumları için akıllı şebeke koruma yöntemlerini sunmuştur. Bu yapılan çalışma kapsamında jeneratör, rüzgâr türbini ve yüklerin bulunduğu akıllı şebeke tabanlı ring dağıtım şebekesi kullanılmıştır. Akıllı şebeke koruma yöntemi iki durumu incelemektedir: birincisi; uzun süreli aşırı akım durumunda kesicileri açarak tüketicilerin başka hattan beslenmesi ve ikincisi; kısa süreli aşırı akım durumu için için tüketicileri aynı hattan beslenmeye devam edilmesidir. Koruyucu rölelerden gelen kesme sinyali tüm sistemi devre dışı bırakmadan ilgili kesicilere gönderilmiştir. Güç sisteminin röle kontrol sistemi; merkezi kontrol yöntemi ile izlenmektedir. Merkezi kontrolör ile DEÜK'lerin gerilim seviyelerinin kontrolü de yapılmaktadır [90].

Ustun ve ark. DEÜK'lerin etkisini ve IEC61850 ve IEC61850-7-420 iletişim standartlarında sağlanan mantıksal düğümlerle mikroşebekenin işletilmesi farklı

çalışma modlarını dikkate alarak bir koruma sistemini sunmuştur. Ağın tüm parametrelerini izlemek için bir mikroşebeke merkezi koruma birimi kullanılmıştır. Ağ yapılanmasındaki her bir değişiklik, DEÜK'lerin bağlantısı ya da ayrılması durumları ve çalışma modlarındaki her bir değişiklik için röle ayarları güncellenmiştir. Rölelerin çalışma akım seviyeleri, şebekenin arıza akımı katkısı, her DEÜK'ün arıza akımı katkısı, mikroşebeke çalışma durumu (şebekeye bağlı veya şebekeden ayrı olma durumu), DEÜK'ün bağlantısı veya bağlantısının kesilmesi durumu ve DEÜK'lerden röle noktasına olan mesafe gibi faktörlere göre hesaplanmıştır [91].

Sortomme ve ark. tarafından haberleşme destekli anlık akım diferansiyel şeması ana koruma olarak kullanılmıştır. Kesici arızası durumunda yedekleme için uygun rölelere iletilmiştir. Haberleşme hattı arızası durumunda ise haberleşme altyapısı yeniden sağlanana kadar tüm röleler karşılaştırmalı gerilim koruması ile çalıştırılmıştır. Ancak, anlık diferansiyel şema daha büyük mikroşebekelere uygulandığında gerekli olan şarj akımı ve veri senkronizasyon hatasının etkileri yeterince ele alınmadığı belirtilmiştir. Ayrıca, haberleşme bağlantısı arızası sırasında, mikroşebekeler için güvenilir bir şema olmayan yalnızca karşılaştırmalı gerilim koruması önerilmiştir [71].

Brearley ve Prabu tarafından yapılan çalışmada merkezi koruma yapısı tanıtılmıştır. Dört koruma bölgesinden oluşan merkezi koruma ünitesinde gerilim-frekans rölesi (ortak bağlantı noktasına (OBN) yerleştirilmiş), yönlü aşırı akım rölesi (fiderde), sigortalı aşırı akım rölesi ve yönsüz aşırı akım rölesi diğeri ise gerilim-frekans rölesi bulunmaktadır. Bu çalışmada şu sonuca varılmıştır: diferansiyel korumanın ana koruma görevini sağlaması ve aşırı akım rölesi de bu ilgili bölgede yedek koruma sağlaması ileri sürülmüştür. Yüklerdeki korumayı sağlamak adına ters zamanlı aşırı akım rölesinin en uygun koruma aracı olduğu ileri sürülmüştür. Rölenin ayar değerlerinde çalışmasını sağlaması için DEÜK ve kesicide yaşanan dinamik değişimleri dikkate alabilmesi ve bunun yanında herhangi bir çalışma durumunda koruma görevini yapabilmesi için mikroşebekeye ait en iyi koruma yönteminin adaptif koruma olduğu ileri sürülmüştür. Ancak bu adaptif koruma yöntemi kendi bünyesinde dijital röle ve sensör içermesinden dolayı maliyetinin artması ancak yine de uzun dönemli olarak düşünüldüğünde geleceğe yönelik iyi bir tercih olabileceği belirtilmiştir [92].

Etkili bir adaptif koruma şeması için haberleşme bağlantısının güvenilirliği kritik bir öneme sahip olduğu belirtilmiştir. Haberleşme bağlantı arızaları, siber güvenlik

sorunları ve yüksek maliyetler ekonomik adaptif koruma yapılarının uygulanmasında büyük sıkıntı çıkardığı vurgulanmıştır [45].

1.5.5. Çok etmenli sistemler tabanlı koruma yöntemleri

Perera ve ark. çok etmenli sistemler tabanlı koruma yöntemini önermiştir. Bu sistem dağıtım şebekesini farklı bölgelere ayırarak ve haberleşme kanalları ile ayrılan bölgeler için bilgi alışverişi yapılmasını sağlamıştır. Bu etmenler stratejik olarak çeşitli bölgelere yerleştirilmiştir. Bunlar lokal akım ölçümlerini kullanır. Akım sinyalleri dalgacık dönüşüm işleminden geçirilir ve arıza tespit edilir. Tüm etmenler arıza lokasyonu algoritması ile yerleştirilmiş ve bu algoritma ile arızalı bölgenin temizlendiği belirtilmiştir [93].

Wan ve ark. aşırı akım rölelerin optimal koordinasyonunun sağlanmasına yönelik çok etmenli koordinasyon yaklaşımını önermiştir. Ancak bu çalışmada önerilen yöntemle ilgili olarak çıkarılan sonuç; koruma koordinasyonu için ihtiyaç duyulan bilgi haberleşme sistemleri sayesinde sağlanmaktadır. Her röle, DEÜK, akım trafosu ve kesici, ayrı bir etmen olarak alınmıştır. Ayrıca, etmenleri temsil etme adına, röle etmeni, DEÜK etmeni ve ekipman etmeni olmak üzere üç etmen topluluğuna ayrılmıştır. Röle etmenleri, optimum koordinasyon için aynı toplumdaki diğer aktarma etmenleri ve ayrıca diğer toplumlardan temsilciler ile iletişim kurabilmektedir. Her röle etmeni, tüm koordinasyon stratejisine dahil edilmiştir [94].

Liu ve ark. çok etmenli sistemler tabanlı koruma sistemleri ile merkezi işlem birimi tabanlı sistemleri karşılaştırma yapmıştır. Bu çalışmada rölelerden merkezi bilgisayara kadar daha geniş iletişim altyapısının gerekli olduğu merkezi işlem birimi tabanlı şemaların aksine, çok etmen tabanlı koruma şemalarının çalışması etmenler arasındaki bilgi alışverişine dayandığı belirtilmiştir [95].

Dizi bileşenleri ve Stockwell dönüşümü kullanan çok etmenli sistemler tabanlı bir koruma şeması Maali Amiri ve Vahidi tarafından önerilmiştir. Normal radyal dağıtım sistemlerinde kullanılan geleneksel aşırı akım koruma yöntemlerinin aksine, önerilen yöntem kısa devre seviyesine veya arıza akımının genliğine bağlı değildir. Bu yöntemde, oldukça kabul edilebilir bir zaman aralığında arızalı bölgeyi tanıyabildiği ve açma sinyallerini ilgili devre kesicilere gönderebildiği belirtilmiştir. Önerilen algoritmanın ilkeleri, kısa devre arızaları sırasında ve sonrasında daha iyi performans için IEC 61850 protokollerine dayalı olarak sunulmuştur. Bu çalışmadan

çıkarılabilecek sonuç; Stockwell (S) dönüşümünün hesaplama karmaşıklığı, etmen tabanlı bir koruma şeması için çok yüksek olmasıdır [96].

Razavi ve ark. tarafından dağıtık adaptif koruma yapılarının merkezi adaptif koruma yapılarına olan üstünlüğü hakkında çevrimiçi şekilde çalışabilen çok etmenli sistemler tabanlı yöntemler; mikroşebeke topolojisindeki değişikliklere karşılık vermek için çevrimiçi olarak farklı stratejiler kullandığını ve bu yöntemin mikroşebekeleri korumak için sağlam bir koruma plan olduğu belirtilmiştir. Bununla birlikte, çevrimiçi çok etmenli sistemler tabanlı koruma yöntemlerinin performansını etkileyen değişkenler; koruma sistemindeki ve iletişim bağlantılarındaki belirsizlikler olarak belirtilmiştir [97].

Çok etmenli sistemler, mikroşebekedeki yapısal değişikliklere yüksek esneklik ve güvenilirlikle yanıt verebilen tek yöntem olarak ortaya çıkmıştır. Bu yöntemde, tüm ağ değişikliklerini çevrimiçi olarak analiz etmek ve mikroşebeke topolojisine göre en iyi koruma stratejisine karar vermek için uygun iletişim bağlantılarının kullanılabileninden bahsedilmiştir [97].

Çok etmenli koruma yöntemlerindeki temel zorluk, etmenlerin ve iletişim bağlantılarının doğru çalışma olasılığının belirsiz olmasıdır. Arızalarda koruma sisteminin çalışması sırasında söz konusu sistemle ilgili belirsizliklerin oluşması muhtemeldir. Böylece istenmeyen kesintilere yol açarlar ve sistemin güvenilirliğini azaltırlar. Öte yandan, haberleşme bağlantılarına dayalı çok etmenli sistemler tabanlı koruma yapısının güvenli çalışması; haberleşme bağlantılarının hızından, gecikme süresinden ve güvenilirliğinden etkilendiği belirtilmiştir [97].

1.5.6. Yapay zekâ destekli koruma yöntemleri

Tuitemwonga ve ark. dağıtım şebekesinde DEÜK'leri yerleştirmek ve dolayısıyla koordinasyonu sağlamak için bilgi ve çıkarım tabanlı uzman sistem kullanmıştır. Bu yöntem ile sistemde herhangi bir sıkıntı olması durumunda gereken değişiklikleri yaparak kullanıcıya kolaylık sağladığı ileri sürülmüştür [98].

Rezaeia ve ark. çeşitli arızalar konusunda arızalı hattı belirlemek için üç aşamalı radyal tabanlı sinir ağı yöntemi geliştirmiştir. Bu yöntemin ilk aşamasında her bir üretim kaynağından arıza noktasına kadar olan uzaklığı belirlenmesidir. İkinci aşamada arızalı hatların, son aşamada ilgili kesicilerin belirlenmesine çalışılır [99].

Zayandehroodi ve ark. yüksek güç seviyesinde DEÜK'e sahip dağıtım sisteminde koruma koordinasyon sorunu ile ilgili yeni adaptif bir yöntem ileri sürmüştür. Arıza yerinin doğru şekilde tespit edilmesi ve bununla birlikte arızalı bölgeye ait olan ana ve yedek rölelerin tanımlanması sağlanmıştır. Bunun için sinir ağı tabanlı iki algoritma geliştirilmiştir. Farklı arıza yerleri için test edilen sistemde herhangi bir koruma koordinasyon problemi yaşanmamıştır. Böylece geliştirilen yöntemin güvenilirliği gösterilmiştir [100].

Jin ve ark. tarafından gelişmiş dalgacık teorisine dayalı adaptif mesafe koruma algoritması tasarlanmıştır. Tasarlanan koruma algoritması iki kısımdan oluşmaktadır. İlk aşama gelişmiş dalgacık teorisi yardımıyla arızanın tespit edilmesidir. Ada çalışma modunda arıza akımının azalması ve akım genliği kullanılarak arızanın tespit edilmesinin zor olmasından dolayı sabit zaman pencere özelliğine sahip fourier analizinin yerine değişken zaman penceresine sahip olma özelliği ile gelişmiş dalgacık teorisi kullanılmıştır. Bu şekilde frekans sapması daha hassas olacak şekilde arıza tespiti sağlanmıştır. İkinci kısımda ise arı kolonisi optimizasyonu ile mesafe koruma ve AAR arasındaki koordinasyonun sağlanması gerçekleştirilmiştir [101].

Abdulwahid ve Wang tarafından bulanık mantık modeli kullanılarak Hilbert uzay tabanlı güç teoremleri diferansiyel koruma yöntemi geliştirilmiştir. Algoritmanın avantajı: arıza gerçekleşmesi durumunda iki periyottan kısa bir süre içerisinde koruma sisteminin çalışmasıdır. Diğer bir avantajı ise arıza tespiti eşik değerlerinin seçimine bağlı olmamasıdır. Eğer veri değerleri akım trafosu tarafından bozulmaya uğramışsa bile istenmeyen yanlış açmalar önlenmiştir. Önerilen yapı; iki aşamadan oluşmaktadır. Birinci aşamada her hattın sonunda anlık reaktif gücün hesaplanmaktadır. İkinci aşamada ise arızalanan bölgeler arasını tespit etmek için bulanık mantık kuralları işlenmektedir. Sonuç olarak röle açma komutunu verir. Arızalanan fazın güç seviyesi arızalanmadan öncekine göre güç değeri olarak düşük olduğu için arızalanan fazlar çok açık bir şekilde belirlenmiştir [102].

Mishra ve ark. tarafından lokal akım ölçümlerini kullanarak dalgacık dönüşümü ve rasgele orman tabanlı sınıflandırıcı yöntemlerinden yararlanan bir mikro şebeke koruma şeması sunmuştur. Ayrık dalgacık dönüşümü kullanılarak mevcut dalga formunun ayrıştırılmasını ve seviye-3 katsayılarından farklı özellikler üretilmesini içermektedir. Arıza tespiti için 9 özellik ve arıza sınıflandırması için 15 özellik kullanılmıştır. Bunların içerisinde ölçülen akım sinyallerinden negatif ve sıfır

bileşenlerin kullanımı ile statik özellikler elde edilmiştir. AG (A-faz toprak), BG (B-faz toprak) ve CG (C-faz toprak) arızalarını bir bütün olarak ele alınmıştır ve bunun gibi diğer arıza çeşitleri iki faz arızaları ve iki faz toprak arızalarını da kapsamıştır. Arıza türlerinin detaylı şekilde sınıflandırılması yapılmamıştır [103].

İletim hattı arızalarını tespit etmek ve sınıflandırmak için faz ölçüm ünitelerinden (phasor measurement units-PMU) üretilen verileri bir toplu özellik girdi veri seti olarak kullanan bir PSO-WELM (Particle Swarm Optimization-Weighted Extreme Learning Machine) sınıflandırıcı modeli tasarlanmış ve geliştirilmiştir. WELM model performansını geliştirmek için optimum katsayılara sahip olması gerekliliğinden dolayı PSO metaheuristik yöntem kullanılmıştır. Arızalı senaryolar oluşturulmasında arıza başlangıç açıları dikkate alınmamıştır. PSO-WELM tabanlı arıza tespit modelinde, arızalar 100 % doğrulukla tespit edilirken, arıza sınıflandırma modelinde 99,85 % doğruluk oranına sahip olduğu belirtilmiştir. Arıza sınıflandırma modelinde tüm arıza tiplerini sınıflandıracak şekilde bir model tasarlanmamıştır. Bunun yerine 4 farklı arıza türü; tek-faz toprak arızası (TFTA), faz-faz arızası (FFA), faz-faz toprak arızası (FFTA) ve faz-faz-faz arızası (FFFA) olarak etiketlenmiştir. Aynı zamanda önerilen sınıflandırma modelinin genelleme kabiliyeti sadece 70-30 oranına sahip eğitim-test seti olarak incelenmiştir [104].

Casagrande ve ark. evirici ağırlıklı bir mikroşebekede arıza olaylarını ayırt etmek için iki klasik istatistiksel sınıflandırıcı, Naive Bayes ve karar ağacı yöntemlerini uygulamıştır. Ancak, bu çalışmanın birincil konsantrasyonu sınıflandırıcı için uygun özelliklerin seçimi üzerinde olduğu görülmüştür. Sarmalayıcı tabanlı yöntem (Wrapper-based) ve filtre tabanlı yöntem olmak üzere iki özellik seçim süreci önerilmiştir. Analiz için alınan özellikler, karelerinin ortalamasının karekökü (RMS) değeri, toplam harmonik bozulma, gerilim ve akım sinyallerinin pozitif, negatif ve sıfır bileşen bileşenleri ve güç faktörü açısidir. Yöntem yalnızca sınıflandırma için daha iyi özellik seçme sürecine dayandığından hem ada hem de şebeke bağlantılı modda çalışan bir mikroşebeke için geçerli olmayabileceği görülmektedir. Ayrıca ağ topolojisine sahip mikroşebekeler için uygun değildir [105].

Casagrande ve ark. tarafından Rastgele orman tabanlı sınıflandırıcı için lokal ve uzak terminallere ait simetrik bileşenler, akım ve gerilim büyüklüğü, faz açısı ve toplam harmonik bozulması gibi diferansiyel özelliklere dayalı bir arıza tespit yaklaşımı önerilmiştir [106].

Hong ve ark. ayrık dalgacık dönüşümü (ADD) ve yapay sinir ağı kullanan mikro şebeke için bir arıza tespiti, sınıflandırması ve arıza lokasyon tespit şemasını önermiştir. 2. ve 3. ayrıştırma seviyesine ait gerilim, faz akımı ve nötr akım dalga formlarının dalgacık dönüşümünün farklı entropi tabanlı özellikleri, sinir ağını eğitmek ve gereken veri seti sayısını azaltması için Taguchi yöntemiyle birlikte kullanılmıştır. Ancak şema, yalnızca mikroşebeke ile elektrik şebekesi arasında yer alan ortak bağlantı noktasındaki (OBN) statik anahtarlara uygulanmıştır [107].

Manohar ve ark. tarafından arıza tespiti, sınıflandırma ve arızalı bölge tanımlanması için optimal rasgele ormana dayalı bir parçacık sürüsü optimizasyonu tabanlı sınıflandırıcı kullanılmıştır. Sınıflandırma için ayarlanan özellik, güneş ışınımı ve rüzgâr hızı seviyelerindeki geniş varyasyonlar altında arıza gerilimi ve akım sinyallerinin ayrıntılı DWT katsayılarının standart sapmalarını içermektedir [108].

Mishra ve Rout, radyal ve örgü yapıları içeren mikroşebekelerde simetrik, asimetrik ve yüksek empedans arızalarını tespit etmek ve sınıflandırmak için üç fazlı akım sinyallerini kullanan Hilbert Huang Transform (HHT) tabanlı makine öğrenme modelini sunmuştur. İlk olarak HHT tabanlı özellik seti oluşturulur ve ardından özellik seti, naive Bayes, SVM ve extreme learning machine (ELM) gibi makine öğrenmesi yöntemlerine girdi olarak sunulur. Çalışmada gürültülü veri örnekleri dikkate alınmamıştır [109].

Bukhari ve ark. akım sinyallerini kullanarak evrişimli sinir ağı tabanlı akıllı arıza koruma şeması önermiştir. Önerdikleri yöntemin etkinliği, güvenliği ve güvenilirliği kanıtlanmıştır. İlgili çalışmada gürültülü örneklerin dikkate alınmadığı, ayrıca özellik çıkarımının sağlanamadığı belirtilebilir [110].

Mishra ve ark. radyal ve ağ yapılı mikroşebekeler için sınıflandırıcı olarak aşırı öğrenme makinası (Extreme learning machine - ELM) yöntemini önermiştir. İlgili çalışmada, özellik çıkarımı için matematiksel morfoloji (MM) kullanılmıştır. MM-ELM'nin sınıflandırma performansı MM-SVM ve MM-YSA öğrenme modellerine göre daha yüksek olduğu görülmüştür. Önerdikleri yöntemde, gürültü örnekler altında test edilmiş ve hedef arızalı fiderin her iki ucundan bir periyot boyutunda üç fazlı akım sinyallerinden yararlanılmıştır [111].

Abdelgayed ve ark. arıza sınıflandırması için karar ağacı (DT) ve en yakın komşular (KNN) yöntemlerinin hem akım hem de gerilim sinyalleri ile eğitimini kullanan yarı

denetimli bir makine öğrenimi (SSML) modelini sunmuştur. Çalışmada ölçüm hatası değerlendirilmiştir [112].

Gush ve ark. ayırık ortonormal Stockwell dönüşümü tabanlı optimize edilmiş çok çekirdekli aşırı öğrenme makinesini (MKELM) kullanan akıllı bir arıza sınıflandırması ve arıza lokasyonu belirleme şeması sunmuştur [113].

Baloch ve ark. lojistik regresyon ve AdaBoost makine öğrenimi yöntemlerini içeren veri madenciliğine dayalı bir arıza tespit ve sınıflandırma şemasını sunmuştur. Önerdikleri yöntemin geçerliliği gürültülü örneklerle test edilmiştir [114].

Pan ve ark. mikroşebekeler için evrişimli sinir ağı (CNN) modeli tabanlı arıza sınıflandırma yöntemini önermiştir. IEEE 13 baralı modelin modifiye edilmiş bir mikroşebeke modelini kullanılmıştır. Bu çalışmada sadece 70-30 oranında eğitim-test seti bölünmesi yapılmıştır. Önerilen sınıflandırma modeli farklı oranlarda eğitim/test setlerine yönelik öğrenme yeteneği sorgulanmamıştır. Ek olarak arızalı senaryolar oluşturulmasında dağıtık üretim kaynağının çıkış gücü seviyesinin değişimi ve sınıflandırmada arızalı olmayan senaryolar dikkate alınmamıştır. Diğer çalışmalarda olduğu gibi klasik makine öğrenme modellerinin öğrenme hatalarını telafi edecek ve genelleme/öğrenme kabiliyetlerini geliştirecek bir model sunulmamıştır [115].

Yapay zekâ tabanlı koruma yapısında; fazla uydurma eğilimi ve daha fazla hesaplama yükü gibi dezavantajlarına sahip olduğu belirtilmiştir. Bu tür algoritmaların gerçek zamanlı performansı, eğitim veri setinin çeşitliliğine ve eğitim için kullanılan özelliklerin türü gibi faktörlere bağlıdır. Özellik seti ile hedef seti (arıza var veya arıza yok) arasında herhangi bir katı mantıksal veya matematiksel ilişki olmayan bu tür tamamen veri odaklı koruma şemalarının dezavantajı; önerilen sınıflandırma şemaların mevcut veri setlerindeki hedef çıktılarının tamamının öğrenilmesini beklemek imkânsız gibi görülmektedir [75].

1.6. Tezin Amacı

Literatür çalışmasında çok sayıda koruma yöntemleri sunulmuş olup bunlarla ilgili avantajlar ve dezavantajlar vurgulanmıştır. Bu tez kapsamında DEÜK'lerden oluşan güç dağıtım sistemlerine yönelik koruma yöntemlerinden yapay zekâ destekli koruma yöntemi uygun bulunmuştur. Bu koruma yöntemlerinde sorun; veri setlerindeki çeşitlilik olmasına rağmen belirli makine öğrenme modelinin öğrenme kabiliyetindeki

sınırlılıktan dolayı sınırlı bir genelleme kapasitesine sahip olmasıdır ve bu durum sınıflandırıcıların tahmin edebilme gücünün zayıflığını göstermektedir. Bu soruna çözüm olması için farklı öğrenme modellerine sahip sınıflandırıcıları birleştirmenin yani bir topluluk modeli oluşturmanın bu sınıflandırıcılara göre daha az hataya sahip olabileceği öngörülmektedir.

Literatürde yer alan topluluk öğrenme modellerinden biri olan oylama modelleri ile ilgili olarak ağırlıklı oylama modelinde sınıflara ait olasılıksal katkılar ve performans sonuçları dikkate alınmamıştır. Diğer yandan ağırlıksız oylama modellerinden biri olan olasılıksal tabanlı oylama yönteminde sınıflandırıcıların eğitim aşamasına dair başarı ölçütleri ağırlık katsayısı olarak dikkate alınmamıştır.

Bu tez çalışmasında, olasılıksal tabanlı oylama yöntemlerinden biri olan olasılıkların toplamı oylama modeline ağırlık katsayılarının entegre edilmesi ve bu ağırlıkların ağırlık matrisinden seçilmesine dayalı olarak olasılıksal ağırlıklı oylama modeli (OAOM) tabanlı arıza tespit ve sınıflandırma şeması (ATSS) sunulmuştur. Bu tez çalışması ile diğer oylama modellerinin zayıf yönleri ele alınarak önerilen oylama modeli (OAOM) ile arıza tespiti ve sınıflandırma performansının geliştirilmesi hedeflenerek literatüre katkı sağlanmıştır.

Çalışmanın amacı doğrultusunda hedeflenen unsurlar şunlardır:

- Arıza tespit ve sınıflandırmasına yönelik önerilen OAOM'nin ve bu modeli oluşturan temel sınıflandırıcıların 11 sınıfa (10 arıza durumu ve arızasız durum) sahip hem gürültüsüz hem de gürültülü veri setlerini kullanarak diğer oylama modellerini de ele alan kapsamlı bir karşılaştırmalı performans analizinin gerçekleştirilmesi
- Önerilen OAOM'nin tahmin edebilme gücünü ya da genelleme kabiliyetini doğrulamak için eğitim-test veri setlerinin 70-30, 60-40 ve 50-50 gibi farklı oranlarda kullanılması
- Farklı sayılardaki temel sınıflandırıcılardan oluşturulmuş OAOM yapılarının doğruluk ölçütü açısından performans verimliliklerinin araştırılması
- Ayırıştırma seviyesi 9 (11th ve 13th harmonik bileşenleri) ve ayırıştırma seviyesi 10 (5th, 7th ve 9th harmonik bileşenleri) için ayrı ayrı yeni bir özellik seti oluşturularak önerilen OAOM'nin performans analizinin gerçekleştirilmesi

- Oylama modellerinden elde edilen performans sonuçlarının diđer oylama modellerine karşı üstünlüğünün gösterilmesi amacıyla Friedman ve Finner post hoc testi ile istatistiksel analiz yöntemi uygulanması hedeflenmiştir. Ayrıca önerilen yöntemi, uluslararası platformlarda kabul edilmiş farklı karakteristiğe sahip veri setleri üzerinde kullanılarak doğruluğunun test edilmesi

2. ARIZA TESPİT VE SINIFLANDIRMASINA YÖNELİK SİNYAL İŞLEME TEKNİKLERİ VE ÖZELLİK ÇIKARIMI

Dağıtık enerji üretim kaynaklarından oluşan bir güç sisteminde kısa devre arızası ya da geçici durum olayı ile karşılaşılması durumunda güç sisteminin sürdürülebilirliğinin aksamasına ve dolayısıyla güvenlik, güvenilirlik ve güç kalitesi gereksinimlerinin karşılanamamasına yol açabilmektedir. Bu nedenle güç sisteminin kararlı bir şekilde çalışması ve tüketicilerin uzun süre elektrik kesintilerine maruz kalmaması için arızanın doğru bir şekilde tespit edilmesi ve sınıflandırılması gerekmektedir. Arıza tespiti ve sınıflandırılması için arıza sinyallerinin yorumlanabilmesi gerekmektedir. Bu sebeple sinyal karakteristik özelliklerinin çıkarılması amacıyla çeşitli sinyal işleme yöntemleri kullanılır. Bu yöntemler ile ilgili detaylı bilgiler alt bölümlerde sunulacaktır.

2.1. Fourier Dönüşümü

Fourier dönüşümü (FD), zaman domenindeki sinyalleri frekans bileşenlerine dönüştürebilen en yaygın yöntemdir. Zamanla değişen frekans veya durağan olmayan sinyaller için yetersiz kalmaktadır [116]. Sinyal bozulmaları veya arıza olaylarının zamanlaması hakkında bilgi vermez ve geçici anlık bilgi elde etmek için yetersizdir [117].

$$X(\omega) = \int_{-\infty}^{+\infty} x(t)e^{-j\omega t} dt \quad (2.1)$$

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} X(\omega)e^{j\omega t} d\omega \quad (2.2)$$

Denklem 2.1 ve 2.2 ile verilen Fourier dönüşümünde, bir periyot boyunca sinüs ve kosinüs fonksiyonlarının ortogonal özellikleri kullanılır [118].

2.2. Kısa Zamanlı Fourier Dönüşümü

Fourier dönüşümünde zamanlama bilgisine ait problemin çözümü için kısa zamanlı fourier dönüşümü (KZFD) ele alınmıştır. Kısa zamanlı Fourier dönüşümü, denklem 2.3'te görüldüğü gibi bir sinyalin başından sonuna kadar sabit büyüklükteki bir pencere fonksiyonun kaydırılması yoluyla her pencere boyutunda Fourier dönüşümü uygulanmasıdır. Ancak KZFD'de pencere boyutunun sabit olması nedeniyle zaman-frekans düzleminde istenilen çözünürlük elde edilememektedir. Bu bağlamda KZFD çoklu çözünürlük analizinde çalışmamaktadır. Sürekli $x(t)$ sinyalinin Kısa Zamanlı Fourier Dönüşümü (KZFD), pencereli sinyalin Fourier Dönüşümü (FD) olarak görülebilir [119, 120].

$$X(\omega, \tau) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\omega t} \quad (2.3)$$

2.3. Dalgacık Dönüşümü

FD ve STFT sinyal işleme yöntemlerinin kısıtlamalarına bağlı olarak sinyal özelliklerini iki boyutta analiz etmek için önemli bir matematiksel araç olan Dalgacık Dönüşümü (Wavelet Transform-WT), ölçeklenebilir ve kaydırılabilir bir şekilde tüm sinyal boyunca uygulanarak ortaya çıkmıştır [119, 121]. Dalgacıklar, her iki uçta da sıfıra düşen kısa süreli genliğin salınımlı dönüşümleridir. Genişleme, ana dalgacığın zaman içinde gerilmesini ve sıkıştırılmasını içerir. Böylece durağan olmayan sinyallerde bozunum ve geçici olaylarla ilgili zaman ve frekans çözünürlüğü elde edilebilecektir [122].

Dalgacık analizinin integral kısmı ana dalgacıktır. Ana dalgacık, fourier dönüşümünde kullanılan sinüzoidal fonksiyonlara eşdeğerdir. Bununla birlikte keskin bir uca ve değişken bir şekle sahip olması bakımından sinüzoidal dalgalardan önemli ölçüde farklıdır. Ana dalgacık seçimi; Haar, Daubechies, Coiflet, Morlet, vb. gibi mevcut ana dalgacık ailelerinden gerçekleştirilir [123]. Dar pencere kullanılması durumunda analiz edilen sinyalin yüksek frekans bileşenleri, geniş pencere kullanılması durumunda analiz edilen sinyalin düşük frekans bileşenleri elde edilir. Başka bir deyişle, düşük frekans bant aralığında kötü zaman konumu ve iyi frekans çözünürlüğü sağlanırken, yüksek frekans bant aralığında doğru zaman lokasyonu ve düşük frekans

çözünürlüğü sağlanır. Yüksek ölçekte daha genel bir yaklaşım elde edilirken, düşük ölçekte ise daha detaylı bir yaklaşım yapılır [124, 125].

Dalgacık dönüşümü, sürekli dalgacık dönüşümü (SDD) ve ayrık dalgacık dönüşümü (ADD) olarak ikiye ayrılır [126]. SDD, ölçek ve ötelemenin sürekli olarak değişimi olarak açıklanabilir. Analiz edilecek sonlu enerjiye sahip bir sinyalin SDD'si (2.4);

$$SDD_x(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt = \langle x(t), \psi_{a,b}(t) \rangle \quad (2.4)$$

burada a , b ve $\frac{1}{\sqrt{a}}$ sırasıyla ölçek, öteleme ve normalleştirme parametresini göstermektedir.

SDD ile ölçek ve konumdaki değişime göre dalgacık katsayıları şeklinde büyük miktarda veri üretilir. Bu işlem büyük bir hesaplama yüküne yol açar ve bu yükün üstesinden gelmek için ADD kullanılır. SDD'nin alt örneklerini temel alan ADD, analizi çok daha verimli hale getirmektedir, uygulanması kolaydır ve hızlı hesaplama süresine sahiptir. Aynı zamanda ADD ile orijinal sinyal, hiçbir veri kaybı olmaksızın kendi katsayı bileşenlerinden tamamen geri kazanılabilir. Bu nedenle SDD'deki hesaplama fazlalığı ve pratik uygulamaların çoğu ayrık tabanlı örnekler olmasından dolayı ADD, SDD'den daha çok tercih edilir [122].

Denklem 2.4'te $a = 2^j$ ve $b = k2^j$ yazılırsa denklem 2.5'te görüldüğü üzere ayrık dalgacık dönüşümüne ait formülasyon elde edilir:

$$ADD_x(j, k) = \left(\frac{1}{\sqrt{2^j}} \right) \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t}{2^j} - k \right) dt = \langle x(t), \psi_{j,k}(t) \rangle \quad (2.5)$$

burada \langle, \rangle iç çarpımı temsil etmektedir.

j . seviyedeki yaklaşıklık ve detay katsayıları (a_k^j , ve d_k^j), $(j-1)$. seviyedeki yaklaşıklık katsayıları kullanılarak elde edilebilir.

$$a_k^j = \sum_n a_n^{j-1} h(n - 2k) \quad (2.6)$$

$$d_k^j = \sum_n a_n^{j-1} g(n - 2k) \quad (2.7)$$

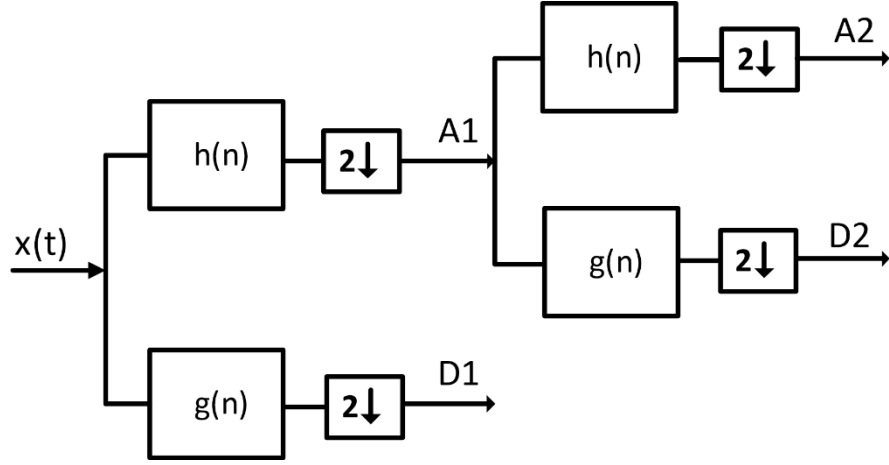
burada denklem 2.6 ve 2.7' de yer alan $h(n)$ ve $g(n)$; alçak ve yüksek geçiren filtre bankalarını, ayrıca j . seviyesindeki yaklaşıklık ve detay katsayılarını gösterir.

$$V_{j-1} = V_j \oplus W_j \quad (2.8)$$


Denklem 2.8'de V_j ve W_j , j . çözünürlük seviyesindeki ölçekleme ($\varphi_{j,k}(t)$) ve dalgacık ($\psi_{j,k}(t)$) fonksiyonlarının içerdiği alt uzayları temsil etmektedir. Dalgacık dönüşümünün $V_j \perp W_j$ olan ortogonal özelliği nedeniyle, W_j , V_j 'nin tümleyenidir. Denklem 2.8, V_j ve W_j alt uzaylarına sahip V_{j-1} , V_j ve W_j 'nin direkt toplamını göstermektedir.

j . seviyedeki dalgacık dönüşümünün çoklu çözünürlük analizi (ÇÇA) farklı seviyelerdeki frekansların çözümlenmesini veya birleştirilmesini sağlar. ÇÇA ile esasen 1 boyutlu sinyali, 2 boyutlu zaman ve ölçek boyutuna eşleştirme sağlanmaktadır [127]. Şekil 2.1'de görüldüğü üzere, $x(t)$ sinyali ayrık dalgacık dönüşümüne maruz kalmaktadır. Seviye 1 de gerekli filtreleme (alçak geçiren filtre ve yüksek geçiren filtre) ve örnekleme işleminden sonra $A1$ ve $D1$ yaklaşıklık ve detay katsayıları elde edilmiştir ve sinyal hakkında daha genel bir inceleme yapılmasına olanak sağlar. Daha sonra tekrar ayrıştırma seviyesinin artması durumunda sinyal hakkında daha detaylı bir inceleme yapılması anlamına gelir. Ayrıştırma seviyesinin yüksek olması durumunda sinyaldeki dinamik değişiklikler hakkında bilgi sahibi olunurken dalgacık seviyesinin düşük olması durumunda sinyal hakkında genel bilgi verilmektedir. Farklı seviyelerdeki detay katsayıları ve nihai yaklaşıklık katsayıları için çeşitli frekans aralığını kapsayan üç seviyeli ayrıştırma diyagramı Şekil 2.2'de gösterilmiştir. Çoklu çözünürlük analizinin arka planında iki temel işlev yer almaktadır: filtreleme (çözünürlük) ve örnekleme (bilginin yarısının atılma durumu). Sinyaldeki detay bilgisinin miktarı sinyalin çözünürlüğü ile ifade edilir bu ise filtreleme işlemleriyle değiştirilir. Ölçek ise yukarı ve aşağı örnekleme işlemleriyle değiştirilir [124].

Bir sinyalin alt örnekleme hızının düşürülmesi veya sinyaldeki gereksiz bazı örneklerin çıkarılması şekilde iki yolla gerçekleştirilir. Öte yandan, bir sinyalin üst örnekleme hızını, sinyale yeni örnekler eklenilerek sinyalin örnekleme hızını artırılmasına karşılık gelir. Yukarıdaki bilgiler ışığında çoklu çözünürlük analizi şu şekilde gerçekleştirilmektedir:



Şekil 2.1. Çoklu çözünürlük analiz görünümü [128]

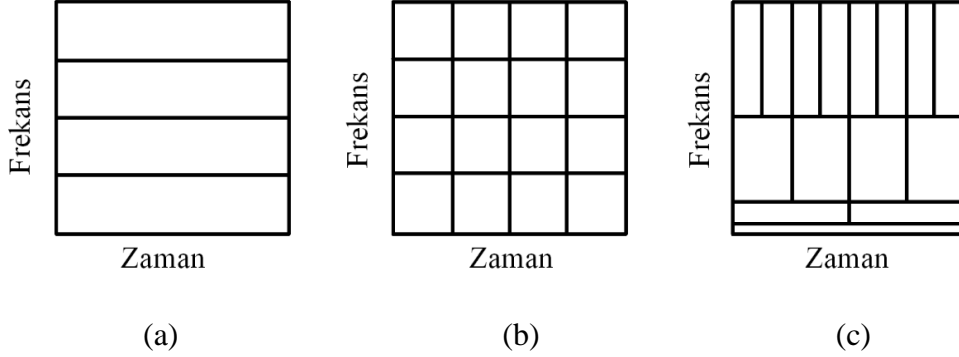


Şekil 2.2. Farklı ayrıştırma seviyeleri için detay ve nihai yaklaşıklık katsayılarının seviyelerini gösteren frekans aralıkları [129]

analiz edilecek sinyali yarım bant alçak geçiren filtreden geçirildikten sonra, örneklerin yarısı Nyquist kuralına göre elimine edilir. Bu durumda sinyalin ölçeği iki katına çıkmıştır. Alçak geçiren filtreleme ile sinyaldeki yüksek frekanslı bilgiler kaldırılmaktadır fakat ölçek değiştirilmemektedir. Yalnızca alt örnekleme işlemi ölçeği değiştirmektedir. Çözünürlük ise sinyaldeki bilgi miktarı ile ilgilidir ve bu nedenle filtreleme işlemlerinden etkilenir. Bu nedenle, filtreleme işleminden sonra çözünürlük yarıya düşmektedir. Bununla birlikte, filtreleme işleminden sonraki alt örnekleme işlemi çözünürlüğü etkilememektedir, çünkü sinyalden spektral bileşenlerin yarısının çıkarılması, örnek sayısının yarısında gereksiz bilginin var olduğu ile açıklanır. Örnek sayısının yarıya düşürülme işleminin örnekleme ile ilişkili olduğu aynı zamanda çözünürlüğü etkilemediği diğer yandan filtreleme işlemlerinin çözünürlüğü etkilediği belirtilmiştir [126]. Bu durum, dalgacık dönüşümünü diğer sinyal işleme tekniklerinden ayıran önemli bir özelliktir.

Denklem 2.9, $x(t)$ sinyalinin ilgili dalgacık ayrıştırma seviyesindeki yaklaşıklık ve detay katsayılarından oluştuğunu göstermektedir.

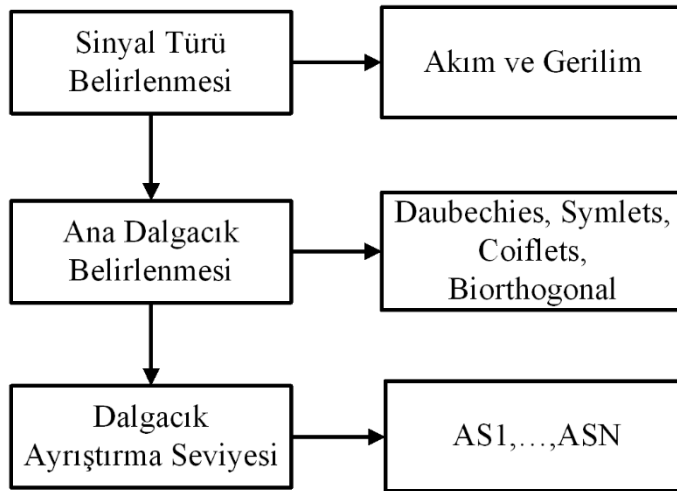
$$x(t) = \sum_{k=1}^J a_{J,k} \left(\frac{1}{\sqrt{2^J}} \right) \varphi \left(\frac{t}{2^J} - k \right) + \sum_{j=1}^J \sum_{k=1}^J d_{j,k} \left(\frac{1}{\sqrt{2^j}} \right) \psi \left(\frac{t}{2^j} - k \right) \quad (2.9)$$



Şekil 2.3. a) Fourier dönüşümü b) Kısa zamanlı fourier dönüşümü c) Dalgacık dönüşümü [130].

Yukarıda açıklanan sinyal işleme teknikleri (Fourier dönüşümü, kısa zamanlı fourier dönüşümü ve dalgacık dönüşümü) arasındaki karşılaştırmayı göstermek için temsili bir gösterim Şekil 2.3'te sunulmuştur.

Şekil 2.3'te, fourier dönüşümünde zaman bilgisi hakkında net bilgi sahibi olunamadığı, kısa süreli Fourier dönüşümünde, klasik fourier dönüşümüne ait sorunları kısmen çözdüğü fakat sabit boyutlu pencereden dolayı zaman-frekans çözünürlüğünde istenilen performans analizinin sağlanamadığı görülmektedir. Dalgacık dönüşümünde ise değişken boyutlu bir pencere kullanılmasından dolayı iyi bir zaman ve frekans çözünürlüğü sağladığı görülmektedir.



Şekil 2.4. Ayrık dalgacık dönüşümünün işleyişi.

Bir dizi zaman sinyaline ayrık dalgacık dönüşümü uygulanmadan önce uygun ana dalgacık fonksiyonu belirlenmeli ve daha sonra kullanılmak istenilen özelliklerin ilgili bozucu olayı diğerlerinden ayırmada kolaylık sağlayacak frekans aralığını yansıtabilmesi için en uygun dalgacık ayrıştırma seviyesi seçilmelidir.


Şekil 2.4'te görüldüğü gibi dalgacık analizi için ilk olarak kullanılacak sinyal türü (akım sinyali, gerilim sinyali ya da akım-gerilim sinyalleri) belirlenmelidir. Bu işlemten sonra ilgili geçici karakteristiğe en uygun tanımlayabilecek ana dalgacık tipi seçilmelidir. Örneğin; Daubechies (db) ana dalgacık ailesinden olan db4 ve db10 fonksiyonları için alçak geçiren ve yüksek geçiren filtre banka dağılımları şekiller (2.5, 2.6, 2.7 ve 2.8)'de gösterilmiştir. En son olarak da ayrıştırma seviyesi belirlenmelidir.

Arıza tespiti ve sınıflandırmasına yönelik özellik çıkartımında kullanılmak üzere ana dalgacık ailesi ve ayrıştırma seviyesi seçimleriyle ilgili literatürde yer alan araştırma sonuçları aşağıda belirtilmiştir:


Pan ve ark. özellik çıkarımında akım sinyallerinden yararlanarak iki seviyeli ayrıştırma ve yeniden birleştirme aşamalarına sahip Daubechies 5 (db5) ana dalgacık fonksiyonunu kullanmıştır. Çalışmalarındaki ana dalgacık seçimi, oldukça iyi konumlandırılmış bir dizi dalgacık sağladığı ve bu dalgacık tipinin seçilmesi ile mikroşebekede meydana gelen herhangi bir arıza tipine referans gösterimi sağlayabileceği belirtilmiştir [115].

Dehghani ve ark. dağıtık üretim kaynaklarından oluşan bir dağıtım sisteminde tek faz toprak, iki faz arızaları, iki faz toprak arızaları ve üç faz toprak arızalarının tespit ve sınıflandırması için üç fazlı akım sinyallerinin pozitif bileşeni ve daha sonra bu bileşenden yararlanarak Haar ana dalgacık fonksiyonunu kullanarak detay katsayılarını elde etmiştir. Bu katsayıları tekil değer ayrışımı (Singular Value Decomposition-SVD) yöntemi kullanılarak dalgacık tekil entropi değerlerinin hesaplanması ve sonuç olarak bulanık mantık algoritmasının girişinin beslenmesi sağlanmıştır. Bulanık mantık algoritması ile arıza tespit ve sınıflandırılması gerçekleştirilmiştir [131].


Sewilam tez çalışmasında, her sinyaldeki (akım ya da gerilim) her ayrıştırma seviyesi için uygun ana dalgacık fonksiyonunu aramak ya da dalgacık ailelerinin arama uzayını keşfetmek için evrimsel bir optimizasyon tekniği olarak harmoni araştırma algoritmasını (Harmony Search Algorithm - HSA) kullanmıştır [130].




Şekil 2.5. db4 alçak geçiren filtre katsayılarının dağılımı.



Şekil 2.6. db4 yüksek geçiren filtre katsayılarının dağılımı.



Şekil 2.7. db10 alçak geçiren filtre katsayılarının dağılımı.



Şekil 2.8. db10 yüksek geçiren filtre katsayılarının dağılımı.

Mishra ve ark. mikroşebeke test sisteminde arıza tespit ve sınıflandırması için db1 (Haar) ana dalgacık fonksiyonu ve 7th, 11th ve 13th harmonik bileşenleri barındıran ayrıştırma seviyesi, özellik çıkarımında kullanmıştır [103].

Li ve ark., db10 ana dalgacık fonksiyonu ile ilgili olarak daha yüksek mertebeli ana dalgacık ailesinin frekans tepkisi incelendiğinde, örtüşen bölgede çarpıcı bir azalma

ve daha keskin kesme frekansı sergilediğini belirtmiştir. Ayrışma sonrası minimum kaçak enerji nedeniyle daha fazla enerji biriktirilmesi sağlanmıştır. db10 dalgacık fonksiyonu ile oluşan özellik vektörü, düşük dereceli diğer db dalgacık fonksiyonlarından daha belirgin hale geldiği belirtilmiştir [132].

Ayrıca Shariatinasab ve ark. db10 ana dalgacık fonksiyonu kullanımı ile ilgili yavaş geçici sinyallerin analizi için uygun olduğunu da belirtmiştir.

Yukarıdaki çalışmalara dayanarak bu tez kapsamında ADD dönüşümünde kullanmak üzere ana dalgacık olarak Daubechies ailesinden db10 dalgacık fonksiyonu seçilmesine karar verilmiştir.

IEEE 1547 standardında DEÜK'lerin dağıtım şebekesine entegrasyonunda güç kalitesi açısından belirli kriterlere sahip olması için şebekeye enjekte edilen akıma ait toplam harmonik distorsiyonun 5 % den küçük olması gerekliliği baz alınarak örnekleme frekansı 500 kHz olarak belirlenmiştir [32].

Thirumala ve ark. harmonik bileşenlerin etkileri ile ilgili olarak arızalı sinyaller üzerinde tek numaralı harmonik bileşenlerin çift numaralı harmonik bileşenlerden daha baskın olduğunu belirtmiştir [133].

Yukarıda belirtilen çalışmalar ve dalgacık katsayılarının dağılımları dikkate alındığında; bu tez kapsamında ayırık dalgacık dönüşümünde kullanılan ayrıştırma seviyeleri aşağıdaki gibi seçilmiştir:

Daubechies dalgacık ailesinden db10 ana dalgacık fonksiyonu ve db10' ile ilgili olarak 11th ve 13th harmonik bileşenleri içermesinden dolayı 9. ayrıştırma seviyesi, diğer yandan 5th, 7th ve 9th harmonik bileşenleri içermesinden dolayı 10. ayrıştırma seviyesi seçimleri gerçekleştirilmiştir.

2.4. Özellik Setinin Elde Edilmesi

Sinyaldeki ani değişimleri tespit edebilmek için verilerin yapısal olarak detaylı şekilde yorumlanması gerekmektedir. Bu bağlamda, özellik çıkarımı, sinyalin özünü temsil eden yararlı bilgileri çıkarmak için daha anlaşılır ve basitleştirilmiş olmalıdır.

Yalnızca saf akım veya gerilim sinyallerinin kullanılması sinyalin karmaşıklığı hakkında bilgi vermez. Bu çalışmada, anlamlı özellikler elde etmek için ADD aracılığıyla ayrıştırılan detay katsayıları kullanılmıştır. Belirli bir veri seti için,

kullanılan ayırt edici özellikler, eşitlikler 2.10, 2.11, 2.12, 2.13, 2.14, 2.15 ve 2.16 kullanılarak hesaplanır:

$$X = \{x_1, x_2, \dots, x_k\} \quad (2.10)$$

$$Y = \{y_1, y_2, \dots, y_k\} \quad (2.11)$$

$$F_{iz} = \begin{cases} z = X, & \text{if } j = 9 \\ z = Y, & \text{if } j = 10 \end{cases} \quad (2.12)$$

burada X-Y,z,k ve i, sırasıyla 9-10 seviyeli detay katsayıları, detay katsayılarının genel gösterimi, detay katsayılarının sayısı ve özellik tipidir.

F_{1z} ve F_{2z} , 9. ve 10. ayrıştırma seviyelerine karşılık gelen detay katsayıları için mutlak maksimum ve ortalama değerlerdir. Bu özellikler, ilgili arıza durumlarını ayırt etmek için kullanılır (2.13-2.14).

$$F_{1z} = \max\{|z_1|, |z_2|, \dots, |z_k|\} \quad (2.13)$$

$$F_{2z} = \text{mean}\{|z_1|, |z_2|, \dots, |z_k|\} \quad (2.14)$$

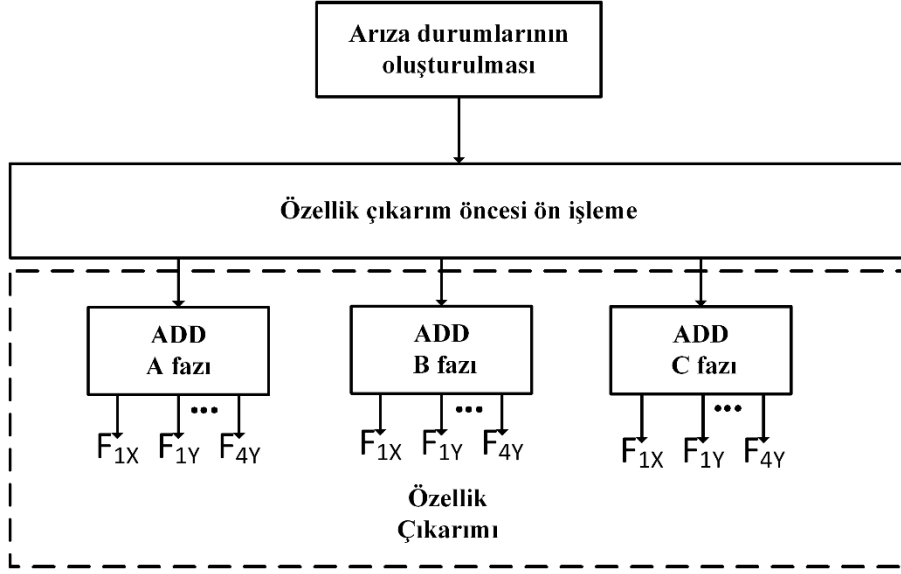
F_{3z} (Shannon entropy (entropi)), sinyal karmaşıklığını ölçmek için ayırt edici bir özelliktir (2.15) [134].

$$F_{3z} = - \sum_{i=1}^k p_i \log(p_i) \quad (2.15)$$

burada p_i , i. katsayının olasılığını belirtir.

Belirli bir özellik vektörü için tanımlanan olasılıkların toplamı bir olmalıdır. Ancak tez çalışmasında entropi hesaplanmasında giriş olarak kullanılan detay katsayıları normalize edilmemiştir. Bundan dolayı entropi değerinin mutlak değerce büyüklüğü 1'den büyük çıkması beklenmektedir.

F_{4z} (Variance (Varyans)), normal çalışma koşullarındaki ani değişimleri ortaya koyan önemli bir özellik, istatistiksel bir terimdir.



Şekil 2.9. Özellik çıkarım aşaması [128].

Varyans, her z_i değişkeni ile ortalama değer $\hat{\mu}$ arasındaki farkın karesinin kümülatif toplamının ortalaması olarak hesaplanır. Varyans, ortalama etrafındaki sapmanın karesel ifadesidir (2.16) [135].

$$F_{4z} = \frac{1}{k-1} \sum_{i=1}^k (z_i - \hat{\mu})^2 \quad (2.16)$$

Özellik çıkarım sürecini gösteren diyagram Şekil 2.9’da gösterilmiştir. Bu süreç ilk olarak arızalı ve arızalı olmayan akım verilerin elde edilmesiyle gerçekleşmektedir. Elde edilen bu verilerde ilgili arıza olaylarını kapsayacak şekilde gruplandırma ve etiketlendirme yapılmaktadır.

Özellik çıkarımı öncesi detay katsayılarını elde etmek için arıza başlangıç anından itibaren ilk çeyrek boyut büyüklüğündeki arızalı / arızalı olmayan veriler hazırlanır. Daha sonra her bir faz için ADD ile ayrıştırma seviyelerine ait elde edilen detay katsayılarına özellik fonksiyonları uygulanır.

Bu tez kapsamında esasında 4 farklı özellik kullanılmıştır. Ancak 2 farklı ayrıştırma seviyesi (her bir faza ait 8 özellik) ve 3 farklı faz olduğu için toplamda 24 özellik çıkarılmıştır.

Özellik setinde yer alan özellikler aşağıda listelenmiştir:

1. Özellik: A fazının seviye 9'a ait detay katsayılarının mutlak maksimum değeri
2. Özellik: A fazının seviye 9'a ait detay katsayılarının mutlak ortalamasının değeri
3. Özellik: A fazının seviye 9'a ait detay katsayılarının entropi değeri
4. Özellik: A fazının seviye 9'a ait detay katsayılarının varyans değeri
5. Özellik: A fazının seviye 10'a ait detay katsayılarının mutlak maksimum değeri
6. Özellik: A fazının seviye 10'a ait detay katsayılarının mutlak ortalamasının değeri
7. Özellik: A fazının seviye 10'a ait detay katsayılarının entropi değeri
8. Özellik: A fazının seviye 10'a ait detay katsayılarının varyans değeri
9. Özellik: B fazının seviye 9'a ait detay katsayılarının mutlak maksimum değeri
10. Özellik: B fazının seviye 9'a ait detay katsayılarının mutlak ortalamasının değeri
11. Özellik: B fazının seviye 9'a ait detay katsayılarının entropi değeri
12. Özellik: B fazının seviye 9'a ait detay katsayılarının varyans değeri
13. Özellik: B fazının seviye 10'a ait detay katsayılarının mutlak maksimum değeri
14. Özellik: B fazının seviye 10'a ait detay katsayılarının mutlak ortalamasının değeri
15. Özellik: B fazının seviye 10'a ait detay katsayılarının entropi değeri
16. Özellik: B fazının seviye 10'a ait detay katsayılarının varyans değeri
17. Özellik: C fazının seviye 9'a ait detay katsayılarının mutlak maksimum değeri
18. Özellik: C fazının seviye 9'a ait detay katsayılarının mutlak ortalamasının değeri
19. Özellik: C fazının seviye 9'a ait detay katsayılarının entropi değeri
20. Özellik: C fazının seviye 9'a ait detay katsayılarının varyans değeri
21. Özellik: C fazının seviye 10'a ait detay katsayılarının mutlak maksimum değeri
22. Özellik: C fazının seviye 10'a ait detay katsayılarının mutlak ortalamasının değeri
23. Özellik: C fazının seviye 10'a ait detay katsayılarının entropi değeri
24. Özellik: C fazının seviye 10'a ait detay katsayılarının varyans değeri

Bu tez kapsamında oluşturulan DEÜK'lerden oluşan güç dağıtım sistem modelinde farklı arıza çeşitleri (tek faz toprak arızaları (TFTA); AG, BG, CG, faz-faz arızaları (FFA); AB, BC, CA, faz-faz toprak arızaları (FFTA); ABG, BCG, CAG, üç faz toprak arızası (FFFTA); ABCG) (Şekil 2.10, Şekil 2.12, Şekil 2.14 ve Şekil 2.16) uygulanmıştır.

Değişik akım karakteristiğine sahip bu arıza türlerini birbirinden ayırt etmek için ADD uygulanarak ilgili arıza türlerine ait karakteristik dağılımları elde edilmiştir. Normal arızalı verileri, gürültü ile katkılanması durumunda normal arızalı verileri ayırt etmede kolaylık sağlaması için 5th, 7th, 9th, 11th ve 13th harmonik bileşenlerini kapsamı açısından 9. ve 10. ayrıştırma seviyeleri seçilmiştir.

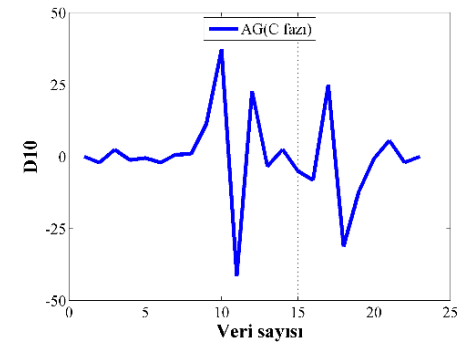

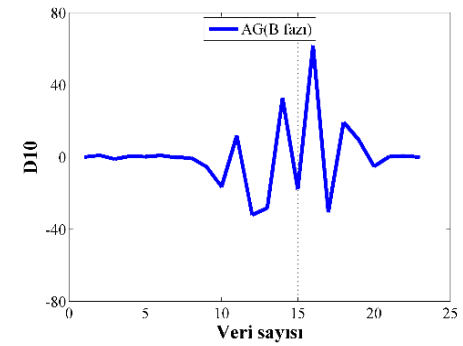

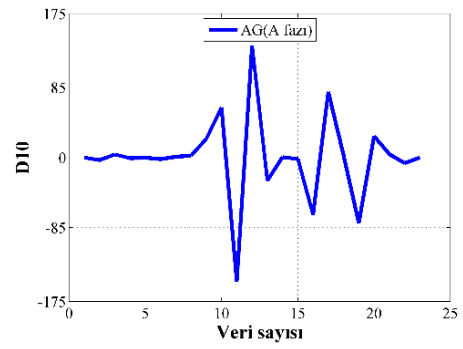

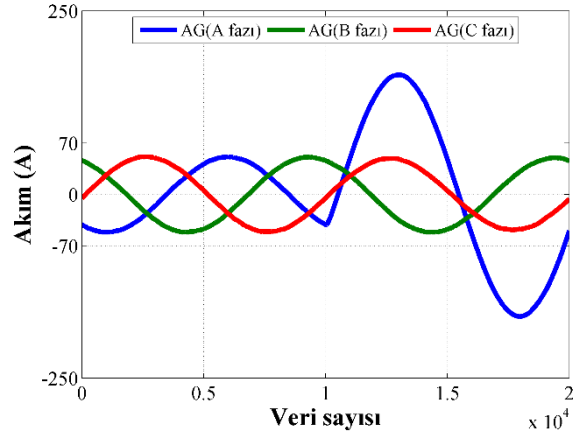
Özellik çıkarım sürecini daha iyi şekilde ifade edebilmek için MATLAB/Simulink ortamından [136] elde edilen arızalı akım sinyalleri, ayrık dalgacık dönüşümünden elde edilen detay katsayılarının dağılımları ve bu dağılımlara uygulanan özellik fonksiyonlarının değişimleri elde edilmiştir.

Şekil 2.10-Şekil 2.11 AG arızası, Şekil 2.12-Şekil 2.13 AB arızası, Şekil 2.14-Şekil 2.15 BCG arızası ve Şekil 2.16-Şekil 2.17 ABCG arızası ile ilgili özellik çıkarım sonuçları sergilenmiştir.

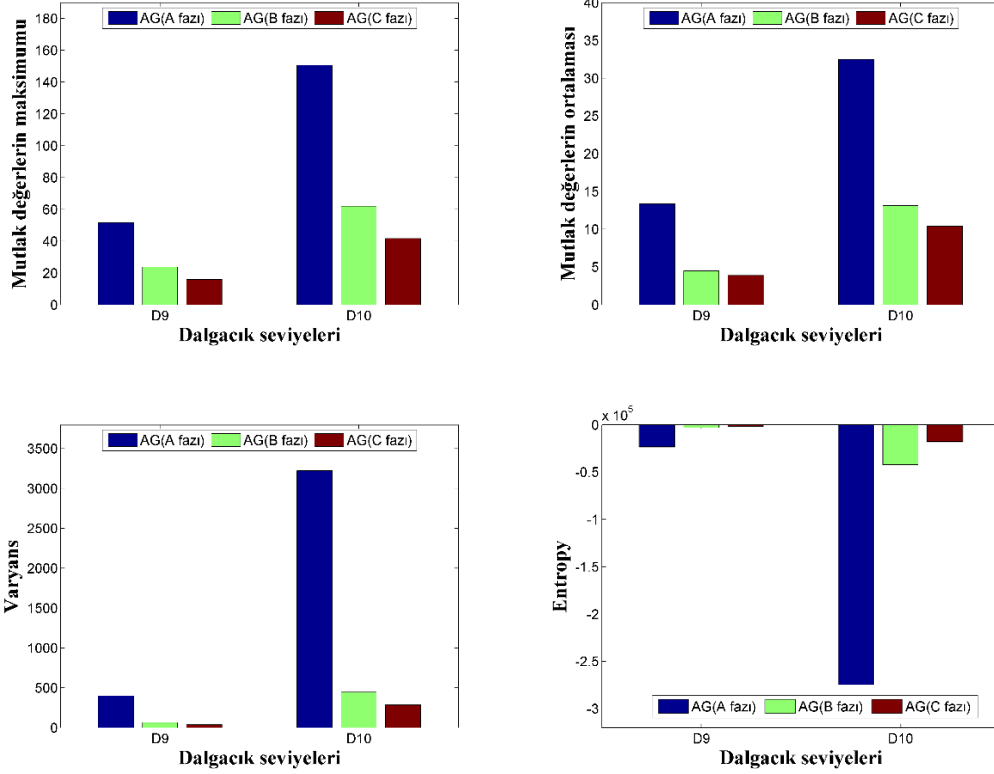
Şekil 2.10'da DEÜK'lerden oluşan güç dağıtım sistem modeline A faz toprak arızası uygulanması durumunda oluşan arızalı akım sinyalleri görülmektedir. ADD uygulanmasından sonra detay katsayılarının değişimi görülmektedir. A fazına ADD uygulaması sonrası 9. ve 10. ayrıştırma seviyelerine ait detay katsayılarının dağılımları B ve C fazındaki dağılımlara göre daha belirgin olduğu gözlenmektedir.

Şekil 2.11'de ise bu elde edilen detay katsayılarının dağılımlarına uygulanan çeşitli özellik fonksiyonlarının ilgili ayrıştırma seviyelerindeki değerleri görülmektedir. Bu arıza tipine ait çıkarılan özellikler ile ilgili çıkarımlar şunlardır:

A fazındaki mutlak değerlerin maksimum ve mutlak değerlerin ortalama karşılıkları diğer fazlardan yüksek olduğu gözlenmektedir.



Şekil 2.10. AG arızasında her bir faza ait 9. ve 10. ayrıştırma seviyeleri için detay katsayılarının dağılımı.


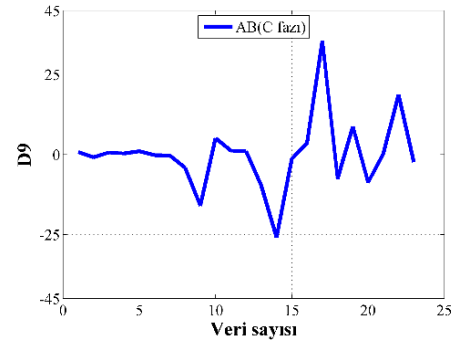



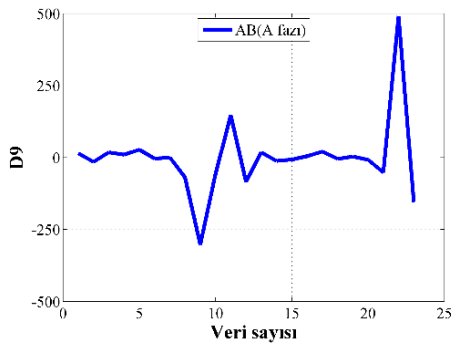
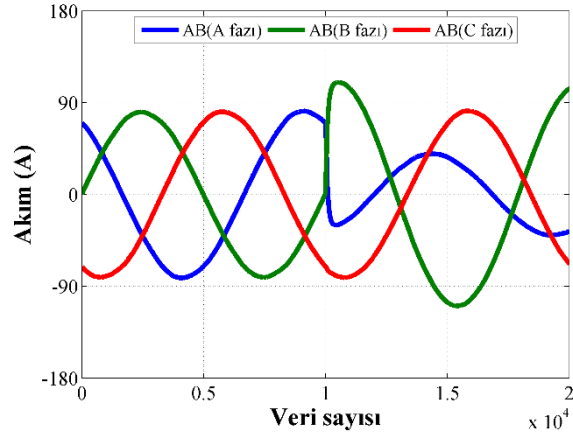


Şekil 2.11. AG arızası için her bir faza ait özelliklerin dağılımı.

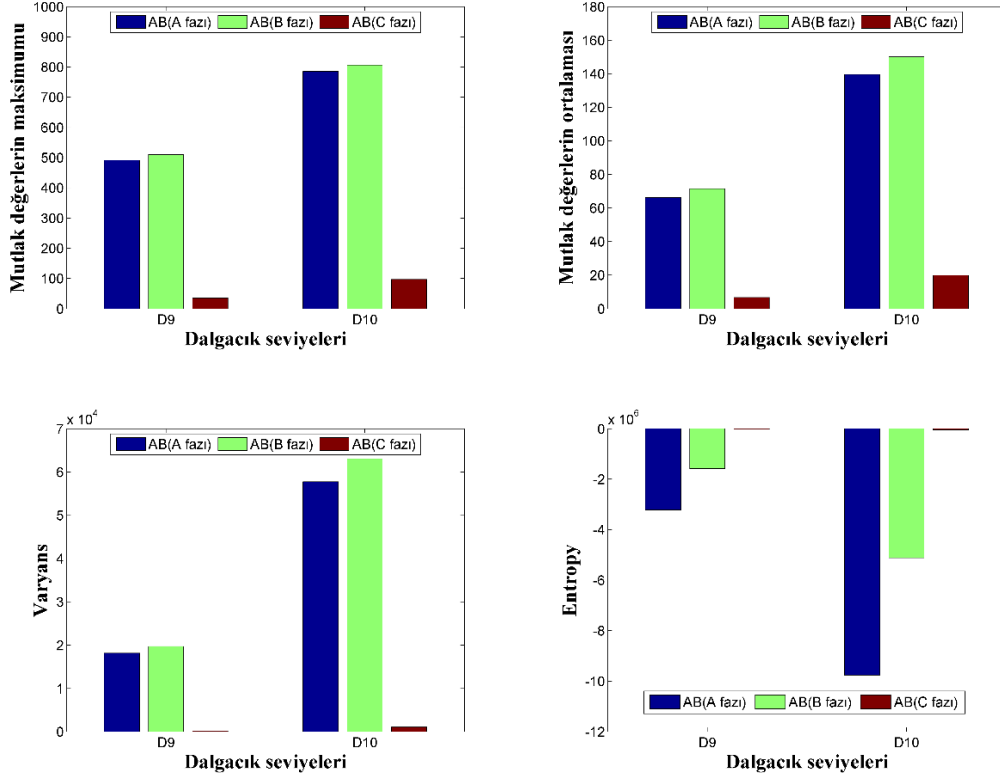
A fazındaki 9. ve 10. seviyedeki detay katsayılarının varyans ve entropi değerleri arızalı olmayan değerlere karşılığı diğer fazlardan daha yüksek olduğu özellikle 10. seviyedeki detay katsayılarının daha fazla baskın olduğu gözlenmektedir.

Şekil 2.12’de DEÜK’lerden oluşan güç dağıtım sistem modeline AB faz arızası uygulanması sonucunda oluşan arızalı akım sinyalleri görülmektedir. A ve B fazlarının 9. ve 10. seviyelerindeki detay katsayılarının dağılımları C fazındaki dağılımlara göre daha belirgin olduğu gözlenmektedir.

Şekil 2.13’te ise bu elde edilen detay katsayılarının dağılımlarına uygulanan çeşitli özellik fonksiyonlarının ilgili ayrıştırma seviyesindeki değerleri görülmektedir. Bu arıza tipine ait çıkarılan özellikler ile ilgili çıkarımlar şunlardır:



Şekil 2.12. AB arızasında her bir faza ait 9. ve 10. ayrıştırma seviyeleri için detay katsayılarının dağılımı.

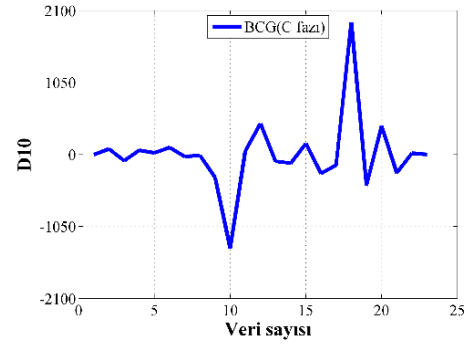
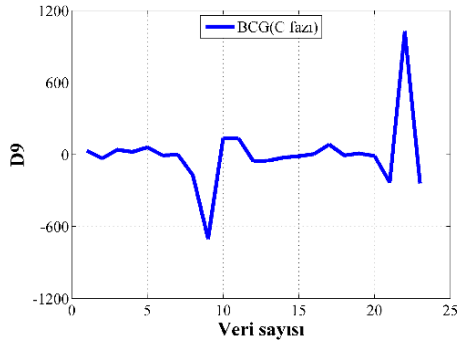







Şekil 2.13. AB arızası için her bir faza ait özelliklerin dağılımı.

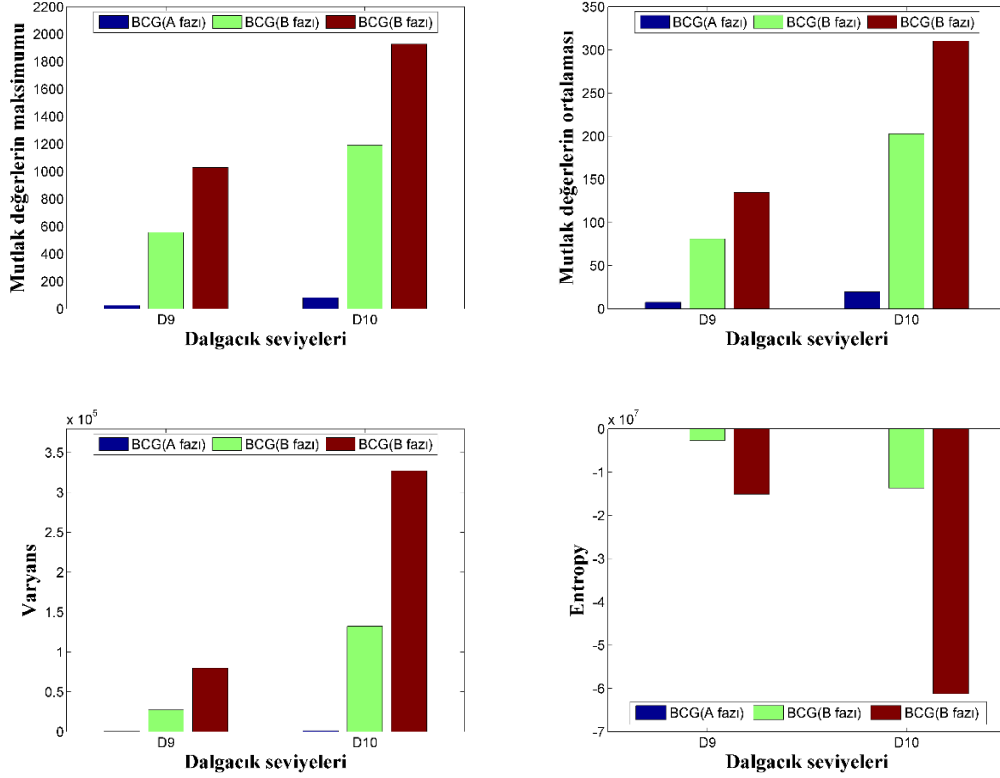
A ve B fazlarındaki mutlak değerlerin maksimum ve mutlak değerlerin ortalama karşılıkları C fazından yüksek olduğu gözlenmektedir.

A ve B fazlarındaki 9. ve 10. ayırıştırma seviyesindeki detay katsayılarının varyans ve entropi değerleri arızalı olmayan C fazından daha yüksek olduğu özellikle 10. seviyesindeki detay katsayılarının daha fazla baskın olduğu gözlenmektedir.

Şekil 2.14'te DEÜK'lerden oluşan güç dağıtım sistem modeline B ve C fazlarına faz-faz toprak arızası uygulanması sonucunda akım verilerine ADD sonrası elde edilen detay katsayılarının değişimi görülmektedir. B ve C fazlarının 9. ve 10. seviyelerine ait detay katsayılarının dağılımları A fazındaki dağılıma göre daha belirgin olduğu gözlenmektedir. Şekil 2.15'te ise bu elde edilen detay katsayılarının dağılımlarına uygulanan çeşitli özellik fonksiyonlarının ilgili ayırıştırma seviyesindeki değerleri görülmektedir. Bu arıza tipine ait çıkarılan özellikler ile ilgili çıkarımlar şunlardır:



Şekil 2.14. BCG arızasında her bir faza ait 9. ve 10. ayrıştırma seviyeleri için detay katsayılarının dağılımı.

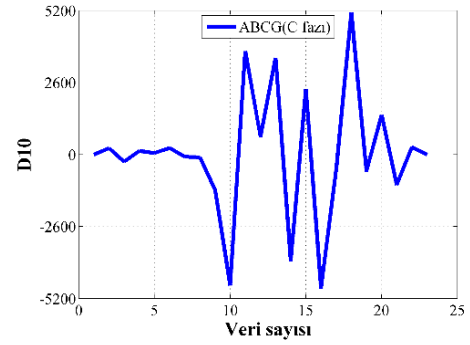








Şekil 2.15. BCG arızası için her bir faza ait özelliklerin dağılımı.

B ve C fazlarındaki mutlak değerlerin maksimum ve mutlak değerlerin ortalama karşılıkları A fazından yüksek olduğu gözlenmektedir.

B ve C fazlarındaki 9. ve 10. ayrıştırma seviyesindeki ADD'ye ait detay katsayılarının varyans ve entropi değerleri arızalı olmayan A fazına ait varyans ve entropi değerlerinden yüksek olduğu özellikle 10. seviyedeki detay katsayılarının daha fazla baskın olduğu gözlenmektedir.

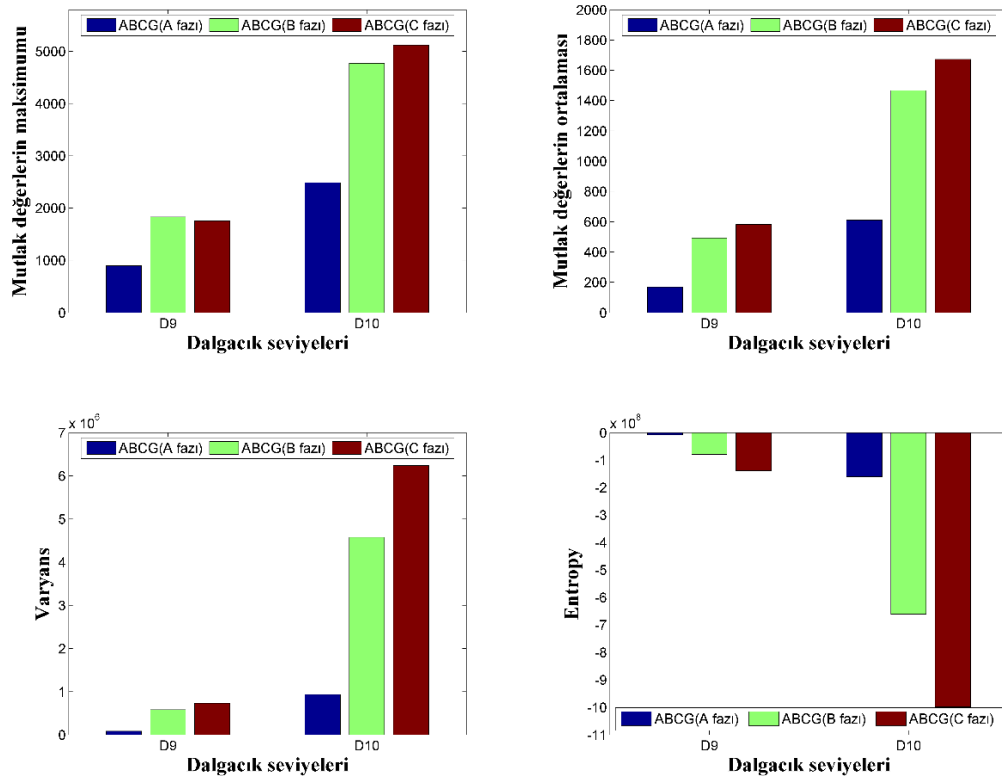
Şekil 2.16'da DEÜK'lerden oluşan güç dağıtım sistem modeline üç faz toprak arızası uygulanması sonucunda oluşan arızalı akım sinyalleri görülmektedir. ADD uygulamasından sonra detay katsayılarının değişimi görülmektedir. A, B ve C fazlarının 9. ve 10. ayrıştırma seviyelerine ait detay katsayılarının dağılımları asimetrik arıza türlerinin arızalı fazlarına kıyasla daha yüksek olduğu gözlenmektedir. Şekil 2.17'de ise detay katsayılarına uygulanan çeşitli özellik fonksiyonlarının 9. ve 10. ayrıştırma seviyesindeki değerleri görülmektedir. Bu arıza tipine ait çıkarılan özellikler ile ilgili çıkarımlar şunlardır:



Şekil 2.16. ABCG arızasında her bir faza ait 9. ve 10. ayrıştırma seviyelerine ait detay katsayılarının dağılımı.

A, B ve C fazlarındaki mutlak değerlerin maksimum ve mutlak değerlerin ortalama karşılıkları asimetrik arıza türlerindeki arızalı faz/fazlara kıyasla daha yüksek olduğu gözlenmektedir.

A, B ve C fazlarındaki 9. ve 10. ayrıştırma seviyesindeki ADD'ye ait detay katsayılarının varyans ve entropi değerleri görülmektedir. Simetrik arıza türündeki üç fazın özellik dağılımı (varyans ve entropi) asimetrik arıza türlerindeki arızalı faz/fazlara kıyasla daha yoğun olduğu görülmektedir.



Şekil 2.17. ABCG arızası için her bir faza ait özelliklerin dağılımı.

3. TOPLULUK ÖĞRENME MODELLERİ VE ÖNERİLEN OLASILIKSAL AĞIRLIKLIL OYLAMA MODELİ

Herhangi bir öğrenme modelinin belirli bir veri setini öğrenebilme kabiliyeti sınırlıdır. Diğer bir ifadeyle, veri setindeki (özellik seti ve sınıf etiketleri) her bir gözlemi öğrenme haritasında eşleştirme yapması pek olası değildir. Böylece en iyi tahmin çıktılarını elde edilmesi mümkün olmamaktadır. Tek öğrenme modeli yerine birden çok öğrenici modelin bir araya getirilmesi tahmin doğruluğunu önemli ölçüde artırabileceği ileri sürülmüştür [137].

Dietterich ve ark. tarafından topluluk öğrenme modelinin tek öğrenici modelden neden yüksek genellemeye sahip olduğu şu şekilde sıralanmıştır [138]:

1. Tek bir en iyi öğrenici modeli seçmek için sadece eğitim verisinin kullanılması yeterli bilgi sağlayamamaktadır. Örneğin, eğitim veri setinde eşit derecede iyi performans gösteren birçok öğrenici model olabilmektedir.
2. Öğrenme algoritmalarının arama süreçlerinin kusurlu olabilmektedir. Örneğin, benzersiz bir en iyi hipotez olsa bile, bu algoritmaları çalıştırmanın optimal olmayan hipotezler verebilmesidir ve sonuç olarak hedeflenen başarıya ulaşamamaktadır.
3. Topluluk yöntemleri iyi bir yaklaşıklık verebilirken aranan hipotez uzayı gerçek hedef fonksiyonunu içermeyebilir. Farklı sınıf etiketlerine sahip veri setinde sınıflar arasındaki karar sınırı çok karmaşık olabilir. Bunun yanında bu veri setine uygulanan sınıflandırıcı modele ait öğrenme uzayının kapsadığı alan karar sınırının dışında kalabilir.

Topluluk öğrenme fikri tek öğrenme modelindeki değişkenliği azaltmak ve böylece doğruluğunu artırmak için geliştirilmiştir. Birçok farklı öğrenme modelinin bir araya getirilmesi ve daha sonra belirli bir strateji ile birleştirilmesi ilkesinden yararlanarak topluluk öğrenme modeli ortaya çıkmıştır [139].

Çoklu öğrenme algoritmalarının birleştirilmesinin temelinde, topluluğu oluşturan temel öğrenme algoritmalarının herhangi birinden elde edilebilecek tahmin performansından daha iyi tahmin performansı elde edebilmek vardır [137].

Topluluk öğreniminin oluşturulması sonucunda tek sınıflandırıcıdan kaynaklı oluşan tahmin hatası diğer sınıflandırıcıların oluşturduğu çeşitlilik ile bu hatanın telafi edilmesi sağlanabilir. Dolayısıyla topluluğa ait genel hatanın tek bir sınıflandırıcı üyesinden daha az olması ortaya çıkabilmektedir [139].

Sınıflandırıcılar eğitim setinin her bir örneğinde farklı hatalar yaptığı ancak genellikle de doğru sınıflandırmalar üzerinde hem fikir olduğu üzerinde anlaştıkları varsayılırsa, sınıflandırıcı çıktılarının ortalamasını almak yani hata bileşenlerinin ortalamasını almak genel sınıflandırma hatasını azaltır. Dolayısıyla topluluk öğrenme modeli ile tahmin edilen çıktılarının varyansı azaltılmış olmaktadır [139].

Birden çok temel öğrenciyi (base learner) toplayarak verilerin temel yapısı hakkında daha fazla bilgi yakalanması sağlanabilir [140].

Yukarıda belirtilen beklentilerden yola çıkılarak son birkaç on yılda topluluk sistemleri olarak da adlandırılan çoklu sınıflandırıcı sistemler, sayısal zekâ ve makine öğrenimi topluluğu alanlarında büyük bir ilgiyle karşılanmıştır. Topluluk öğrenme modelleri özellik seçimi, güven tahmini, hata düzeltme, sınıf dengesizliği sorunlarının yanı sıra yüz ve duygu tanımadan metin sınıflandırması, tıbbi teşhis ve finansal tahmine kadar çeşitli gerçek yaşam problemlerinde başarıyla kullanılmıştır. Topluluk öğrenme yöntemleri, uygulama alanlarının genişliği sayesinde çok etkili ve son derece çok yönlü oldukları kanıtlandığından bu ilgi hak edilmiştir [137, 139].

Lu ve ark., her bir sınıflandırıcının sınıf ağırlıklarına dayalı bir oylama mekanizması önermiştir [141]. Onan ve ark. sınıflandırıcıların ağırlıklarına dayanan yeni bir optimizasyon tabanlı ağırlıklı oylama şeması sunmuştur [142]. Aynı çalışmada, önerilen sınıflandırma yöntemi, torbalama, artırma ve çoğunluk oylaması (majority voting) dahil olmak üzere bireysel sınıflandırma yöntemlerinden daha üstün olduğu gösterilmiştir. Pourdarbania ve ark. aşırı öğrenme sorununun çoğunluk oylaması ile aşılabileceğini belirtmiştir [143].

Wang ve ark. tarafından stator tek faz toprak arızası korumasına yönelik topluluk öğrenme yöntemlerinden olan torbalama (bagging) yöntemi ile arızalı durumların tespitinde doğruluk oranının artabileceği gösterilmiştir [144]. Torbalama yönteminin klasik makine öğrenimi yöntemlerinden daha iyi olduğu gösterilmiştir [141-144].

Topluluk öğrenme modellerinin özellikleri [145]:

1. Bağımsızlık

2. Dağıtklaşma
3. Fikirlerin çeşitliliği
4. Toplama

Yukarıda belirtilen özelliklere ek olarak topluluk öğrenme modelinin eğitim setinin farklı kısımlarında farklı temel öğrenciler ile farklı hata oranlara sahip olması nihai başarı oranının yukarı çıkmasında önemli etkilerden biridir [146]. Bu bağlamda öğrenme modelinde kullanılan temel öğrenciler birbirinden bağımsız olması yani farklı hata yapabilme kabiliyetine sahip olmaları birbirinden ilişkisiz/uyumsuz (korelasyonlarının düşük olması) olmaları gerektirir.

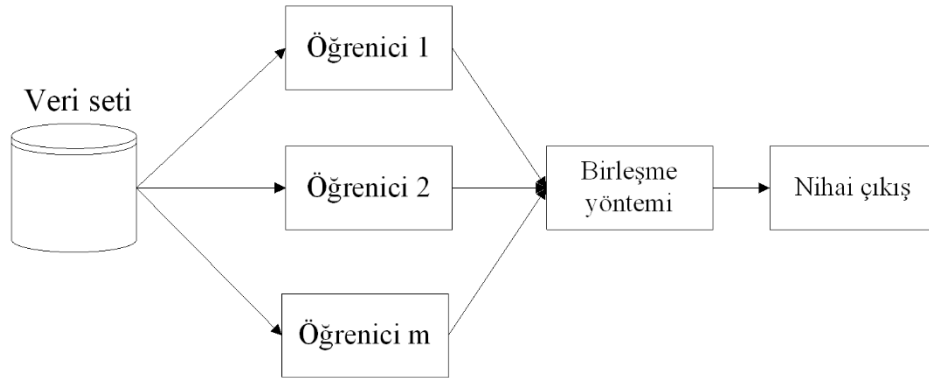
3.1. Topluluk Öğrenme Modeli Topolojileri

Topluluk yöntemleri: bağımlı (seri ya da ardışıl) ve bağımsız (paralel) olmak üzere iki farklı topolojiye sahiptir [147].


Bağımlı bölümde, her uyarıcının çıktısı bir sonraki uyarıcının yapısını etkiler. Bu bölümde, önceki yinelemelerde üretilen bilgi, bir sonraki yinelemede öğrenmeye rehberlik etmektedir.

Bağımsız bölümde ise, her uyarıcı, diğer uyarıcılardan bağımsız olarak oluşturulur. Birleştirme modelleri çeşitli şekillerde oluşturulabilir.

Şekil 3.1’de görülen paralel topluluk diyagramında, çoklu temel öğrenciler aynı anda oluşturulur ve bu temel öğrencilerin bağımsızlığı son modelin performansını iyileştirmek için kullanılır. Paralel topluluğun en önemli avantajı, paralel hesaplamaya elverişli olmasıdır ve gerekli eğitim süresini önemli ölçüde azaltılmasıdır.



Şekil 3.1. Paralel şekilde gerçekleşen öğrenme modeli [147].



Şekil 3.2. Seri şekilde gerçekleşen öğrenme modeli [147]

Paralel topluluktan farklı olarak, sıralı (ardışıl) toplulukta yeni öğrencilerin birer birer oluşturulması gerekir.

Şekil 3.2’de görülen seri öğrenme modelinde sonraki öğrenciler, önceki öğrencilerin hatalarından kaçınabilir ve böylece topluluk performansı gelişebilir.

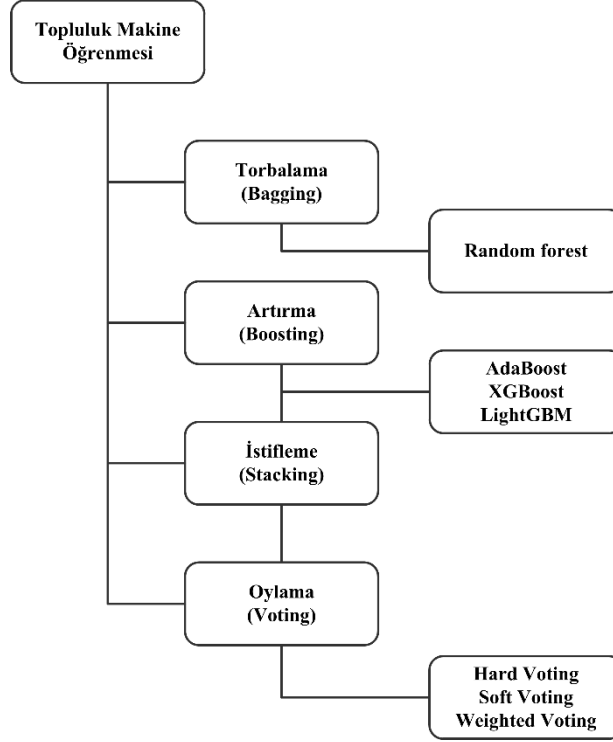
3.2. Topluluk Öğrenme Yöntemleri

En yaygın olarak kullanılan topluluk öğrenme teknikleri: Şekil 3.3’te görüldüğü gibi Torbalama (Bagging), Artırma (Boosting), İstifleme (Stacking) ve Oylama (Voting) olarak yer almaktadır [148]. Sonraki alt bölümlerde topluluk öğrenimine ait kullanılan yöntemler detaylı olarak açıklanacaktır.

3.2.1. Torbalama (Bagging)

Torbalama yöntemi, Bootstrap (Önyükleme) ve Aggregating (Toplama/Birleştirme) adımlarından oluşmaktadır. Torbalama, bir grup tahminciyi kullanarak ve birleştirerek daha iyi bir başarı elde etmeyi amaçlamaktadır. Torbalama yöntemi bağımsız hatalar yapan bazı öğrenme algoritmalarından oluşmaktadır.

Torbalama algoritmasında farklı eğitim kümeleri oluşturmak için önyükleme yöntemi olan örnekleme yoluyla eğitim veri kümesinden k adet alt küme ve her bir alt kümeye uygulanacak şekilde k adet sınıflandırıcı algoritmaları oluşturulur. Her bir sınıflandırıcı algoritmalarından üretilen çıktılar toplanarak tek bir tahmini çıktı elde edilir. Algoritmanın tahmin adımı ise farklı k öğrenci için çoğunluk oylamasına gerçekleştirilmesidir [144].



Şekil 3.3. Topluluk öğrenme modellerinin sınıflandırılması [149].

3.2.2. Artırma (Boosting)

Artırma yöntemi, bir dizi "zayıf" sınıflandırıcıyı yüksek doğrulukla "güçlü" olacak şekilde birleştirmek için kullanılan etkili bir yöntemdir. Güçlendirmeye dayalı algoritmalar, güçlü öğrenenler elde etmek için birden çok zayıf öğreniciyi birleştirir ve genelleme yeteneğini geliştirebilen sapmaları azaltmakla ilgilenir. İlk ve en yaygın kullanılan Boosting algoritması, Adaptive Boosting algoritması olarak literatürde geçmektedir. Standart AdaBoost'ta, her güncellemeden sonra, ya yeniden ağırlıklandırılmış örnekler bir sonraki temel öğreniciyi eğitmek için doğrudan kullanılabilir ya da ilk olarak ağırlıklara göre yeniden örneklenir ve ardından temel öğreniciyi eğitmek için ağırlıklandırılmamış örnekler kullanılabilir [141, 150].

3.2.3. İstifleme (Stacking)

İstifleme yöntemi, birden fazla çok iyi performans gösteren makine öğrenimi modellerinden elde edilen tahminleri en iyi şekilde nasıl birleştirileceğini öğrenen bir topluluk makine öğrenimi yöntemidir. Çoğunluk veya ağırlıklı oylama yöntemleri ile temel eğitim girdileri birleştirebilir [151].

İstifleme yönteminin çalışma prensibi; birinci katmanda birçok sınıflandırıcıdan oluşan bir topluluk inşa edilir, daha sonra ikinci katmanda önceki katmandan elde edilen tahmin çıktıları yeni öğrenicinin girişlerini beslemesi için yeni özellik seti

olarak sunulur. Bu ikinci katmanda yer alan sınıflandırıcı, farklı modellerden üretilen tahminleri birleştirerek nihai bir sınıf etiketinin belirlenmesini sağlar [149].

3.2.4. Oylama (Voting)

Belirli öğrenme modellerinin bir araya getirilmesinden sonra belirli bir veri setine yönelik sınıflandırmada karara varmak için ilgili modellerin tahminleri uygun bir kuralla birleştirilmesi gerekir. Bunun yapılmasındaki amaç; nispeten sabit veya benzer biasa (yanılgıya) sahip birkaç sınıflandırıcının bir araya getirilmesi ve ardından varyansın (sapmanın) azaltılmasıdır. Bu sebeple sınıflandırıcıları birleştirme yöntemlerinde biri olan oylama, iki veya daha fazla makine öğrenimi modellerinden elde edilen tahminlerin tek modelde birleşmesinden oluşmaktadır [139].

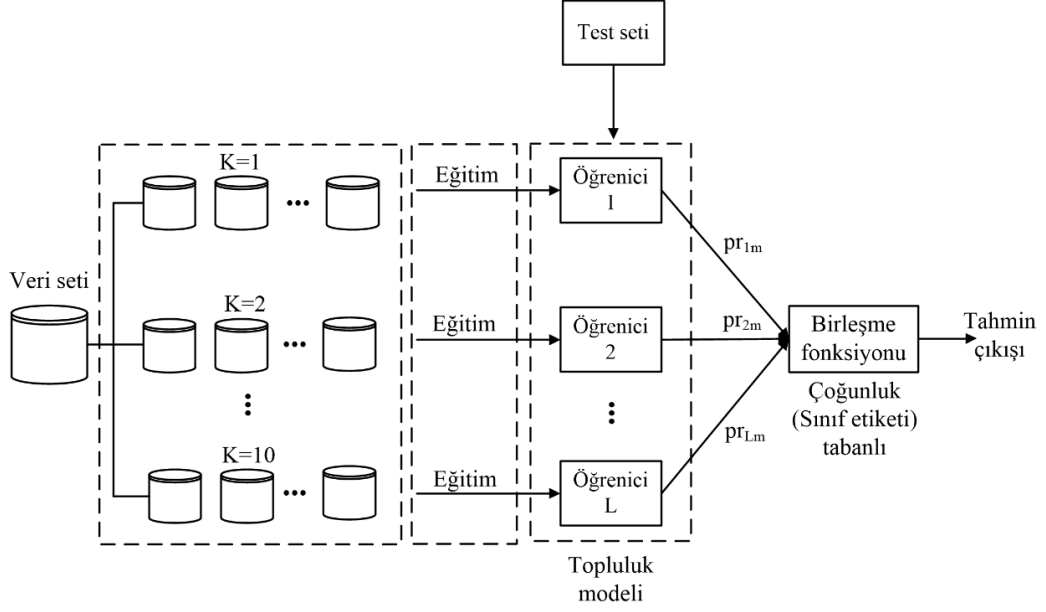
Birden fazla sınıflandırıcı modellerin olduğu topluluk sisteminde tek bir noktada nihai karara varmak için uygulanan karar kuralıdır [152].

Çoğu topluluk yöntemi, homojen temel öğrenciler üretmek için tek tabanlı bir öğrenme algoritması kullanır, ancak heterojen öğrenciler üretmek için çoklu öğrenme algoritmalarını kullanan bazı yöntemler de vardır [153, 154]. Aynı sınıflandırıcılardan oluşan torbalama, artırma ve rastgele ormandan (RF) farklı olarak, çoklu öğrenme modellerini birleşmesini sağlayan heterojen topluluk yöntemi, çeşitlilik sağlayarak sınıflandırma (oylama) performansını artırır [155, 156].

Oylama, toplu öğrenmede en sık uygulanan yaklaşımdır. Oylama modeli, ağırlıksız ve ağırlıklı oylamayı içerir [142]. Ağırlıksız oylama, olasılıksal tabanlı oylama veya çoğunluk tabanlı oylama modellerini içerirken, ağırlıklı oylama modeli ise, basit ağırlıklı oylamayı içerir.

3.3. Ağırlıksız Oylama Modeli

Bu bölümde ağırlıksız oylama modelleri detaylı olarak açıklanacaktır. Bu tür oylama yöntemleri ya modeller tarafından tahmin edilen sınıf etiketleri aracılığıyla doğrudan nihai sınıf tahmini edilir ya da kesinliği belli olmayan test setindeki sınıflara ait olasılıksal dağılımlar sayesinde nihai sınıf tahmini edilir [157].



Şekil 3.4. Çoğunluk tabanlı oylama modelinin mimarisini.

3.3.1. Çoğunluk tabanlı oylama modeli (Hard voting)

Genel olarak bu oylama türü, çoğunluğun sahip olduğu sınıf etiketi olarak bilinmektedir. Bagging (torbalama) modelinde nihai sınıf etiketinin hesaplanması bu yöntem (hard voting) ile gerçekleştirilmektedir.

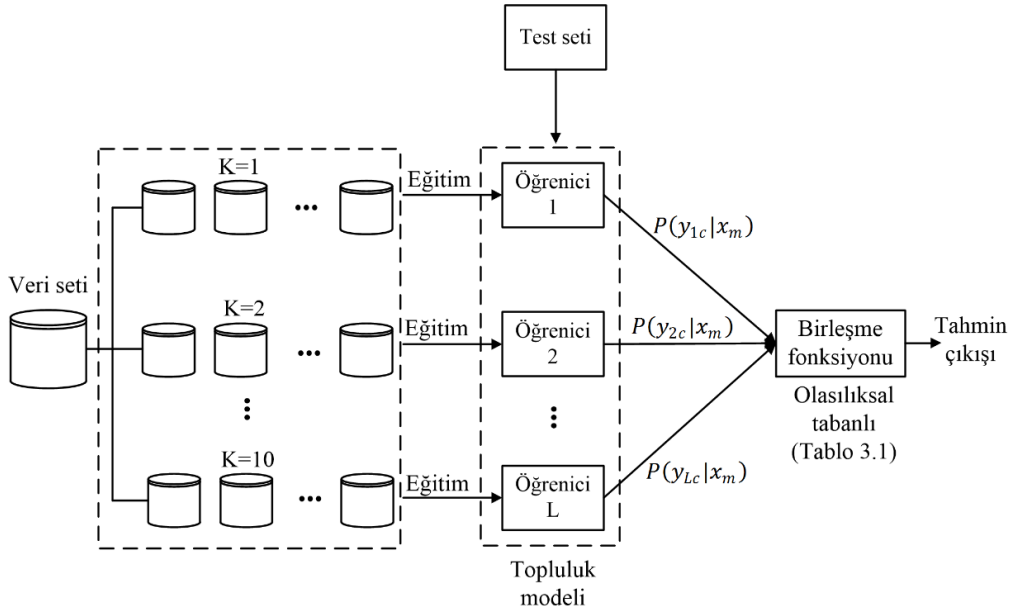
Çoğunluk tabanlı oylama modeli, topluluk yöntemleri arasında basit ve verimli yöntemdir. Şekil 3.4'te gösterilen sınıf etiketi tabanlı oylama yönteminin mimarisinde, nihai tahmin sınıf etiketi, denklem 3.1 ile sınıflandırıcılar tarafından tahmin edilen sınıf etiketlerinin en yüksek sayıda oy almasına bağlı olarak gerçekleştirilir [142].

$$HV_m = mode(pr_{1m}, pr_{2m}, pr_{lm}, \dots, pr_{Lm}) \quad (3.1)$$

Burada pr_{lm} ve HV_m ise sırasıyla m . test örneği için l . öğrenici model tarafından tahmin edilen sınıf etiketi ve çoğunluk oylama tabanlı çıkış etiketi olarak isimlendirilir.

3.3.2. Olasılıksal tabanlı oylama modeli (Soft voting)

Olasılıksal tabanlı oylama modelinde, eğitilen her modele test setinin tüm örnekleri sunulur. Her bir test örneği için tüm sınıf etiketlerine karşılık gelen olasılıksal dağılımlar elde edilir. Sınıf etiketlerine ait ayrı ayrı skor katkısı, Şekil 3.5'te görüldüğü gibi, topluluk modeli içerisinde yer alan modellerin olasılık değerleri ve uygun görülen birleşme fonksiyonu ile belirlenir.



Şekil 3.5. Olasılıksal tabanlı oylama modelinin mimarisi.

Son olarak bu skor katkılarından maksimum olan etiket, ilgili test örneğinin nihai sınıf etiketidir. Kittler tarafından [158] sunulan Maksimum Kuralı, Minimum kuralı, Çarpım Kuralı ve Toplam Kuralı içeren topluluk kuralları, ilgili test örneğinin sınıf etiketini belirlemede kullanılabilir. Maksimum skor değerine sahip sınıf etiketi; sınıflara atanan sonsal (posterior) olasılık değerleri ve Tablo 3.1’de listelenen topluluk kuralları ile belirlenir. M adet ölçüm/gözlem, F adet özellik ve C adet sınıf etiketine sahip D veri setine L adet temel öğrencinin sınıflandırma yapmak amacıyla bir araya getirildiğini varsayalım.

Burada test verisi $k = 1 \leq m \leq M$, sınıf etiketleri $e = 1 \leq c \leq C$ ve temel öğrenciler $n = 1 \leq l \leq L$ olarak belirtilmiştir.

L tane temel öğrenciler tarafından m . test örneğine ait c . sınıf etiketi; $P(y_{1c}|x_m), P(y_{2c}|x_m), \dots, P(y_{lc}|x_m), P(y_{Lc}|x_m)$ sonsal olasılık dağılımları Tablo 3.1’de olduğu gibi uygun bir birleşme fonksiyonu ile nihai etiket değeri belirlenir.

Burada SV_m ; C adet sınıf etiketli m . test seti örneğini sınıflandırmada en yüksek skor katkısına sahip nihai sınıf etiketine karşılık gelmektedir.

Hard voting (çoğunluk tabanlı oylama) modeli ile nihai sınıf etiketi için sınıflandırıcıların tahmin ettikleri etiket değerlerinden herhangi birini almasına zorlanır.

Tablo 3.1. Olasılıksal tabanlı oylama model çeşitleri.

Kural	Strateji	Tanım
Max	$SV_m = \arg \max_c \{R_1, R_2, \dots, R_C\}$ $R_c = \max\{P(y_{1c} x_m), \dots, P(y_{Lc} x_m)\}$	<i>a</i>
Min	$SV_m = \arg \max_c \{R_1, R_2, \dots, R_C\}$ $R_c = \min\{P(y_{1c} x_m), \dots, P(y_{Lc} x_m)\}$	<i>b</i>
Product	$SV_m = \arg \max_c \{R_1, R_2, \dots, R_C\}, R_c = \prod_{i=1}^L P(y_{ic} x_m)$	<i>c</i>
Sum	$SV_m = \arg \max_c \{R_1, R_2, \dots, R_C\}, R_c = \sum_{i=1}^L P(y_{ic} x_m)$	<i>d</i>

a: Olasılıklar maksimumu tabanlı oylama modeli

b: Olasılıklar minimumu tabanlı oylama modeli

c: Olasılıklar çarpımı tabanlı oylama modeli

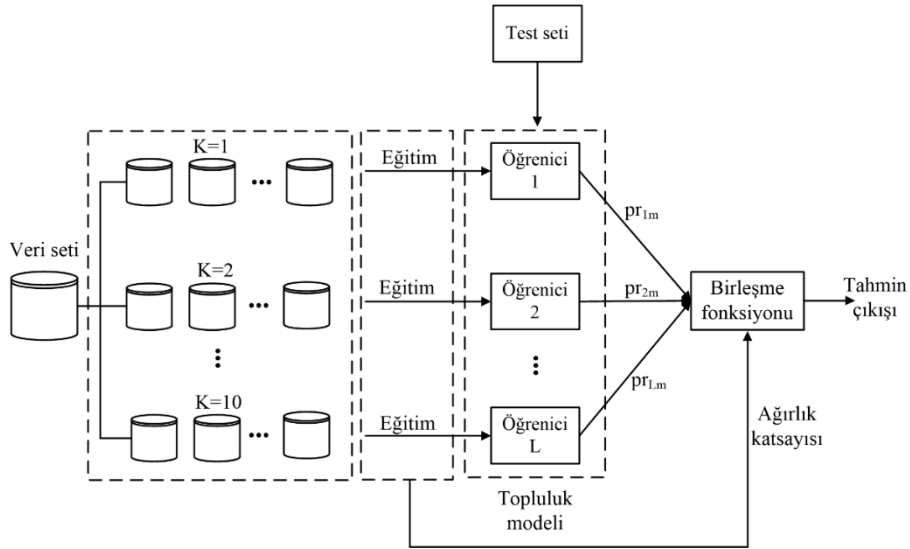
d: Olasılıklar toplamı tabanlı oylama modeli

Diğer yandan olasılıksal tabanlı oylama modeli ise doğrudan sınıf etiketlerine yönlendirmeden her bir sınıflandırıcının sınıf etiketlerinin olasılıksal katkıları değerlendirilir [159].

3.4. Ağırlıklı Oylama Modeli (Weighted Voting)

Ağırlıklı oylama modelinde topluluk modelinde yer alan her bir temel öğrencilerin nasıl ağırlıklandırılacağı ve ağırlıklandırma parametrelerinin nasıl ayarlanacağı önemli bir husustur [152].

Ağırlıklı oylama modelinde, Şekil 3.6’da görüldüğü gibi her bir öğrenci modelinin ağırlık katkısı, eğitim veri kümesi üzerindeki tahmin doğruluğu temel alınarak belirlenir. Daha spesifik olarak, daha yüksek tahmin doğruluğuna sahip makine öğrenimi modellerine, daha düşük tahmin doğruluğuna sahip olanlardan daha üstün/yüksek ağırlıklar atanır. Ağırlık tabanlı oylama yönteminin çoğunluk oylamasına göre bir avantajı vardır [142].



Şekil 3.6. Ağırlıklı oylama modelinin mimarisi.

Denklem 3.2 eşitliğini kullanarak sınıflandırıcıların ağırlıkları $[0,1]$ aralığında toplamları 1 olacak şekilde orantılı olacak şekilde dengelenir.

$$w_i^* = \frac{w_i}{\sum_{i=1}^L w_i} \quad (3.2)$$

Burada w_i ve L sırasıyla i . öğrenicinin/sınıflandırıcının m . test örneği için ağırlık katsayısı ve toplam sınıflandırıcı sayısı olarak temsil edilir.

3.5. Oylama Modelleri Hakkında Yapılan Literatür Çalışmaları

Bu bölümde oylama öğrenme modelleri hakkında araştırmacıların yaptıkları çalışmalar ile ilgili değerlendirme yapılmıştır. Bu çalışmalardan yola çıkarak bu tez çalışmasında kullanılan oylama modeli ile ilgili analiz yapılmıştır.

Gao ve ark., sınıflandırıcıların sınıf ağırlıklarının hesaplanmasına bağlı olarak adaptif bir oylama yöntemini önermiştir [160].

Catal ve ark., olasılıksal oylama yöntemlerine ve önerdikleri yönteme (çoğunluk tabanlı) ilişkin performans sonuçları, oylama yöntemlerini karşılaştırmak amacıyla çalışmalarında sunulmamıştır. Ayrıca eğitim aşamasında verilerin sadece 90 %'i kullanılmıştır [161].

Rustam ve ark. pulsar yıldızlarını tahmin etmek için rastgele orman (Random Forest - RF), gradyan artırılmış sınıflandırıcı (Gradient Boost Classifier - GBC) ve ekstra ağaç sınıflandırıcı (Extra Trees Classifier - ETC) modellerini içeren rastgele ağaç artırılmış

oylama sınıflandırıcısını (RTB-VC) sunmuştur. Çoğunluk tabanlı, olasılıksal tabanlı ve ağırlıklı oylama yöntemlerinin bir kombinasyonu olan bir oylama modelini önermiştir [162].

Żabiński ve ark. oylama yöntemi olarak çoğunluk ve ağırlıklı çoğunluktan yararlanmışlardır. Bu yöntemlerden ağırlıklı çoğunluk oylama yönteminin daha uygun olduğu görülmüştür. Ağırlıklı çoğunluk oylamasında, ağırlık katsayıları olarak sonsal (posterior) olasılıklar kullanılmıştır. Çoğunluk ve ağırlıklı çoğunluk tabanlı modellerin performans sonuçları karşılaştırmalı şekilde verilmemiştir [163].

Rahimi ve ark. yeni bir topluluk makine öğrenimi yöntemi oluşturmak için sınıflandırıcıların sınıf doğruluklarını ve karışıklık matrisinde doğru bir şekilde tahmin edilen değerleri dikkate almıştır [164].

Livieris ve ark. akciğer anormalliklerini göğüs röntgenlerinden sınıflandırmak için yeni bir ağırlıklı oylama şemasına dayalı yeni bir topluluk öğrenme algoritması sunmuştur. Ağırlık ataması, önerilen oylama şemasındaki değerlendirme (validation) seti ile ilgili her bir sınıflandırıcının sınıf etiketlerindeki doğruluklarına göre yapılmıştır. Eğitim aşamasının performans sonuçları ağırlık seçiminde dikkate alınmamıştır [165].

[160-164] çalışmalarında kullanılan yöntemin geçerliliğini göstermek için istatistiksel analiz gerçekleştirilmemiştir ve kabul edilmiş veri setleri değerlendirilmemiştir.

Yukarıda bahsedilen çalışmalar, ağırlıklı ve ağırlıksız oylama modelleri incelendiğinde ağırlıklı oylama modelinde topluluk sistemine ait temel öğrencilerin sınıflarıyla ilgili olasılıksal dağılımların olmaması, diğer yandan ağırlıksız oylama modellerinden olan olasılıksal tabanlı oylama yönteminde temel öğrencilerin eğitim aşamasındaki performansları ile ilgili katsayıların/ağırlıkların yer almamasıdır. Bu bilgiler ışığında, önerilen oylama modelinin temelinde ağırlık seçim tabanlı olasılıksal dağılımların ağırlık katsayıları ile katkılandırılması yer almaktadır [128].

3.6. Önerilen Olasılıksal Ağırlıklı Oylama Modeli

Örüntü tanıma biliminde sınıflandırma en önemli görevlerden birisidir. Örüntü tanıma biliminin başlangıcından bu yana, bu alandaki en zorlu problemlerden biri, herhangi bir probleme ait veri setini düzgün bir şekilde öğrenebilen bir genel sınıflandırıcının sunulmamasıydı. Şimdiye kadar problemlerin öğrenilmesi için birçok sınıflandırıcı

önerilmiştir. Ancak hepsinin kendine göre olumlu ve olumsuz yönleri bulunmaktadır. Bundan dolayı, sadece belirli problemler için iyi performans sergilemişlerdir [155].

Belirli bir problem için hangi sınıflandırıcının daha iyi bir model olduğunu anlamanın güçlü bir çözümü yoktur. Sınıflandırıcıların veri kümesinin tamamını öğrenebilmesi diye bir şeyin olmadığı da söylenebilir. Her sınıflandırıcı bir veri kümesinin farklı alt uzaylarında farklı performans ya da hata eğilimi gösterebilir. Bu bağlamda farklı alt uzaylarda yanlış şekilde kullanılan sınıflandırıcıların bir araya getirilmesi sonucunda topluluk içerisindeki sınıflandırıcılardan daha az hata eğilimi gösterebileceği de gözlemlenmiştir. Bu şekilde toplu öğrenme ile herhangi bir problem için optimale yakın bir sınıflandırıcı model oluşturulması mümkündür. Bu bağlamda daha sağlam bir tahmin modeli için çoklu öğrenme modellerine (ÇÖM) ihtiyaç vardır. Böyle bir model birbirinden bağımsız tahmin yapabilen sınıflandırıcılar ile sağlanabilir. ÇÖM, herhangi bir numune testi için sınıflandırıcıların daha esnek, güçlü ve sağlam model tahminlerini sunar. ÇÖM'ün sınıflandırma performansı bireysel sınıflandırıcılardan daha iyi olduğu araştırmacılar tarafından [160, 166-167] çalışmalarında savunulmuştur.

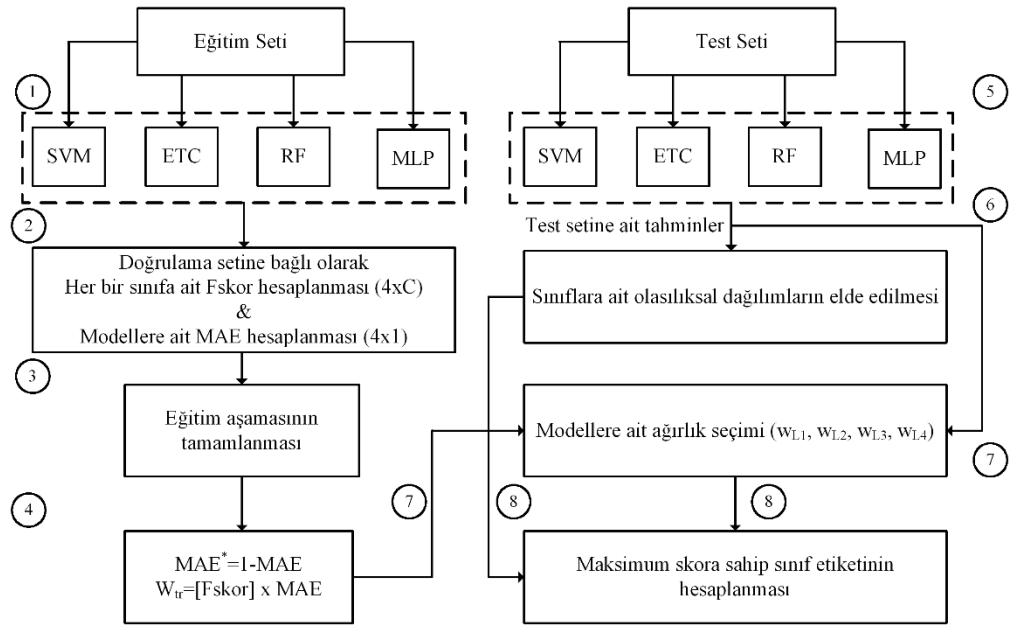
Topluluktaki sınıflandırıcıların birbirinden bağımsız olarak farklı şekilde hata eğilimi göstermeleri topluluğu güçlendirmesine ve bu nedenle daha iyi sınıflandırma performansına yol açabilmektedir. Bunlara ek olarak standart altı bir çözüm hipotezi sunan algoritmalar; topluluk yöntemi ile bu arama süreçlerini daha iyi bir seviyeye çıkarabilme şansları olduğu belirtilmiştir [140, 155].

Önerilen olasılıksal ağırlıklı oylama modelinin (OAOM) tasarım aşamaları bu bölümde sunulacaktır. Olasılıksal ağırlıklı oylama modelini tasarlamak için açık kaynaklı yazılım dili Python ve scikit-learn kütüphanesi kullanılmıştır [168].

Şekil 3.7'de gösterilen olasılıksal ağırlıklı oylama modelinin tasarlanmasına ilişkin aşamaları şu şekilde listelenmiştir:

1. Topluluk öğrenme modelinde kullanılan temel öğrenciler/sınıflandırıcılar ve bunlara ait parametrelerinin belirlenmesi
2. Eğitim aşaması: eğitim setinin K-katlı çapraz doğrulama ile 10 eşit parçaya ayrılması-sınıflandırıcı modellerin eğitilmesi

3. Eğitim aşamasında doğrulama setlerinden elde edilen Fskor ve ortalama mutlak hata değerlerinin elde edilmesi
4. 3. bölümden elde edilen Fskor ve ortalama mutlak hataya bağlı olarak ağırlık kümesinin oluşturulması
5. Eğitilen her bir öğrenci modele test setinin sunulması ve doğruluğu bilinmeyen ilk sınıf etiketlerinin elde edilmesi
6. Her bir öğrenci model için test örneklerinin sınıflarına ait sonsal olasılıksal dağılımlarının oluşturulması
7. 4. ve 5. aşamalar yardımıyla ilgili test örneği için öğrencilere ait ağırlık katsayılarının belirlenmesi
8. 6. ve 7. aşamalara bağlı olarak katkılılandırılmış ağırlık değerlerinden oluşan ağırlık matrisinin gösterimi ve nihai sınıf etiketinin belirlenmesi



Şekil 3.7. Önerilen oylama modeline (OAOM) ait tasarım diyagramı [128].

3.6.1. Önerilen oylama modelinde (OAOM) kullanılan temel öğrenciler ve bu öğrencilere ait parametrelerin belirlenmesi

Bu bölümde önerilen olasılıksal ağırlıklı oylama modelinde kullanılan temel öğrenci modeller ve bu modellere ait sınıflandırma parametrelerinin belirlenme süreci hakkında detaylı açıklama yapılacaktır.

3.6.1.1. Önerilen oylama modelinde kullanılan temel öğreniciler

Bu alt bölümde OAOM yapısında kullanılacak temel öğrenici modeller detaylı bir şekilde anlatılacaktır.

- Ekstra ağaçlar sınıflandırıcı modeli

Geurts ve ark. çalışmalarında; karar ağaçlarına dayalı olarak çalışan Ekstra ağaçlar sınıflandırıcı modeli (Extra Trees Classifier – ETC)'nin temelinde bir ağaç düğümünü bölerken hem özellik hem de kesim noktası seçimini güçlü bir şekilde rastgele hale getirmekten oluştuğunu bildirmişlerdir [169].

ETC, N özelliği rastgele seçmek için doğrudan tüm örnekleri kullanır. Bu N özellik için, her özellik rastgele bir bölünmüş düğüm seçer, böylece N bölünmüş düğüm elde edilir. Daha sonra ETC, N bölünmüş düğümün puanlarını hesaplar ve en yüksek puana sahip bölünmüş düğümü seçer.

Önyükleme kopyalaması ve kesme noktalarının rasgele seçimi yerine tüm örneğin kullanılması, ETC'nin iki temel ayırt edici özelliğidir.

ETC, rastgele ormanın (RF) bir çeşididir. Bu nedenle, ETC algoritması ile RF algoritması arasında iki ana fark vardır [170]:

Birincisi, her karar ağacının eğitim seti için RF, her karar ağacının eğitim seti olarak numune setini seçmek için rastgele örnekleme önyükleme kullanır, ETC ise rastgele örnekleme kullanmaz, yani her karar ağacı orijinal eğitim setini kullanır.

İkincisi, bölme özelliklerini seçtikten sonra, RF'nin karar ağacı; Gini katsayısına, ortalama karesel sapmaya ve geleneksel karar ağacıyla aynı olan diğer ilkelere dayalı olarak optimal bir özellik değeri olan bölme noktasını seçecektir. ETC ise bölmek için rastgele bir özellik değeri seçecek ve rastgele ormana (RF) kıyasla daha küçük ve daha kararlı varyansa sahip bir sonuç elde edecektir.

- Destek vektör makineleri

Destek vektör makinesi (Support vector machine - SVM), küçük örneklem ve doğrusal olmayan sınıflandırma problemini çözebilen, yapısal risk minimizasyonu ilkesine dayalı yaygın olarak kullanılan bir makine öğrenme yöntemidir. Hiperdüzlem denklemi optimal ayırma düzlemi standardına ulaşırsa, yani maksimum sınıf aralığı durumunda örnek doğru bir şekilde ayrılabilirse, optimal ayırma düzlemi için çözüm aşağıdaki amaç fonksiyonlarına ve kısıtlamalara dönüştürülür [171].

Doğrusal olarak ayrılabilir veri noktaları için SVM algoritmasının amacı; veri noktalarını belirgin şekilde sınıflandıran N boyutlu bir uzayda (burada N, özellik sayısıdır) optimal bir hiper düzlemi (veya bir karar sınırı) bulmaktır. Destek vektörleri, hiper düzleme en yakın olan veri noktalarıdır. SVM algoritması, ayırıcı hiper düzlem etrafındaki marjı en üst düzeye çıkarmayı amaçlar ve bu da onu esasen kısıtlı bir optimizasyon problemi haline getirir [172].

Yukarıda bahsedilen problem, denklem 3.3, 3.4 ve 3.5 ile gösterilen optimizasyon problemine dönüştürülür.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_{i,t} \quad (3.3)$$

$$y_i(w\varphi(x_i) + b) - 1 + \xi_{i,t} \geq 0, \quad (3.4)$$

$$\xi_{i,t} \geq 0, i = 1, \dots, l, \quad (3.5)$$

burada C, yanlış sınıflandırma örnekleri için ceza derecesini kontrol eden ceza parametresidir. Ek olarak, C değeri ne kadar büyük olursa, hata cezası da o kadar büyük olur.

Yukarıda belirtilen problemler, denklem 3.6, 3.7 ve 3.8 ile gösterilen ikili probleme dönüşür:

$$\operatorname{argmax} \left(\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y_i y_j \alpha_i \alpha_j K(x_i, x_j) \right) \quad (3.6)$$

$$\sum_{i=1}^l \alpha_i y_i = 0, \quad (3.7)$$

$$0 \leq \alpha_i \leq C, \quad i = 1, \dots, l, \quad (3.8)$$

Burada α_i Langrange çarpanı ve $K(x_i, x_j) = \varphi(x_i) \cdot \varphi(x_j) \in R$ kernel fonksiyonudur ki bu ise $\varphi(x_i)$ ve $\varphi(x_j)$ fonksiyonların iç çarpımıdır. Bunların sonucunda nihai karar fonksiyonu denklem 3.9 ile ifade edilir:

$$f(x) = \text{sgn} \left(\sum_{i=1}^l \alpha_i^* y_i^* K(x_i^*.x) + b \right) \quad (3.9)$$

SVM modelini daha kompleks veri kümelerinde genelleme yapabilmek için çekirdek (kernel) fonksiyonları kullanılır. SVM, yüksek boyutlu uzayındaki veri sınıflandırma problemlerini çekirdek fonksiyonları ile iyi bir şekilde çözebilir.

Çekirdek işlevi SVM için çok önemlidir. SVM'de, çekirdek işlevleri temel olarak denklem 3.10 ile gösterilen lineer çekirdek işlevi (LKF), denklem 3.11 ile gösterilen radyal temel işlevi (RBF), sigmoid işlevi ve polinom çekirdek işlevini içerir. Bu çekirdek işlevleri arasında, RBF işlevi, girdi uzayından örnek kümesini yüksek boyutlu bir özellik uzayına etkili bir şekilde eşleyebilir; böylece, girdi ve çıktı örnekleri arasındaki karmaşık doğrusal olmayan ilişkiyi temsil etmek için daha uygundur [173].

$$K_{linear}(x, x_i) = (x^T x_i + c) \quad (3.10)$$

$$K_{rbf}(x, x_i) = \exp \left(-\frac{\|x - x_i\|^2}{2\sigma^2} \right) \quad (3.11)$$

Burada $K_{linear}(x, x_i)$ ve $K_{rbf}(x, x_i)$ radyal temelli ve lineer kernel fonksiyonlarını sırasıyla temsil etmektedir.

Düşük boyutlu özellik seti ve eğitim verisi için genellikle RBF SVM'nin çekirdek işlevi olarak seçilir; özellik boyutu eğitim setinden fazla olması durumunda, genellikle LKF kullanılır [174].

- Çok katmanlı algılayıcı

Bir yapay sinir ağı modeli kurmak için gerekli adımlar [175]:

1. YSA'nın mimarisi
2. Eğitim aşamasında kullanılacak eğitim algoritması
3. Matematiksel modeli tanımlayan matematik fonksiyonların oluşturulması

Yukarıdaki bu maddeler incelendiğinde modelde kullanılan nöronlar 1 katmandan fazla şekilde tasarlanma durumunda model çok katmanlı YSA modeline dönüşecektir. Eğitim aşamasında amaç ilgili problemin giriş ve çıkış değişkenleri arasındaki

minimizasyonun sağlanması ve bunu sağlayacak optimal ağırlıkların belirlenmesi ele alınmaktadır. Bu hatanın azaltılma işlemini gerçekleştirecek birden fazla optimizasyon yöntemi kullanılabilir. Son olarak her bir nöronun davranışını tanımlamada kullanılan matematiksel fonksiyonlar: toplam fonksiyonu ve aktivasyon fonksiyonudur.

Bir geri yayımlı sinir ağı (BPNN) modeli, ileri beslemeli bir mimariye sahiptir, denetimli bir öğrenme yöntemi kullanır, kendisine verilen örneklerden öğrenir ve bu nedenle, değişkenler arasındaki matematiksel ilişkileri belirleme ihtiyacından yoksundur ve karmaşık veri ilişkilerini barındırır. Bu eğitim algoritması kullanılarak, bu tür YSA'lar, hatanın ağ boyunca geriye doğru yayıldığı gradyan iniş yöntemleriyle eğitilir.

BPNN mimarisi, sinir ağının birden çok değişken arasında doğrusal olmayan eşleme ilişkisi kuran modeller arasındaki karmaşık ilişkileri hesaplamasını ve tahmin etmesini sağlayan bir girdi katmanı, bir çıktı katmanı ve bir veya birkaç gizli katman içerir. Geri yayılım algoritması, zincir kuralı yöntemini uygulayarak bir YSA'yı eğitir. Ağın ağırlıkları rasgele başlatılır, ardından gerçek çıktı y_{out} ile istenen çıktı y_{out} değeri arasındaki fark ölçülerek hesaplanan maliyet fonksiyonunun en aza indirilmesi yoluyla tekrar tekrar ayarlanır. En yaygın hata ölçümlerinden biri, denklem 3.12'de görüldüğü gibi ortalama karesel hata (MSE)'dir [176, 177].

$$E = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.12)$$

Transfer fonksiyonunun seçimi büyük oranda yapay sinir ağın karmaşıklığını ve performansını etkiler. Bu YSA türünde bilgi ileri beslemeli olarak akar. Bundan dolayı bu YSA'lar, çok katmanlı ileri beslemeli veya çok katmanlı algılayıcılar (Multi layer perceptron - MLP) olarak tanımlanmaktadır.

- Rastgele orman modeli

Rastgele orman modeli (Random forest - RF), korelasyonu olmayan ağaç kestiricimlerinin büyük bir kombinasyonudur. Bu birleşim, bağımsız şekilde örneklenmiş rastgele vektörlerin değerlerine bağlıdır [178]. Tek tek ağaçlar gürültülü ve dengesizdir, ancak yeterince derine doğru büyüdüklerinde nispeten düşük sapmaya

sahiptirler. Bu nedenle, karmaşık etkileşimleri yakalayabildikleri için topluluk öğrenme yapısına ideal adaylardan biridir.

$$f(x_i) = \{f(x, \delta_k), k = 1, \dots, K\} \quad (3.13)$$

Burada $f(x, \delta_k)$ meta sınıflandırıcıdır ve birkaç algoritmalardan oluşan ağaç yapısında bir sınıflandırıcıdır, x giriş vektörü, δ_k random vektör birbirinden bağımsız fakat aynı dağılımı paylaşabilen bir vektördür (3.13) ve tek karar ağacının büyümesini belirlemektedir. RF optimal sınıflandırıcı sonucunu almak için farklı karar ağaçlarının sonuçlarını özetler. Karar ağacının aksine RF genellemedeki zayıflığın üstesinden gelmektedir [179].

Rastgele ormanlar, toplamaya dayalı varyans azaltmadan tamamen yararlanır. Her bir düğümü bölmek için rastgele bir özellik seçimi kullanılması ve her bir ağacı büyütmek için eğitim setinin yeniden örneklenmesi (değiştirme) ile korelasyonu olmayan ve gürültüye göre daha güçlü hata oranları verir. Rastgele ormanlar için genelleme hatası, ormandaki ağaç sayısı arttıkça bir sınıra yakınsar. Genel olarak özellikleri; basit ve kullanımı kolaydır, çok yüksek doğruluğa sahiptir, aykırı değerlere ve gürültüye karşı nispeten sağlamdır, bölme seçimine duyarsızdır [178].

3.6.1.2. Temel öğrencilere ait sınıflandırma parametrelerin ayarlanması

Topluluk modeli için seçilen temel öğrencilerin sınıflandırma performanslarını yükseltmek için hiperparametre özelliğinden yararlanır. Tüm hiperparametre ayarları, 5 katlı çapraz doğrulama işlemi altında grid search uygulaması ile gerçekleştirilir. Izgaralama (grid search) yöntemi; çapraz doğrulama tekniğini kullanarak bir tahmin edici için belirtilen parametre değerleri üzerinde kapsamlı bir arama yapılmasını sağlar. Bu yöntem kullanılarak öğrenci modellere ait parametreler Tablo 3.2'deki gibi elde edilmiştir [128].

3.6.2. Eğitim aşaması

Bu bölümde seçilen modellerin eğitim aşamaları sunulmaktadır. Eğitim yapılmasındaki amaç; öğrenme modellerinin eğitim seti verilerini kapsayacak şekilde eşleştirme yapabilmelerini ve öğrenmelerini sağlamaktır. Bunu yapabilmek için makine öğrenme alanında iki terim karşımıza çıkmaktadır: çeşitlilik ve genelleme. Bunlara çözüm olması için de K-katlı çapraz doğrulama yöntemi kullanılmaktadır.

Tablo 3.2. Temel öğrenicilere ait model parametreleri.

Temel Öğrenici	Parametre değerleri
SVM	C=5000, Gamma=5, Kernel tipi=rbf
ETC	Maksimum derinlik = 15, Ağaç sayısı=200
RF	Ağaç sayısı=180, Düğüm bölümü için minimum örnek sayısı=2, Minimum yaprak sayısı=1, Maksimum derinlik =80
MLP	Optimizasyon fonksiyonu=adam, Aktivasyon fonksiyonu=tanh, alpha=1e-4, Gizli katman boyutu=80-200-80

3.6.2.1. Çeşitlilik

Birkaç sınıflandırıcı aynı sınıflandırma performansını gösterse bile çıkışlarının birleştirilmesi tek sınıflandırıcıdan daha iyi performans göstermesine neden olabilir. Farklı sınıflandırıcıların birleşiminin daha iyi sınıflandırma yaptığını söyleyebilmek için sınıflandırıcılar arasındaki çeşitlilik kavramının olması gerekmektedir. Bir toplulukta çeşitliliğin varlığı, bu sınıflandırıcıların birbirinden bağımsız olduğu gerçeğini ortaya koymaktadır [155]. Bu nedenle paralel sınıflandırıcılar topluluk öğrenmesine daha uygundur. Bağımsızlık denilmesindeki amaç, herhangi bir test örneği için topluluğu oluşturan modeller tarafından yanlış olarak sınıflandırmaların aynı anda gerçekleşmediğinin belirtilmesidir. Bu modeller arasında düşük korelasyon/uyumsuzluk olması anlamına da gelmektedir.

Nitesh ve ark. çeşitliliği; sınıflandırıcıların yaptıkları hatalarda anlaşamama derecesi olarak ifade etmiştir. Bu ise oylama ile elde edilen doğruluğun herhangi bir tek sınıflandırıcının elde ettiği doğruluktan daha büyük olmasına sağlar [180].

Bashir ve ark. çalışmalarında, heterojen yapıdaki öğrenme topluluğunun güçlü bir öğrenme kabiliyetine sahip olmasını, temel sınıflandırıcıların performansı ve aralarındaki korelasyon eksikliğiyle (model çeşitliliği) ilişkili olduğunu belirtmişlerdir [167].

Bir öğrenme modelinin yaptığı hatanın diğer modeller tarafından telafi edilecek şekilde olması çeşitliliğin sağlandığı anlamına geldiğini gösterir.

Deneysel sonuçlar, modeller arasında önemli bir çeşitlilik olduğunda topluluk modellerinin daha iyi sonuçlara sahip olma eğiliminde olduğunu göstermektedir. Model çeşitliliği farklı algoritmalara dayalı modeller kullanılması; bir diğeri ise, aynı

algoritmaya dayalı, ancak veri kümesinin farklı alt kümeleriyle eğitilmiş modellerini kullanılması ile açıklanabilir [181].

Kuncheva topluluk öğrenme yapılarında istenilen başarıyı sağlama adına ya giriş tarafında ya çıkışta ya da öğrenici modellerde istenilen performansı göstermek için kasıtlı olarak çeşitlilik yöntemini uygulamıştır [182].

3.6.2.2. Genelleme

Genelleme, eğitim tamamlandıktan sonra modelin gerçek problem üzerinde ne kadar iyi performans gösterdiğinin bir ölçüsüdür. Genellikle eğitim seti dışındaki yeni veriler üzerinde ağın performansı değerlendirilerek test edilir [183]. Eğitim için kullanılan örneklerden farklı olarak yeni örnekleri doğru tahmin edebilme yeteneği, makine öğrenimi için önemli değerlendirme kriterlerinden biri olan genelleme yeteneği [184] olarak bilinir.

Eğitilmiş bir modelin genelleme yeteneği genellikle az veya aşırı öğrenme sorunlarıyla ilgilidir. Az öğrenme, örnek verilerin yetersiz olduğu veya öğrenme algoritmasının uygun olmadığı anlamına gelirken, aşırı öğrenme genellikle gözlem sayısına göre çok fazla parametreye sahip olmak gibi modelin aşırı derecede karmaşık olduğu anlamına gelmektedir [185].

Gao ve ark. tarafından görülmemiş test setlerine ait tek bir sınıflandırıcıdan daha çok genelleme kabiliyetini ve sağlamlılığını geliştirmek için sınıflandırıcıların çıkışlarının birleştirilmesi gerektiği vurgulanmıştır [160]. Bunun nedenlerinden biri, tek bir öğrencinin mevcut eğitim verilerinden yeterli bilgiyi yakalayamamasıdır. Örneğin, birkaç öğrenici modeller belirli bir eğitim veri setinde eşit derecede iyi performans gösterebilir, ancak bu öğrencileri birleştirmek daha iyi bir sonuç verebilir. Diğer bir neden de temel öğrencilere ait öğrenme/eşleştirme süreçlerinin çok iyi olmaması durumudur. Böylece topluluklar, bu tür kusurlu arama sürecini telafi edebilir. Dolayısıyla topluluk yapısının genelleme kabiliyeti artabilir.

3.6.2.3. K-katlı çapraz doğrulama

Birçok sınıflandırma modeli içinde barındırdığı birçok parametre ile uygun eğitim modelini oluşturmada karmaşıklığa yol açmaktadır. Bu şekilde yapılması durumunda uygun eğitim modelinin bulunması uzun bir süre alabilmektedir.

Veri seti yeterince mevcut olması durumunda, model seçimi için en basit yol, tüm verileri eğitim seti, doğrulama seti ve test seti olmak üzere üç alt kümeye ayırmaktır.

Kuncheva bağımsız üretilen eğitim setlerinin topluluk sistemleri için yüksek çeşitlilik sağlandığını belirtmiştir. Bunu sağlamak için farklı veri ayırma/bölme oranları kullanılması ve farklı özellik setlerinin kullanılması önerilmiştir [141].

İlk olarak eğitim setinde bir dizi model eğitilir, doğrulama setinde karşılaştırılır ve son olarak test setinde değerlendirilir. Farklı öğrenme karakteristiğine sahip karmaşık modeller arasından en etkili ve iyi tahmin performansına sahip olan modelin seçimi, K. katlı çapraz doğrulama aşamalarındaki doğrulama setlerinden elde edilen başarı performanslarının ortalamasına bağlı olarak gerçekleştirilir.

Pratik bir uygulamada, eğitim ve test veri seti sınırlı olabilmektedir ve bu da genelleme hatasının artmasına neden olmaktadır. Bu durumu önlemek için K-katlı çapraz doğrulama gerçekleştirilmektedir [186]. K = 5 durumu için. K katlamalı çapraz doğrulama, mevcut veri seti D'yi K ayrık gruplara, D1, D2, ... , D5 bölümlere ayırır. Daha sonra K-1 grupları eğitim seti olarak kalan grup ise doğrulama (validation) seti olarak kullanılır. Bu şekilde tüm K olası doğrulama aşamaları için tekrarlanır ve K alt kümelerden elde edilen performans sonuçlarının ortalaması alınır. Bu şekilde eğitilen modelin performansı değerlendirilir. Bu yöntem ile kullanılan öğrenme modelinin tahmin kabiliyeti hakkında ikna edici sonuçlara ulaşılması, aşırı ve eksik öğrenmenin önlenmesi gerçekleşir. Şekil 3.8'te görüldüğü gibi veri seti 5 eşit parçaya bölünmüştür. K=1 doğrulama aşamasında 5. alt küme seti doğrulama seti (turuncu alan), geri kalanlar (beyaz renkli alanlar) ise eğitim seti olarak kullanılır.

Eğitim ve Doğrulama Seti					
K=1	1	2	3	4	5
K=2	1	2	3	4	5
K=3	1	2	3	4	5
K=4	1	2	3	4	5
K=5	1	2	3	4	5

Şekil 3.8. K-katlı çapraz doğrulama.

3.6.3. Eğitim aşamasında doğrulama setlerinden elde edilen Fskor ve ortalama mutlak hata değerlerinin elde edilmesi

Öğrenici modellerin eğitimi, K katlı çapraz doğrulama yöntemi ile gerçekleştirilmektedir. Her K. katlı çapraz doğrulama aşamasında eğitim setinin dışarısında kalan alt küme doğrulama seti olarak kullanılarak temel öğrencilere ait Fskor ve ortalama mutlak hata (MAE) değerlerinin hesaplanması gerçekleştirilmiştir.

$$MAE = \frac{1}{N} \sum_{j=1}^N |y_j - \hat{y}_j| \quad (3.14)$$

$$\begin{aligned} MAE_1 &= \begin{bmatrix} e_{1,1} \\ e_{1,2} \\ e_{1,3} \\ \vdots \\ e_{1,10} \end{bmatrix} & MAE_2 &= \begin{bmatrix} e_{2,1} \\ e_{2,2} \\ e_{2,3} \\ \vdots \\ e_{2,10} \end{bmatrix} \\ MAE_3 &= \begin{bmatrix} e_{3,1} \\ e_{3,2} \\ e_{3,3} \\ \vdots \\ e_{3,10} \end{bmatrix} & MAE_4 &= \begin{bmatrix} e_{4,1} \\ e_{4,2} \\ e_{4,3} \\ \vdots \\ e_{4,10} \end{bmatrix} \end{aligned} \quad (3.15)$$

Temel öğrenici modellerinin duyarlılığını ve kesinliğini ölçmek için iyi bir gösterge olan Fskor ölçüm kistası dikkate alınmıştır. Modelin tahmin ya da genelleme kabiliyetinin gücünü tahmin etmek için eğitim aşamasında denklemler (3.14, 3.15) ile ortalama mutlak hata (MAE) değerleri kullanılır [187]. Bu bölümde ilk olarak öğrenici modellerin genelleme performansını hesaplamak için her K. katlı doğrulama aşamasında ortalama mutlak hatalar hesaplanır. Önceden tanımlanan (10x1) boyutundaki boş vektöre ilgili K. adımdaki MAE değeri kaydedilir. Bu şekilde eğitim süreci boyunca her öğrenici model için L tane MAE vektörü oluşturulur.

Sınıf etiketleri $c \in \{1,2 \dots C\}$, temel öğrenciler $l \in \{1,2 \dots L\}$ aralığında ve test setine ait gözlemler $m \in \{1,2 \dots M\}$ olarak belirtilmiştir.

Her bir modelin sınıf dağılımlarına ait Fskor matrisi, toplam C sınıf etiketine sahip bir veri seti ve 10 kat doğrulama aşamasından oluşacak bir eğitim süreci için (10 x C) boyutunda oluşturulmaktadır. Her çapraz doğrulama aşamasında sınıf etiketlerine ait denklem 3.16 ile hesaplanan Fskor değerleri önceden tanımlanan bu matrise

kaydedilir. Bu şekilde tüm doğrulama setleri için temel öğrencilere ait Fskor matrisleri, eşitlikler (3.17, 3.18, 3.19, 3.20)'deki gibi oluşturulur.

$$Fskor = \left(2 \times \frac{\frac{TP}{TP+FN} \times \frac{TP}{TP+FP}}{\frac{TP}{TP+FN} + \frac{TP}{TP+FP}} \right) \quad (3.16)$$

$$Fskor_1 = \begin{bmatrix} fs^1_{1,1} & fs^2_{1,1} & fs^3_{1,1} & \dots & fs^C_{1,1} \\ fs^1_{1,2} & fs^2_{1,2} & fs^3_{1,2} & \dots & fs^C_{1,2} \\ fs^1_{1,3} & fs^2_{1,3} & fs^3_{1,3} & \dots & fs^C_{1,3} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ fs^1_{1,10} & fs^2_{1,10} & fs^3_{1,10} & \dots & fs^C_{1,10} \end{bmatrix} \quad (3.17)$$

$$Fskor_2 = \begin{bmatrix} fs^1_{2,1} & fs^2_{2,1} & fs^3_{2,1} & \dots & fs^C_{2,1} \\ fs^1_{2,2} & fs^2_{2,2} & fs^3_{2,2} & \dots & fs^C_{2,2} \\ fs^1_{2,3} & fs^2_{2,3} & fs^3_{2,3} & \dots & fs^C_{2,3} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ fs^1_{2,10} & fs^2_{2,10} & fs^3_{2,10} & \dots & fs^C_{2,10} \end{bmatrix} \quad (3.18)$$

$$Fskor_3 = \begin{bmatrix} fs^1_{3,1} & fs^2_{3,1} & fs^3_{3,1} & \dots & fs^C_{3,1} \\ fs^1_{3,2} & fs^2_{3,2} & fs^3_{3,2} & \dots & fs^C_{3,2} \\ fs^1_{3,3} & fs^2_{3,3} & fs^3_{3,3} & \dots & fs^C_{3,3} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ fs^1_{3,10} & fs^2_{3,10} & fs^3_{3,10} & \dots & fs^C_{3,10} \end{bmatrix} \quad (3.19)$$

$$Fskor_4 = \begin{bmatrix} fs^1_{4,1} & fs^2_{4,1} & fs^3_{4,1} & \dots & fs^C_{4,1} \\ fs^1_{4,2} & fs^2_{4,2} & fs^3_{4,2} & \dots & fs^C_{4,2} \\ fs^1_{4,3} & fs^2_{4,3} & fs^3_{4,3} & \dots & fs^C_{4,3} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ fs^1_{4,10} & fs^2_{4,10} & fs^3_{4,10} & \dots & fs^C_{4,10} \end{bmatrix} \quad (3.20)$$

3.6.4. Eğitim performansından elde edilen verilere göre ağırlık matrisinin oluşturulması

Bu bölümde, ağırlık matrisinin oluşturulması ile ilgili formülasyon sunulacaktır.

İlk olarak denklemler (3.17, 3.18, 3.19 ve 3.20) ile temel öğrencilere ait Fskor değerlerinden oluşan matrislerin ortalaması alınır ve sonuç olarak her bir model için (1xC) boyutunda vektör oluşturulur daha sonra bu vektörler alt alta birleştirilir. Sonuç olarak elde edilen matris, eşitlik 3.21'deki gibi görünmektedir.

$$w_{in} = \begin{bmatrix} fs_{1,1} & fs_{1,2} & fs_{1,3} & \dots & fs_{1,C} \\ fs_{2,1} & fs_{2,2} & fs_{2,3} & \dots & fs_{2,C} \\ fs_{3,1} & fs_{3,2} & fs_{3,3} & \dots & fs_{3,C} \\ fs_{4,1} & fs_{4,2} & fs_{4,3} & \dots & fs_{4,C} \end{bmatrix} \quad (3.21)$$

Benzer şekilde denklem 3.15'te görüldüğü gibi MAE değerlerinden oluşan vektörleri denklem 3.22'den faydalanarak MAE^* vektörlerine dönüştürülür. Daha sonra bu vektörlerin ortalaması alınır ve (4x1) boyutunda yeni bir vektör elde edilir.

$$MAE^* = 1 - MAE \quad (3.22)$$

Eşitlikler 3.21 ve 3.22 kullanılarak eşitlik 3.23'teki gibi ağırlık kümesi elde edilir. Böylece bu elde edilen (4xC) boyutundaki matriste, hem temel öğrenciler hakkında genelleme kabiliyeti hem de veri setinde bulunan sınıf etiketlerinin Fskor'a bağlı olarak değişen sınıf dağılımları görülmektedir.

$$w_{tr} = \begin{bmatrix} fs_{1,1} & fs_{1,2} & fs_{1,3} & \dots & fs_{1,C} \\ fs_{2,1} & fs_{2,2} & fs_{2,3} & \dots & fs_{2,C} \\ fs_{3,1} & fs_{3,2} & fs_{3,3} & \dots & fs_{3,C} \\ fs_{4,1} & fs_{4,2} & fs_{4,3} & \dots & fs_{4,C} \end{bmatrix} \cdot \begin{bmatrix} MAE^*_1 \\ MAE^*_2 \\ MAE^*_3 \\ MAE^*_4 \end{bmatrix} \quad (3.23)$$

3.6.5. Eğitilen her bir öğrenci modele test setinin sunulması ve doğruluğu bilinmeyen ilk sınıf etiketlerinin elde edilmesi

Bu bölümde, eğitilen her bir öğrenci modelin girişleri daha önceden sunulmamış yeni özellik-sınıf seti ile beslenmesi sağlanacaktır. Daha sonra her bir modelden test seti boyutunda yeni sınıf etiketleri elde edilir. M boyutlu gözlemlere ait tahmin edilen etiket değerleri Denklem 3.24'te görüldüğü gibi ($M \times 1$) boyutundaki vektörlerde kaydedilir.

$$pr_{1m} = \begin{bmatrix} pr_{11} \\ pr_{12} \\ pr_{13} \\ \cdot \\ \cdot \\ \cdot \\ pr_{1M} \end{bmatrix} \quad pr_{2m} = \begin{bmatrix} pr_{21} \\ pr_{22} \\ pr_{23} \\ \cdot \\ \cdot \\ \cdot \\ pr_{2M} \end{bmatrix} \quad pr_{3m} = \begin{bmatrix} pr_{31} \\ pr_{32} \\ pr_{33} \\ \cdot \\ \cdot \\ \cdot \\ pr_{3M} \end{bmatrix} \quad pr_{4m} = \begin{bmatrix} pr_{41} \\ pr_{42} \\ pr_{43} \\ \cdot \\ \cdot \\ \cdot \\ pr_{4M} \end{bmatrix} \quad (3.24)$$

3.6.6. Her bir öğrenci model için test örneklerinin sınıflarına ait sonsal olasılıksal dağılımlarının oluşturulması

Bu bölümde, bir önceki aşamaya ait test setinden elde edilen tahminlere bağlı olarak sınıf etiketlerinin sonsal olasılık dağılımlarının formülasyonu verilecektir. Herhangi bir test örneği için sınıf etiketinin c olma durumuna ait topluluk içerisindeki yer alan öğrencilerin sonsal olasılık dağılımları denklem 3.25'teki gibi gösterilir.

$$P = \{p_1(y = c|x), p_2(y = c|x) \dots p_L(y = c|x)\} \quad (3.25)$$

Herhangi bir eğitilmiş öğrenci modele test seti sunulmasından sonra tahmin çıktıları oluşmaktadır. Bu tahmin çıktılarına karşılık gelen olasılıksal dağılımları gösteren (gözlem sayısı \times sınıf etiketi) boyutundaki olasılıksal dağılım kümesi, Denklemler (3.26, 3.27, 3.28 ve 3.29)'de görüldüğü gibi oluşturulmaktadır.

$$P_{1m} = \begin{bmatrix} p^1_{1,1} & p^2_{1,1} & p^3_{1,1} & \dots & p^c_{1,1} \\ p^1_{1,2} & p^2_{1,2} & p^3_{1,2} & \dots & p^c_{1,2} \\ p^1_{1,3} & p^2_{1,3} & p^3_{1,3} & \dots & p^c_{1,3} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ p^1_{1,M} & p^2_{1,M} & p^3_{1,M} & \dots & p^c_{1,M} \end{bmatrix} \quad (3.26)$$

$$P_{2m} = \begin{bmatrix} p^1_{2,1} & p^2_{2,1} & p^3_{2,1} & \dots & p^c_{2,1} \\ p^1_{2,2} & p^2_{2,2} & p^3_{2,2} & \dots & p^c_{2,2} \\ p^1_{2,3} & p^2_{2,3} & p^3_{2,3} & \dots & p^c_{2,3} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ p^1_{2,M} & p^2_{2,M} & p^3_{2,M} & \dots & p^c_{2,M} \end{bmatrix} \quad (3.27)$$

$$P_{3m} = \begin{bmatrix} p^1_{3,1} & p^2_{3,1} & p^3_{3,1} & \dots & p^c_{3,1} \\ p^1_{3,2} & p^2_{3,2} & p^3_{3,2} & \dots & p^c_{3,2} \\ p^1_{3,3} & p^2_{3,3} & p^3_{3,3} & \dots & p^c_{3,3} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ p^1_{3,M} & p^2_{3,M} & p^3_{3,M} & \dots & p^c_{3,M} \end{bmatrix} \quad (3.28)$$

$$P_{4m} = \begin{bmatrix} p^1_{4,1} & p^2_{4,1} & p^3_{4,1} & \dots & p^c_{4,1} \\ p^1_{4,2} & p^2_{4,2} & p^3_{4,2} & \dots & p^c_{4,2} \\ p^1_{4,3} & p^2_{4,3} & p^3_{4,3} & \dots & p^c_{4,3} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ p^1_{4,M} & p^2_{4,M} & p^3_{4,M} & \dots & p^c_{4,M} \end{bmatrix} \quad (3.29)$$

3.6.7. Temel öğrencilere ait ağırlık katsayılarının belirlenmesi

Topluluk öğrenme modelinin içerisindeki öğrenci modellere ağırlık ataması ya da seçimi, MAE vektörü ve Fskor matrisi kullanılarak gerçekleştirilir.

Doğruluğu bilinmeyen/kesin olmayan tahminlere dayalı olarak ağırlık seçimi, denklem 3.30 ile belirlenir. Bu ağırlık seçimi, denklem 3.23'teki ağırlık matrisinden belirlenir.

$$\{w^1_l = w_{tr}(l, y), \text{ eğer } pr_{lm} = y \text{ ise}\} \quad (3.30)$$

En son olarak 3.23'ten belirlenen sınıflandırıcılara ait ağırlıklar, eşitlik 3.2 ile kümülatif toplamları 1 olacak şekilde dengelenir.

Örneğin, eğer 1. öğrenci model tarafından test setindeki 1. gözlem için tahmin edilen etiket değeri 2 olduğu varsayılırsa;

3.30 eşitliğinde $\{w_s = w_{tr}(1,2), \text{ eğer } pr_{1,1} = 2\}$ 1. öğrenci modele ait ağırlık katsayısı, (3.25)'den yararlanarak ilgili ağırlık matrisinin 1. satır ve 2. sütun karşılığında yer alan değer ağırlık katsayısı olarak seçilir. Bu durum diğer öğrenci modellere de uygulanır.

Sonuç olarak ilgili temel öğrenci modelin katkılanmış ağırlık değerleri, ağırlık matrisinden elde edilen ağırlık katsayısı ve ilgili öğrenci modelin test setindeki gözlemine ait sınıfların olasılıksal dağılımları ile belirlenir.

3.6.8. Eğitim performansı ve olasılıksal katkılanma ile oluşturulan ağırlık matrisinin gösterimi ve nihai sınıf etiketinin belirlenmesi

Kittler [158] tarafından sunulan olasılıksal oylama yönteminde, eşitlik 3.31'te gösterildiği gibi nihai sınıf etiketi; her bir sınıfa ait temel öğrencilerin olasılıksal dağılımları baz alınarak toplam, çarpım, minimum ve maksimum fonksiyonlarına göre belirlenmektedir. Temel öğrencilerin performansları ağırlık katsayısı olarak bu oylama yönteminde dikkate alınmamıştır. Bu bilgiden esinlenerek tez çalışmasında, eğitim aşamasından elde edilen Fskor ve MAE değerlerinden bir ağırlık matrisi oluşturulmuştur. Temel öğrencilerin tahmin çıktılarına bağlı olarak ağırlık matrisinden ağırlık katsayısı seçimleri gerçekleştirilerek eşitlik 3.32'de olduğu gibi (sınıf sayısı x temel öğrenci sayısı) boyutunda bir ağırlık matrisi oluşturulur. Sonuç olarak, nihai sınıf etiketinin belirlenmesi için oluşan katkılanmış ağırlık matrisi,

3.33'te görüldüğü üzere olasılıklar dağılımların ağırlık katsayıları ile katkılanırılmasına dayalıdır.

$$P = \begin{bmatrix} P_1(y = 1|x) & P_2(y = 1|x) & P_3(y = 1|x) & P_4(y = 1|x) \\ P_1(y = 2|x) & P_2(y = 2|x) & P_3(y = 2|x) & P_4(y = 2|x) \\ \vdots & \vdots & \vdots & \vdots \\ P_1(y = C|x) & P_2(y = C|x) & P_3(y = C|x) & P_4(y = C|x) \end{bmatrix}_{CX4} \quad (3.31)$$

$$w = \begin{bmatrix} w_{L1}^n & w_{L2}^n & w_{L3}^n & w_{L4}^n \\ w_{L1}^n & w_{L2}^n & w_{L3}^n & w_{L4}^n \\ \vdots & \vdots & \vdots & \vdots \\ w_{L1}^n & w_{L2}^n & w_{L3}^n & w_{L4}^n \end{bmatrix}_{CX4} \quad (3.32)$$

$$w \odot P = S = \begin{bmatrix} w_{L1}^n P_1(y = 1|x) & w_{L2}^n P_2(y = 1|x) & w_{L3}^n P_3(y = 1|x) & w_{L4}^n P_4(y = 1|x) \\ w_{L1}^n P_1(y = 2|x) & w_{L2}^n P_2(y = 2|x) & w_{L3}^n P_3(y = 2|x) & w_{L4}^n P_4(y = 2|x) \\ \vdots & \vdots & \vdots & \vdots \\ w_{L1}^n P_1(y = C|x) & w_{L2}^n P_2(y = C|x) & w_{L3}^n P_3(y = C|x) & w_{L4}^n P_4(y = C|x) \end{bmatrix} \quad (3.33)$$

S_{jk} , ilgili test setinin m . gözlemi için S matrisindeki j . temel öğrencinin k . sınıfına ait katkılanmış ağırlık değerini temsil etmektedir. Örneğin; S matrisinin 1. satırı; ilgili test setinin gözlemi için "1" etiketi olarak gösterilen sınıfa ait tüm temel öğrencilerin katkılanmış ağırlık değerlerini temsil etmektedir.

n , 3.32 eşitliğinde yer alan $n \in \{1,2 \dots N\}$ tanım kümesinde olacak şekilde temel öğrencilere ait ağırlık katsayılarının güçlendirilmesi için sağlanan bir parametredir.

Denklem 3.34 ile maksimum skora sahip sınıf etiketi belirlenir. S matrisinin ilgili satır vektörüne ait tüm katkılanmış ağırlık değerleri toplanır. S matrisindeki her bir satır vektörlere toplam fonksiyonu uygulanır. Maksimum değere sahip olan toplam fonksiyonuna ait satır numarası, ilgili test seti gözlemi için nihai sınıf etiketidir. Son işlem adımı, ağırlıksız oylama modeline ait olasılıkların toplam yöntemine benzemektedir, fakat bu yöntemden farkı ise olasılıksal dağılımların ağırlık katsayıları ile katkılanırılmasıdır.

$$OAOMC_m = \underset{c \in \{1,2 \dots C\}}{\operatorname{argmax}} \left(\sum_{k=1}^L S_{1,k}, \sum_{k=1}^L S_{2,k}, \dots, \sum_{k=1}^L S_{C,k} \right) \quad (3.34)$$

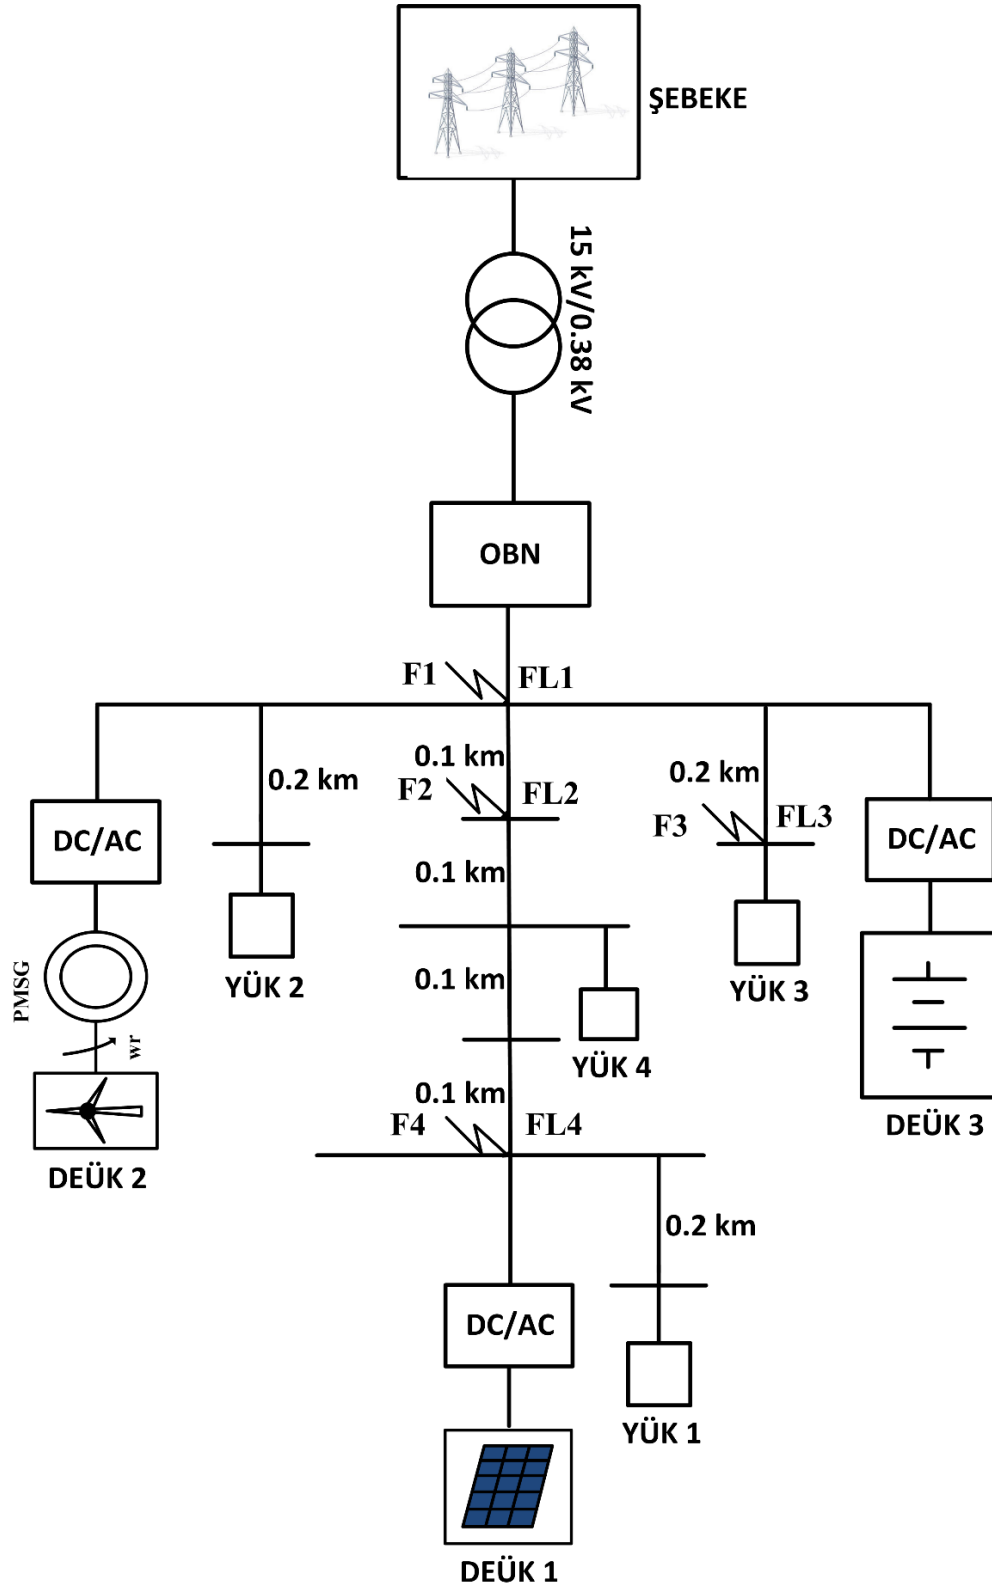
4. TEST SİSTEMİ VE DAĞITIK ENERJİ ÜRETİM KAYNAKLARININ MODELLENMESİ

Bu bölümde tez kapsamında kullanılacak olan test sistemi detaylı şekilde tanıtılacaktır. Test sistemi olarak Elektrik Güvenilirliği Teknoloji Çözümleri Konsorsiyumu (Consortium for Electric Reliability Technology Solutions-CERTS)'na ait mikroşebeke modeli modifiye edilerek DEÜK'lerden oluşan güç dağıtım sistem modeli olarak bu tez kapsamında kullanılacaktır [188]. Bu model, 15 kV / 0.38 kV gerilim seviyesine sahip üç fazlı bir dağıtım transformatörün sekonder kısmından (alçak gerilim tarafından) beslenen elektrik güç dağıtım sisteminin bir parçası olarak kabul edilir. Test sisteminde OBN'de bulunan üç-fazlı bir dağıtım transformatörü, DEÜK'lerin kapasiteleri, yük ve hat modeli ile ilgili parametreler sunulacaktır. Daha sonra yenilenebilir enerji kaynakları olarak fotovoltaik panel ve rüzgâr türbini hakkında daha kapsamlı bilgiler verilecektir. Sonraki aşamada test sisteminde kullanılan dağıtık enerji üretim kaynaklarının şebeke bağlantısına ait kontrol yöntemi sunulacaktır. En son olarak bu test sisteminden oluşturulacak olası arızalı ve arızalı olmayan senaryolar ile ilgili detaylı bir açıklama sunulacaktır.

Şekil 4.1'de gösterildiği gibi, test sistemi; üç adet dağıtık enerji üretim kaynakları, dört adet yük grubu, üç-fazlı dağıtım transformatörü, hat ve şebeke modelinden oluşmaktadır.

Tablo 4.1. Transformatör parametreleri.

Parametre	Değer
Nominal güç	400 kVA
Primer-sekonder gerilimi	15 kV/0.38 kV
Reaktans/direnç oranı	4



Şekil 4.1. Test sistemi [128].

Test sistemi boyunca dört tane yük YÜK 1, YÜK 2, YÜK 3 ve YÜK 4 olarak dağıtılır. Dağıtık enerji üretim kaynakları ve yüklerden oluşan güç dağıtım sistemi, ortak bağlantı noktası (OBN)'de bulunan üç-fazlı dağıtım transformatörü ile şebekeye

bağlantısı sağlanmaktadır. OBN’de bulunan üç-fazlı dağıtım transformatöre ait parametreler Tablo 4.1’de gösterilmiştir. Test sisteminde kullanılan dağıtık enerji üretim kaynakları; DEÜK 1 (FV panel), DEÜK 2 (rüzgâr türbini sistemi) ve DEÜK 3 (batarya enerji depolama sistemi). Tablo 4.2’de test sisteminde kullanılan dağıtık enerji üretim kaynaklarına ait üretim kapasiteleri verilmiştir.

Tablo 4.3’te test sistemi modelinde kullanılan yük çeşitleri ve parametreleri gösterilmiştir. Tablo 4.4’te güç dağıtım sistem modelinde kullanılan hat parametreleri verilmiştir.

Tablo 4.2. Dağıtık enerji üretim kaynaklarının kapasiteleri.

Parametre	Değer
DEÜK 1	100 kW
DEÜK 2	25 kW
DEÜK 3	40 kW

Tablo 4.3. Yük parametreleri.

Parametre	Değer
YÜK 1	50 kW
YÜK 2	20 kW
YÜK 3	40 kW+j20kVar
YÜK 4	20kW

Tablo 4.4. Hat parametreleri.

Parametre	Değer
Hat direnci	0.2551 (ohm/km)
Hat reaktansı	0.0331 (ohm/km)
Hat uzunluğu	100 m

4.1. Yenilenebilir Dağıtık Enerji Üretim Kaynaklarının Modellenmesi

Bu test sisteminde kullanılan yenilenebilir dağıtık enerji üretim kaynakları hakkında detaylı bilgilendirme aşağıdaki alt bölümlerde sunulmuştur.

4.1.1. Fotovoltaik panel modeli

Genel olarak, tipik bir fotovoltaik (FV) hücresinin güç çıkışı, 0.5 V çıkış geriliminde 2 W'tan azdır. Bu nedenle, FV hücreleri, yeterince yüksek çıkış gücü ve gerilimi üretmek için bir seri-paralel konfigürasyon modülünde bağlanır. FV sistemler için FV dizisi, elektriksel olarak seri ve paralel olarak bağlanmış birkaç FV modül grubudur [189].

Tablo 4.5. Güneş paneli karakteristikleri.

Parametre	Değer
Açık devre gerilimi/modül	64.2 V
Kısa devre akımı/modül	5.96 A
Gerilime ait maksimum çalışma noktası	54.7 V
Akıma ait maksimum çalışma noktası	5.58 A
Dizi başına bağlı seri modül sayısı	5
Paralel dizi sayısı	66

Fotovoltaik sistemdeki güneş pilinin bağlantısı seri ve paralel şeklindedir. Bir diyot, iki direnç ve bir akım kaynağından oluşan devre şeması, bir güneş pilinin tek diyot paradigmasını modellemektedir.

FV panelin üretilen gücü ve verimliliği iki ana hususa bağlıdır: güneş ışınımı ve çalışma sıcaklığı. Bu nedenle, FV çıkış gücü ve elektrik verimliliği denklemler (4.1, 4.2, 4.3, 4.4 ve 4.5) ile araştırılmaktadır [190].

Bu çalışmada nominal boyutu 305 W olan monokristal silikon malzemeden yapılmış FV panel modeli kullanılmıştır. Bu kullanılan FV panel modeli için detaylandırılmış parametre değerleri Tablo 4.5'te verilmiştir [191].

Fotoakım I_{ph} , kısa devre akımı I_{sc} 'nin bir fonksiyonu olarak belirlenir; kısa devre sıcaklık katsayısı, K_i ; hücre sıcaklığı, T_p ; hücre referans sıcaklığı, T_{ref} ; ve fotodiyot üzerine düşen güneş ışınımı, G parametrelerine bağlı bir fonksiyon olarak modellenir (4.1).

$$I_{ph} = \frac{G[I_{sc} + K_i(T_p - T_{ref})]}{1000} \quad (4.1)$$

Diyot doyma akımı, I_0 , denklem 4.2'de gösterildiği gibi ters doyma akımının, I_{rs} bir fonksiyonudur; hücre sıcaklığı, T_p ; ve referans sıcaklığı, T_{ref} ; elektron yükü sabiti, q ; yarı iletken bant aralığı enerjisi, E_{g0} ; diyot idealite faktörü, n ; ve Boltzmann sabiti, K_b parametrelere bağlı olarak değişmektedir.

$$I_0 = I_{rs} \left(\frac{T_p}{T_{ref}} \right)^3 e^{\left(\frac{qE_{g0} \left(\frac{1}{T_{ref}} - \frac{1}{T_p} \right)}{nK_b} \right)} \quad (4.2)$$

Ters doyma akımı I_{rs} , 4.3'te gösterildiği gibi, kısa devre akımı I_{sc} elektron yükü sabiti, q ; açık devre gerilimi, V_{oc} ; diyot idealite faktörü, seri bağlantıdaki hücre sayısı, N_s ; Boltzmann sabiti; ve hücre sıcaklığı parametreleri ile hesaplanmaktadır.

$$I_{rs} = \frac{I_{sc}}{e^{\left(\frac{qV_{oc}}{nN_sK_bT_p} \right)} - 1} \quad (4.3)$$

Şönt direncinden geçen akım, I_{sh} , denklem 4.4'te görüldüğü üzere yükün maruz kaldığı gerilim, V ; yük akımı, I ; seri direnç, R_s ; ve şönt direnci, R_{sh} parametrelerinden belirlenmektedir.

$$I_{sh} = \frac{V + IR_s}{R_{sh}} \quad (4.4)$$

Son olarak, çıkış akımı I , denklem 4.5'te görüldüğü gibi fotoakımı, doygunluk akımı, elektron yük sabiti, yük gerilimi, çıkış akımı, seri direnci, diyot faktörü, Boltzmann sabiti, seri modül sayısı, hücre sıcaklığı ve şönt akımı parametrelerine bağlı olarak hesaplanmaktadır.

$$I = I_{ph} - I_0 \left[e^{\left(\frac{q(V+IR_s)}{nN_sK_bT_p} \right)} - 1 \right] - I_{sh} \quad (4.5)$$

4.1.2. Rüzgâr türbini sistemi

Rüzgâr türbini, rüzgâr enerjisinden daha fazla gücü yüksek verimlilik, düşük maliyetle ve işletme maliyetiyle dönüştürmek için göbek yüksekliği, rotor çapı ve jeneratör boyutu açısından dağıtık enerji üretim sistemlerinde en yaygın kullanılan kaynaklardan biridir. Rüzgâr türbini jeneratörünün güç çıkışı, rüzgâr hızı değişimlerine bağlı olarak her zaman dalgalanır ve güç çıkışının nominal kapasitesini aşmasına izin verilmez. Bu nedenle, kanat açısı kontrolörü, izin verilen hız sınırını aşmayacak şekilde rüzgâr türbininin rotor hızını korumak için çalışır. Rüzgâr enerjisinin elektrik enerjisine dönüşümünde ana kontrol amaçları; maksimum güç çekimi ve şebekenin ihtiyacına bağlı olarak istenilen güç faktöründe reaktif güç kontrolünün gerçekleştirilmesidir [192, 193].

Rüzgâr tarafından çekilen gerçek mekanik güç denklem 4.6 ile belirtilmiştir:

$$P_w = 0.5\rho\pi R^2 V_w^3 C_p(\lambda, \beta) \quad (4.6)$$

Burada; P_w rüzgâr türbininin çıkış gücü, ρ hava yoğunluğu, R rüzgâr türbininin kanat yarıçapı, V_w rüzgâr hızı, C_p rüzgâr gücü katsayısıdır.

$$C_p(\lambda, \beta) = c_1 \left(\frac{c_2}{\lambda_i} - c_3\beta - c_4 \right) e^{\frac{-c_5}{\lambda_i}} + c_6\lambda \quad (4.7)$$

$$\frac{1}{\lambda_i} = \frac{1}{\lambda + 0.08\beta} - \frac{0.035}{1 + \beta^3} \quad (4.8)$$

Denklem 4.7'de C_p olarak gösterilen rüzgâr gücü dönüşüm katsayısı; uç hızı oranının λ ve kanat açısının β doğrusal olmayan bir fonksiyonudur. Denklemler (4.7 ve 4.8), rüzgâr türbini karakteristiğini göstermektedir. Denklem 4.7'de c_1, c_2, c_3, c_4, c_5 ve c_6 olarak gösterilen rüzgâr türbininin karakteristik katsayılarının değerleri sırasıyla 0.5176, 116, 0.4, 5, 21 ve 0.0068'dir ve ω_r , rüzgâr türbininin rotor hızıdır (rad/s) [192].

Uç hızı oranı λ denklem 4.9'daki gibi tanımlanabilir:

$$\lambda = \frac{\omega_r x R}{V_w} \quad (4.9)$$

MPPT kontrol stratejisi genellikle rüzgardaki maksimum gücün elde edilmesini ve nominal değerinin altındaki herhangi bir rüzgâr hızı için rüzgâr türbininin dönüş hızını ayarlayarak jeneratörün optimum hızda çalıştırılmasını sağlamaktadır.

8,1'lik optimum uç hızı oranı (λ_{opt}) ve 0,48'lik optimum güç katsayısı (C_{popt}), rüzgâr hızı 12 m/s'lik bir nominal hızda olduğunda elde edilir.

Tablo 4.6. Rüzgâr türbini karakteristikleri.

Parametre	Değer
Kutup sayısı	10
Rüzgâr hızı	12 m/s
Kanat yarıçapı	4 m
Optimum güç katsayısı	0.48
Optimum uç hız oranı	8.1

Maksimum Güç Noktası İzleme (MPPT) aracılığıyla rüzgâr türbini güç çıkışı denklem 4.10'daki gibi hesaplanır:

$$P_{mppt} = 0.5\rho\pi R^2 \left(\frac{\omega_r R}{\lambda_{opt}} \right)^3 C_{popt} \quad (4.10)$$

Tek parça kütleli modelde aktarma sürücü modeli denklem 4.11 ile ifade edilir.

$$T_m = T_e + J_{eq} \frac{d\omega_r}{dt} + B_m \omega_r \quad (4.11)$$

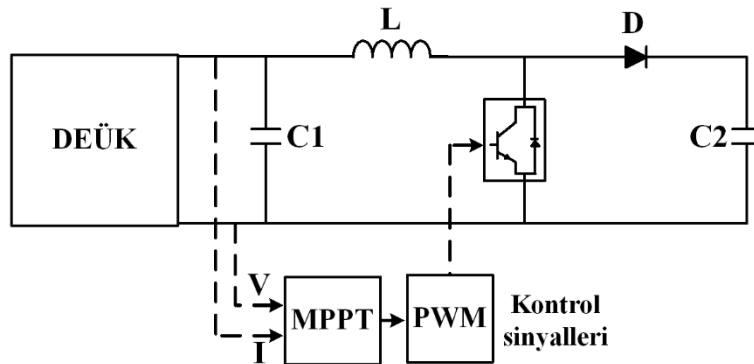
burada T_m , rüzgâr türbini mekanik torkudur (Nm), T_e , jeneratörün elektrik torkudur (Nm), J_{eq} , rüzgâr türbini jeneratörünün eşdeğer dönme eylemsizliğidir (kg.m^2) ve B_m , sönümleme katsayısıdır (Nm/s). Ek olarak, rüzgâr türbini sisteminin korunmasını ve güvenliğini garanti etmek, gücü nominal değerde tutmak ve kanatların eğim açısını rüzgâr hızına göre ayarlamak için genellikle eğim açısı kontrolü adı verilen bir yöntem kullanılır [193].

4.2. Dağıtık Enerji Üretim Kaynaklarına İlişkin Kontrol Modelleri

Bu bölümde ilk olarak yenilenebilir dağıtık enerji üretim kaynaklarının DC-DC yükseltici (boost) dönüştürücü kontrol modeli sunulacaktır. Daha sonraki bölümlerde de dağıtık enerji üretim kaynaklarının şebekeye entegrasyonunu sağlamak için gerekli DC-AC eviriciye ait kontrol modeli sunulacaktır.

4.2.1. Yenilenebilir dağıtık enerji üretim kaynaklarının DC-DC dönüştürücü kontrol modeli

Test modelinde kullanılan fotovoltaik panel ve rüzgâr türbini modellerinde giriş gerilim seviyesini istenilen çıkış gerilim seviyesine yükseltmek için şekil 4.2'de gösterildiği gibi DC-DC yükseltici dönüştürücü model kullanılmıştır. DC-DC dönüştürücü model, MPPT kontrolör kullanılarak çalıştırılır.



Şekil 4.2. Dağıtık enerji üretim kaynaklarına ait DC-DC dönüştürücü modeli.

Değişen ortam koşullarında MPPT ile yenilenebilir enerji kaynaklarının optimum çalışma noktasında çalıştırılması sağlanır. İstenilen çıkış geriliminin elde edilmesinin

yanı sıra FV panelden ya da rüzgâr türbininden maksimum güç elde edilmesi sağlanır. Böylece DC-DC dönüştürücülerde MPPT kullanılarak yenilenebilir DEÜK'lerin verimliliği ve performansının artması sağlanabilir [193].

4.2.2. Batarya DC-AC evirici kontrol modeli

Dağıtık enerji üretim kaynaklarının şebeke bağlantısı gerilim kaynaklı dönüştürücüler sayesinde gerçekleştirilmektedir. Gerilim kaynaklı dönüştürücüler üç faz bağlantısına sahip oldukları için her bir faz akımının birbirinden bağımsız şekilde kontrol edilmesi gerekir. Her bir faz akımını ayrı ayrı kontrol etmek yerine DC karakteristiğe sahip bileşenler üzerinden kontrol etmek kontrol açısından kolaylık sağlamaktadır [130, 194]. Bu bağlamda kontrol aşamasında ilk olarak üç faz akım sinyallerine park dönüşümü uygulanır. Aktif ve reaktif güç kontrolünü gerçekleştirmek için gerekli kontrol modeline ait formülasyon aşağıda verilmiştir (4.12, 4.13, 4.14, 4.15, 4.16, 4.17):

Denklemler 4.12 ve 4.13 üç faz akım ve gerilim sinyallerinin döner referans eksenlerindeki karşılığını göstermektedir.

$$\begin{bmatrix} V_d \\ V_q \\ V_0 \end{bmatrix} = \frac{2}{3} \begin{bmatrix} \cos \theta & \cos\left(\theta - \frac{2\pi}{3}\right) & \cos\left(\theta + \frac{2\pi}{3}\right) \\ -\sin(\theta) & -\sin\left(\theta - \frac{2\pi}{3}\right) & -\sin\left(\theta + \frac{2\pi}{3}\right) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} V_a \\ V_b \\ V_c \end{bmatrix} \quad (4.12)$$

$$\begin{bmatrix} i_d \\ i_q \\ i_0 \end{bmatrix} = \frac{2}{3} \begin{bmatrix} \cos \theta & \cos\left(\theta - \frac{2\pi}{3}\right) & \cos\left(\theta + \frac{2\pi}{3}\right) \\ -\sin(\theta) & -\sin\left(\theta - \frac{2\pi}{3}\right) & -\sin\left(\theta + \frac{2\pi}{3}\right) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} \quad (4.13)$$

$$P = \frac{3}{2}(V_d I_d + V_q I_q) \quad (4.14)$$

$$Q = \frac{3}{2}(V_q I_d - V_d I_q) \quad (4.15)$$

Denklem 4.14 ve 4.15 döner referans eksenindeki ortalanan aktif ve reaktif gücü göstermektedir.

$$P_{ref} = \frac{3}{2}V_d I_{dref} \quad (4.16)$$

$$Q_{ref} = -\frac{3}{2}V_d I_{qref} \quad (4.17)$$

Denklemler (4.14 ve 4.15), faz kilitlemeli çevriminde (PLL) V_q sıfır değerinde sabit şekilde tutulması sağlanarak denklemler (4.16 ve 4.17) durumuna dönüşmektedir. PLL kullanılarak şebeke akımına ait referans sinyalinin şebeke gerilimi ile aynı fazda olması sağlanmaktadır [195].

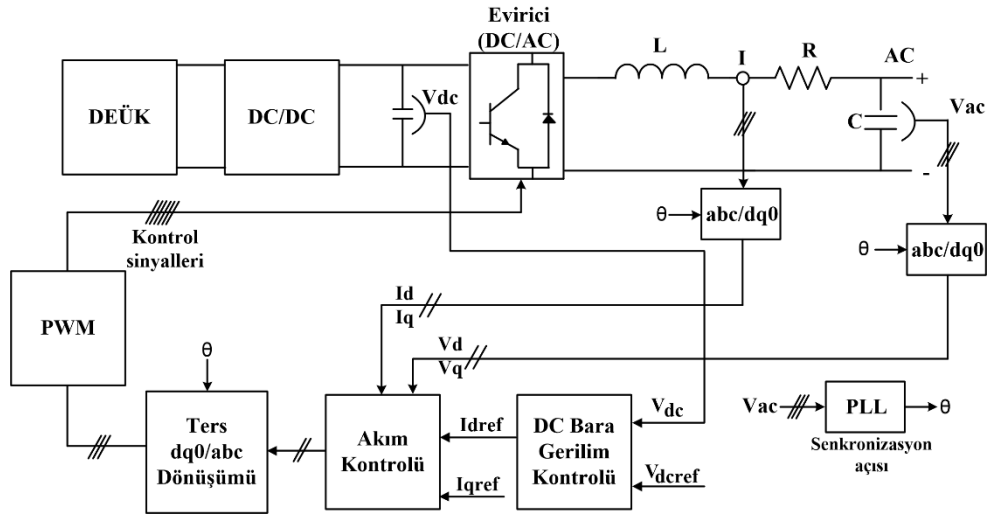
(4.16 ve 4.17)'deki sadeleştirilmiş (P_{ref} , Q_{ref}) eşitliklerinden elde edilen d ve q eksenlerindeki (I_{dref} , I_{qref}) referans parametrelerini ve evirici çıkışından ölçülen üç fazlı akım sinyallerinin d ve q eksenlerdeki karşılıkları olan I_d , I_q parametrelerini iki ayrı PI (Proportional Integral) kontrolörde kullanılarak d ve q eksenlerindeki akım kontrolü gerçekleştirilir. Bu PI kontrolör çıkışlarından evirici için gerilim referansı üretilir.

Eviricinin daha iyi bir dinamik cevabı olması için evirici çıkışındaki üç fazlı gerilim sinyallerine ait V_d ve V_q parametreleri ileri beslemeli (feedforward) olarak işleme katılır. Evirici çıkışındaki gerilim bozucu olarak varsayılır, böylece ileri beslemeli işlem adımı, bozucuların kompanze edilmesini sağlamaktadır [195].

4.2.3. Yenilenebilir dağıtık enerji üretim kaynaklarının DC-AC evirici kontrol modeli

Bu bölümde, yenilenebilir DEÜK'lerin şebeke tarafındaki kontrol modeli sunulacaktır.

FV panel ya da rüzgâr türbini gibi yenilenebilir DEÜK'lerin şebekeye bağlantısı iki kısımdan oluşmaktadır: Şekil 4.3 görüldüğü gibi dış çevrim kontrolü olarak bilinen DC bara gerilim ve iç çevrim kontrolü olarak bilinen akım kontrolleridir. Bu iki kontrolörün uygulanması ile evirici girişindeki DC bara bağlantısındaki gerilim seviyesi, DEÜK'ler tarafından üretilen çıkış akımı ve gücü kontrol edilmektedir. Aynı zamanda, eviricilerin birim güç faktöründe çalıştırılması sağlanmaktadır [194, 195].



Şekil 4.3. Yenilenebilir DEÜK'lere ait evirici kontrol modeli.

4.3. Arızalı ve Arızalı Olmayan Olası Senaryoların Oluşturulması

Bu bölümde, DEÜK'lerden oluşan güç dağıtım sistem modelinde arızalı ve arızalı olmayan senaryoların oluşturulması yer almaktadır. Olası arızalı senaryolar; FV ışınım, arıza açısı, arıza yeri ve 11 farklı arıza türlerinden (10'u kısa devre arızası durumları ve 1'i arızasız durum) oluşmaktadır.

FV ışınım değerleri (W/m^2); 600, 800 ve 1000. Arıza başlangıç açı değerleri ($^{\circ}$); 0, 45, 90 ve 180. Arıza empedans değerleri (ohm); 0.01, 0.5 ve 2. Arıza yerleri; FL1, FL2, FL3 ve FL4. Arıza yerlerinin seçimi; Brearley ve ark. tarafından yapılan çalışmadan faydalanarak DEÜK'lerden oluşan güç dağıtım sistemindeki başlıca koruma yapılacak elemanlar DEÜK, hat, OBN ve yük olarak belirtilmiştir [92]. Bu bilgiler ışığında, Şekil 4.1'deki test sisteminde FL olarak gösterilen 4 farklı arıza lokasyonu seçilmiştir.

Tablo 4.7'de görüldüğü gibi her bir arıza türü için toplamda 144 farklı arıza senaryosu oluşturulmuştur. Diğer yandan 144 farklı arızalı olmayan olası senaryolar; Tablo 4.8'de görüldüğü üzere, 1.senaryoda farklı FV ışınımlarıyla ilişkili yük baralarındaki ani yük değişiklikleri ve 2. senaryoda ise farklı FV ışınımlarıyla ilişkili yük baralarında ve OBN'de kapasitör kapanması olaylarından oluşmaktadır.

Tablo 4.7. Olası arızalı senaryolar [128].

Arıza türü		FV ışınlım (W/m ²)	Arıza empedansı (ohm)	Arıza açısı (°)	Arıza yeri	Sayı
TFTA	AG	600, 800 ve 1000	0.01, 0.5 ve 2	0, 45,90 ve 180	FL1, FL2, FL3 ve FL4	144
	BG					144
	CG					144
FFA	AB					144
	BC					144
	CA					144
FFTA	ABG					144
	BCG					144
	CAG					144
FFFTA	ABCG					144
TOPLAM		3	3	4	4	1440

Tablo 4.8. Olası arızalı olmayan senaryolar [128].


Senaryo	Sayı
1. Senaryo Farklı FV panel ışınlımlarıyla ilişkili yük baralarındaki ani yük değişiklikleri	
2. Senaryo Farklı FV panel ışınlımlarıyla ilişkili yük baralarında ve OBN'de kapasitör kapanması	
Toplam	144

4.4. Arızalı ve Arızalı Olmayan Verilerin Gürültülü Şekilde Elde Edilmesi


Bir sonraki bölümde ele alınacak sınıflandırma modelinin verimliliğini doğrulamak amacıyla 20 dB, 30 dB ve 40 dB sinyal-gürültü oranı (SNR) seviyelerinde toplamsal beyaz Gauss gürültüsünün (AWGN) orijinal veri setine katkılanırılması bu bölümde gerçekleştirilmiştir. Bunun için gerekli formülasyon 4.18’de gösterilmiştir.

AB iki faz arızası durumunda üç fazlı akım sinyallerine ait (a) Normal (gürültüsüz), (b) SNR 40 dB, (c) SNR 30 dB ve (d) SNR 20 dB görünümü sırasıyla şekil (4.4, 4.5, 4.6 ve 4.7)’de verilmiştir. Şekil (4.5, 4.6, 4.7)’den görüleceği üzere üç fazlı akım sinyallerindeki gürültü miktarları en düşükten yükseğe doğru; SNR 40 dB (Şekil 4.5), SNR 30 dB (Şekil 4.6), SNR 20 dB (Şekil 4.7) olarak yer almaktadır.


$$SNR = 10 \log_{10} P_{sig} - 10 \log_{10} P_{noise} \quad (4.18)$$




Şekil 4.4. Üç fazlı akım sinyallerinin normal (gürültüsüz) görünümü.



Şekil 4.5. Üç fazlı akım sinyallerinin SNR 40 dB gürültü seviyesindeki görünümü.



Şekil 4.6. Üç fazlı akım sinyallerinin SNR 30 dB gürültü seviyesindeki görünümü.



Şekil 4.7. Üç fazlı akım sinyallerinin SNR 20 dB gürültü seviyesindeki görünümü.

5. BULGULAR

Bu bölümde, arıza tespit ve sınıflandırması için önerilen olasılıksal ağırlıklı oylama modeli (OAOM)'nin, bu modeli oluşturan temel sınıflandırıcılarının ve literatürde yer alan oylama modellerinin performanslarını değerlendirmek için kapsamlı bir karşılaştırmalı performans analizi gerçekleştirilecektir.

Arıza tespit ve sınıflandırması için kullanılan veri setlerinden farklı olarak uluslararası platformlarda kabul edilmiş farklı karakteristiğe sahip bilinen veri setleri kullanılarak önerilen oylama modelinin (OAOM) verimliliği incelenecektir. Son olarak literatürde yer alan dağıtık enerji üretim kaynaklarından oluşan güç sistemlerinde gerçekleştirilmiş arıza tespiti ve sınıflandırmasına yönelik çalışmalarda belirli özellikler kapsamında karşılaştırma yapılacaktır.

5.1. Sınıflandırma Sürecine Dair Değerlendirme Ölçütleri

Bu bölümde öğrenme modellerinin performans analizi için karışıklık matrisinden elde edilen değerlendirme ölçütleri detaylı olarak açıklanacaktır.

Tablo 5.1'de gösterilen karışıklık (Confusion) matrisi, bir sınıflandırıcının performansını görselleştirmek için kullanılır. Doğru ve yanlış sınıflandırmalara ilişkin gözlemler, $C(c_{ij})$ karışıklık matrisinde toplanır; burada c_{ij} , i . satır j . sütundaki tanımlanma sıklığını temsil eder. Karışıklık matrisinin boyutu, sınıf sayısına sahip bir kare matristir. Satırlar, hedef sınıfın etiketini temsil etmektedir; diğer yandan, sütunlar ise tahmin sınıfının etiketini temsil etmektedir. Sınıflandırıcının ilgili asıl hedef sınıfına ait performansını değerlendirmede kullanmak için karışıklık matrisinden elde edilen dört tip sınıflandırma sonucu bulunmaktadır:

- TP ; model tarafından doğru şekilde tahmin edilen doğru (pozitif) sınıf sayısı
- TN ; model tarafından doğru şekilde tahmin edilen yanlış (negatif) sınıf sayısı
- FP ; model tarafından yanlış şekilde tahmin edilen doğru (pozitif) sınıf sayısı
- FN ; model tarafından yanlış şekilde tahmin edilen yanlış (negatif) sınıf sayısı

Tablo 5.1. Karışıklık matrisi gösterimi.

	Pozitif (tahmin)	Negatif (tahmin)
Pozitif (gerçek)	TP	FN
Negatif (gerçek)	FP	TN

Yukarıda elde edilen bu dört tip sınıflandırma sonuçlarını kullanarak aşağıdaki değerlendirme ölçütleri elde edilmiştir.

Doğruluk: Bu ölçüt, sınıflandırıcının ne sıklıkla doğru tahmin yaptığını ölçmektedir. Doğruluk ölçütü denklem 5.1 ile hesaplanmaktadır.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (5.1)$$

Duyarlılık (Doğru pozitiflerin oranı): Gerçek sınıf değeri “pozitif” olarak gösterilen etiketlerin kaç tanesinin “pozitif” olarak tahmin edildiğini gösteren ölçüttür. Duyarlılık ölçütü denklem 5.2 ile hesaplanmaktadır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (5.2)$$

Kesinlik: “Pozitif” olarak tahmin edilen etiketlerin gerçek sınıf değeri “pozitif” olan etiketler içerisindeki başarısını gösteren ölçüttür. Kesinlik ölçütü denklem 5.3 ile hesaplanmaktadır.

$$Kesinlik = \frac{TP}{TP + FP} \quad (5.3)$$

AUC: Bu ölçüt ayrılabilirlik derecesini temsil eden eğrinin altındaki alandır ve makine öğrenimi algoritmalarını değerlendirmek için kullanılan önemli bir ölçüttür [196]. AUC ölçütü denklem 5.4 ile hesaplanmaktadır.

$$AUC = 0.5 \times \left(\frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right) \quad (5.4)$$

MCC: Dengesiz veri setlerinde en uygun sınıflandırıcıyı belirlemek için kullanılan uygun bir ölçüttür [196]. MCC ölçütü denklem 5.5 ile hesaplanmaktadır.

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP) \times (TP + FN) \times (TN + FP) \times (TN + FN)}} \quad (5.5)$$

5.2. Arıza Tespiti ve Sınıflandırmasına İlişkin Ön Hazırlık

Bu bölümde önceki bölümlerde elde edilen arızalı/arızasız özellik setlerinin birleştirilmesi sonucunda oluşan veri setlerine normalizasyon işleminin uygulanması ele alınacaktır.

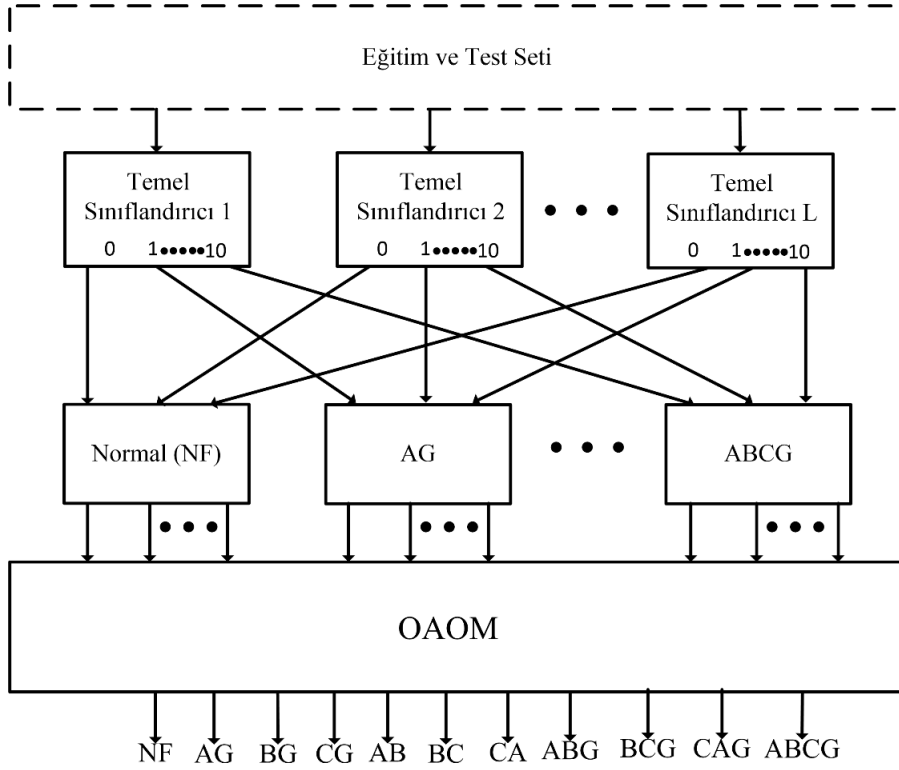
Arızalı/arızalı olmayan verilere ait özellik setlerinin birleştirilmesi sonucu (24x1584) boyutunda özellik seti elde edilmektedir. Daha sonra makine öğrenme modeli veri setini daha iyi anlamasına kolaylık sağlamak için özellik setine denklem 5.6 aracılığıyla normalizasyon işlemi uygulanır.

$$x' = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (5.6)$$

Normalizasyon işleminden sonra her bir özellik etiketinin ilgili arızalı ve arızalı olmayan verileri kapsayacak şekilde 0-1 aralığında olması sağlanır. Daha sonra veri seti rastgele (shuffle/random) şekilde karıştırılır. Böylece aynı sınıf etiketlerine ait özellik setlerinin ard arda öğrenme modeline giriş olarak gelmesi önlenmektedir. Aynı zamanda modelin genelleme kabiliyetine katkıda bulunmuş olunur.

Öğrenici modellerin daha önce sunulmamış veri setleri karşısında performansını daha iyi görebilmek için veri seti eğitim ve test seti olarak % 70 - % 30 oranında ayrıştırılır. Veri seti bölündükten sonra eğitim seti K-katlı çapraz doğrulanma ile her bir K. eğitim kümesi L adet sınıflandırıcının eğitimi için sunulur. Eğitim aşamasında uygulanan çapraz doğrulama yöntemi ile her bir modele ait doğrulama (validation) aşaması da gerçekleştirilir.

Eğitim ve doğrulama aşamalarından sonra test setindeki her bir test örneği için sınıf etiketlerine karşılık gelen olasılıksal dağılımlar elde edilir. Şekil 5.1'de görüldüğü üzere olasılıksal dağılımları ve eğitim aşamasından elde edilen sınıf etiketlerine bağlı olarak elde edilmiş ağırlık seçimleri kullanılarak oluşturulmuş ağırlıklandırılmış katsayılar ile sınıf etiketlerinin nihai tahmin durumları belirlenir [128].



Şekil 5.1. Arıza tespiti ve sınıflandırması için önerilen model diyagramı.

5.3. Arıza Tespiti ve Sınıflandırmasına Yönelik Performans Analizi

Bu bölümde arıza tespit ve sınıflandırmasına yönelik normal ve gürültülü veri setleri altında önerilen oylama modelinin (OAOM), bu modeli oluşturan temel öğrencilerin ve oylama modellerinin performansları kapsamlı şekilde analiz yapılacaktır. Bu gerçekleştirilen analizler; tahmin edebilme gücünü ya da genelleme kabiliyetini doğrulamak için 70-30, 60-40 ve 50-50 gibi farklı oranlara bölünmüş eğitim-test veri setlerinin kullanılması, ATSP’de yer alan sınıf etiketlerinin performanslarının detaylı şekilde incelenmesi, farklı sayıdaki temel öğrenciler kullanılarak OAOM’nin performans analizi, farklı ayırıştırma seviyelerinden elde edilen ayrı ayrı özellik setlerinin kullanılması, ve son olarak oylama modelleri arasında istatistiksel analizinin gerçekleştirilmesidir.


5.3.1. Önerilen OAOM’nin gürültülü veriler altında temel sınıflandırıcılar ile karşılaştırılması

Önerilen oylama modelinde kullanılan temel öğrenci/sınıflandırıcı modellerin (Rastgele orman (RF), ekstra ağaç sınıflandırıcı (ETC), çok katmanlı algılayıcı (MLP) ve destek vektör makineleri (SVM)) etkinliğini/verimliliğini göstermek için gürültülü

veri seti kümeleri (SNR 20 dB, SNR 30 dB ve SNR 40 dB) oluşturulur ve normalizasyon işlemi uygulanır.

Normal eğitim seti (gürültüsüz), (toplam 1584 veri setinin 70 %'ine tekabül etmektedir) OAOM içerisinde yer alan temel öğrencilerin eğitiminde, geri kalan veri seti (toplam 1584 veri setinin 30 %'ine tekabül etmektedir) test aşamasında kullanılır. Bu test seti ilk olarak gürültüsüz veri seti ile gerçekleştirilir daha sonra ise sırasıyla SNR 40 dB, SNR 30 dB ve SNR 20 dB oranında katkılanmış gürültülü veriler ile gerçekleştirilir. Kullanılan değerlendirme ölçütleri; Doğruluk, Duyarlılık, Kesinlik, Fskor ve AUC. Tablo 5.2'de görüldüğü gibi OAOM modelini oluşturan temel öğrenciler ile OAOM'yi birbirleri ile karşılaştırmalı şekilde hazırlanmış performans analizleri sergilenmiştir [128]. Tablo 5.2'deki önerilen OAOM'nin ve temel öğrencilerin bazı ölçütler (Doğruluk, Kesinlik ve Fskor) açısından etkilerini daha net bir şekilde görebilmek için Şekil 5.2, Şekil 5.3 ve Şekil 5.4 oluşturulmuştur.


Tablo 5.2'de temel öğrencilerin ve OAOM'nin doğruluk ölçütüne göre performans analizleri şu şekilde ortaya çıkmaktadır. Gürültüsüz veriler altında RF, ETC, MLP, SVM ve OAOM doğruluk değerleri sırasıyla; 0.9558, 0.9642, 0.9516, 0.9811 ve 0.9937 olarak elde edilmiştir.




Şekil 5.2. Doğruluk ölçütü altında önerilen OAOM'nin temel sınıflandırıcılar ile karşılaştırılması.

Tablo 5.2. Önerilen OAOM'nin öğrenici modeller ile karşılaştırılması.

Model	Ölçüt	Normal	SNR 40 dB	SNR 30 dB	SNR 20 dB
RF	Doğruluk	0.9558	0.9432	0.9411	0.9305
	Duyarlılık	0.9560	0.9420	0.9401	0.9297
	Kesinlik	0.9567	0.9460	0.9425	0.9305
	Fskor	0.9561	0.9430	0.9407	0.9299
	AUC	0.9758	0.9682	0.9671	0.9614
ETC	Doğruluk	0.9642	0.9495	0.9495	0.9495
	Duyarlılık	0.9635	0.9482	0.9482	0.9482
	Kesinlik	0.9658	0.9521	0.9521	0.9521
	Fskor	0.9642	0.9490	0.9490	0.9490
	AUC	0.9800	0.9716	0.9716	0.9716
MLP	Doğruluk	0.9516	0.9453	0.9368	0.9242
	Duyarlılık	0.9504	0.9438	0.9356	0.9231
	Kesinlik	0.9572	0.9511	0.9409	0.9265
	Fskor	0.9518	0.9453	0.9369	0.9242
	AUC	0.9728	0.9691	0.9646	0.9577
SVM	Doğruluk	0.9811	0.9726	0.9726	0.9621
	Duyarlılık	0.9802	0.9714	0.9714	0.9606
	Kesinlik	0.9837	0.9756	0.9756	0.9654
	Fskor	0.9809	0.9723	0.9723	0.9615
	AUC	0.9891	0.9843	0.9843	0.9784
OAOM	Doğruluk	0.9937	0.9895	0.9853	0.9747
	Duyarlılık	0.9935	0.9892	0.9847	0.9742
	Kesinlik	0.9949	0.9911	0.9868	0.9760
	Fskor	0.9940	0.9898	0.9854	0.9748
	AUC	0.9964	0.9941	0.9916	0.9858



Şekil 5.3. Kesinlik ölçütü altında önerilen OAOM'nin temel sınıflandırıcılar ile karşılaştırılması.



Şekil 5.4. Fskor ölçütü altında önerilen OAOM'nin temel sınıflandırıcılar ile karşılaştırılması.

Normal veri seti, SNR 40 dB oranında gürültü ile katkılanması durumunda RF, ETC, MLP, SVM ve OAOM doğruluk değerleri sırasıyla; 0.9432, 0.9495, 0.9453, 0.9726 ve 0.9895 olarak elde edilmiştir.

Normal veri seti, SNR 30 dB oranında gürültü ile katkılanması durumunda RF, ETC, MLP, SVM ve OAOM doğruluk değerleri sırasıyla; 0.9411, 0.9495, 0.9368, 0.9726 ve 0.9853 olarak elde edilmiştir.

Normal veri seti, SNR 20 dB oranında gürültü ile katkılanması durumunda RF, ETC, MLP, SVM ve OAOM öğrenme modellerinin doğruluk değerleri sırasıyla; 0.9305, 0.9495, 0.9242, 0.9621 ve 0.9747 olarak elde edilmiştir.

Gürültüsüz ve gürültülü veriler altında önerilen OAOM'nin performansı/etkinliği temel öğrenici modellerden yüksek olduğu görülmektedir.

5.3.2. Gürültülü veriler altında önerilen OAOM'nin oylama modelleri ile karşılaştırılması

Bu bölümde önerilen OAOM yapısının ve literatürde yer alan oylama modellerinin farklı oranlardaki eğitim-test veri setlerine yönelik sınıflandırma performanslarının verimliliği araştırılacaktır. Bu çalışma için Tablo 5.3'te görüldüğü gibi 70-30, 60-40 ve 50-50 gibi farklı oranlarda bölünmüş eğitim-test veri setleri oluşturulmuştur [128]. Farklı eğitim-test seti oranları; normal, 20 dB, 30 dB ve 40 dB ATSP'lere uygulanmıştır.

Arabameri ve ark. optimal öğrenme modelini belirlemek için, farklı oranlarda bölünmüş eğitim-test setlerinin sınıflandırma performansları kullanılarak önceliklendirme (prioritization) yöntemi uygulamıştır [197]. Bu yöntemin geçerliliği, farklı oranlarda bölünmüş veri setlerinin her birinden elde edilen sınıflandırma doğruluklarının ortalama ve standart sapma (SS) değerleri ile analiz edilmiştir.

Tablo 5.3'teki verilerden yararlanarak farklı oranlardaki test setleri üzerinde oylama modellerinin gösterdiği genelleme kabiliyetini daha iyi bir şekilde görebilmek için Şekil 5.5, Şekil 5.6 ve Şekil 5.7 oluşturulmuştur. Şekil 5.5, Şekil 5.6 ve Şekil 5.7'de x ekseninde dört farklı veri seti grubu ve bu grupların her birinde oylama modelleri; olasılıklar toplamı (M1), olasılıklar çarpımı (M2), olasılıklar maksimumu (M3), olasılıklar minimumu (M4), çoğunluk (M5), ağırlıklı (M6) ve OAOM yer almaktadır


Tablo 5.3. OAOM'nin farklı oylama modelleri ile karşılaştırılması.

Oylama Modeli	Eğitim/Test Seti Oranı	Normal	40 dB	30 dB	20 dB	Performans Sıralaması
M1	70-30	0.9916	0.9768	0.9768	0.9726	
	60-40	0.9748	0.9621	0.9621	0.9574	
	50-50	0.9444	0.9356	0.9306	0.9293	
	Ortalama	0.9703	0.9582	0.9565	0.9531	5
	SS	0.0239	0.0208	0.0236	0.0219	
M2	70-30	0.9916	0.9789	0.9768	0.9726	
	60-40	0.9716	0.9606	0.9590	0.9543	
	50-50	0.9533	0.9432	0.9419	0.9394	
	Ortalama	0.9721	0.9609	0.9592	0.9554	3
	SS	0.0191	0.0178	0.0174	0.0166	
M3	70-30	0.9894	0.9789	0.9747	0.9642	
	60-40	0.9700	0.9574	0.9543	0.9495	
	50-50	0.9634	0.9520	0.9533	0.9407	
	Ortalama	0.9742	0.9627	0.9607	0.9514	2
	SS	0.0135	0.0142	0.0120	0.0118	
M4	70-30	0.9832	0.9726	0.9684	0.9621	
	60-40	0.9748	0.9621	0.9590	0.9543	
	50-50	0.9508	0.9419	0.9432	0.9331	
	Ortalama	0.9696	0.9588	0.9568	0.9498	6
	SS	0.0168	0.0156	0.0127	0.0150	

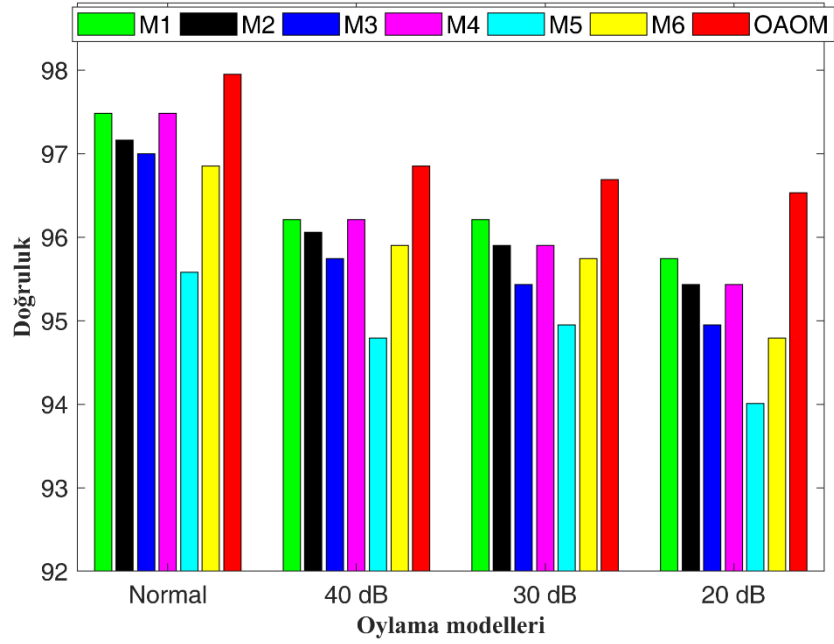
Tablo 5.3. (Devamı) OAOM'nin farklı oylama modelleri ile karşılaştırılması.

	70-30	0.9832	0.9726	0.9747	0.9663	
M5	60-40	0.9558	0.9479	0.9495	0.9401	
	50-50	0.9356	0.9280	0.9280	0.9230	
	Ortalama	0.9582	0.9495	0.9507	0.9431	7
	SS	0.0238	0.0223	0.0233	0.0218	
	70-30	0.9874	0.9789	0.9789	0.9684	
M6	60-40	0.9685	0.9590	0.9574	0.9479	
	50-50	0.9609	0.9533	0.9457	0.9331	
	Ortalama	0.9722	0.9637	0.9606	0.9498	4
	SS	0.0136	0.0134	0.0168	0.0177	
	70-30	0.9937	0.9895	0.9853	0.9747	
OAOM	60-40	0.9795	0.9685	0.9669	0.9653	
	50-50	0.9710	0.9634	0.9621	0.9508	
	Ortalama	0.9814	0.9738	0.9714	0.9636	1
	SS	0.0114	0.0138	0.0122	0.012	


Y ekseninde ise bu oylama modellerine ait gürültüsüz veri seti (Normal), SNR 40 dB, SNR 30 dB ve SNR 20 dB oranında katkılanmış gürültülü veriler ile test edilmesi sonucunda sahip oldukları performans sonuçları görülmektedir. Önerilen OAOM yapısı ve diğer oylama modellerinin performansı, sınıflandırma doğruluklarının ortalama ve standart sapma değerleri açısından analiz edilmiştir. Farklı oranlardaki bölünmeler ile hazırlanan veri setleri üzerinde OAOM ve diğer oylama modellerinin



Şekil 5.5. 70-30 oranında bölünmüş veri seti altında önerilen OAOM ve oylama modellerinin karşılaştırılması.



Şekil 5.6. 60-40 oranında bölünmüş veri seti altında önerilen OAOM ve oylama modellerinin karşılaştırılması.




Şekil 5.7. 50-50 oranında bölünmüş veri seti altında önerilen OAOM ve oylama modellerinin karşılaştırılması.

tahmin performansını doğrulamak amacıyla yukarıda bahsedilen önceliklendirme yöntemi için doğruluk ölçütü baz alınmıştır.

Önceliklendirme işlemi için ilk olarak ilgili oylama modellerinin farklı oranlardaki veri setlerine yönelik arıza tespiti ve sınıflandırmasındaki doğruluk performanslarının ortalaması alınmıştır. Bu durum gürültülü veri setleri içinde aynı şekilde yapılmıştır. Sonuç olarak 4 veri setine ait doğruluk performanslarının ortalama değerine bağlı olarak genel bir değerlendirme yapılmıştır. Bu değerlendirme sonucunda şekil 5.8'de görüldüğü üzere 97.26 % ile önerilen OAOM modeli ile en yüksek başarı oranına sahiptir. OAOM modelinden sonra sıralama 96.23 % ile olasılıklar maksimumu (M3), 96.19 % ile olasılıklar çarpımı (M2), 96.16 % ile ağırlıklı (M6), 95.95 % ile olasılıklar toplamı (M1), 95.87 % ile olasılıklar minimumu (M4) ve 95.03 % ile çoğunluk (M5) modelleri şeklinde olmuştur.

Şekil 5.8 incelendiğinde önerilen OAOM yapısının diğer oylama modellerine kıyasla daha üstün olduğu görülmektedir. Elde edilen sonuçlardan önerilen modelin (OAOM) literatürdeki oylama modellerinden daha optimum bir model olabileceği sonucuna ulaşılabilmektedir.



Şekil 5.8. Farklı oranlarda bölünmüş veri setleri üzerinde önerilen OAOM ve oylama modellerinin performans sıralaması.

5.3.3. Önerilen OAOM ile arızalı/arızalı olmayan durumlara ait normal ve gürültülü veri setleri için performans analizi

Bu bölümde, arıza tespit ve sınıflandırma probleminde yer alan her bir sınıf etiketine ait sınıflandırma performansları detaylı bir şekilde sunulacaktır. Arızalı sınıflara ek olarak arızanın olmadığı durum “arızasız” sınıf etiketi isminde arızalı etiketler içerisinde yer almıştır. Bu çalışmada, veri seti 2 etiketli (arıza var ve arıza yok) şeklinde hazırlamak yerine tüm arıza türlerini dikkate alarak toplamda 11 etiketli bir veri seti oluşturulmuştur. Sınıf etiketlerinin performans analizi; duyarlılık, kesinlik, Fskor ve doğruluk başarı ölçütleri kullanılarak gerçekleştirilmiştir.

Gerçekleştirilen bu analizde ilk olarak, Tablo 5.4 ‘den görüleceği üzere 4 farklı veri seti grubunda arızasız durumların 100 % olarak tespit edildiği ve ek olarak tek faz toprak ve üç faz toprak arızalarının 100 % doğruluk başarı oranı ile sınıflandırıldığı görülmektedir.

Bu çalışma ile ilgili diğer bir çıkarım ise, iki faz (AB, BC ve CA) ve iki faz toprak (ABG, BCG ve CAG) arızalarında daha çok yanlış sınıflandırma yapılan sınıf etiketleri olarak görülmektedir. Bu arıza türlerinin farklı veri setleri arasındaki sınıflandırma başarı oranı yüksekten düşüğe daha doğru sırasıyla Normal, SNR 40 dB, SNR 30 dB ve SNR 20 dB olarak yer aldığı görülmektedir. Değerlendirme ölçütü duyarlılık ile

Tablo 5.4. Her bir etiket için karşılaştırmalı performans analizi.

Etiket	Ölçüt	Normal	SNR 40 dB	SNR 30 dB	SNR 20 dB
Arızasız	Duyarlılık	1	1	1	1
	Kesinlik	1	1	1	1
	Fskor	1	1	1	1
	Doğruluk	1	1	1	1
AG	Duyarlılık	1	1	1	1
	Kesinlik	1	1	1	1
	Fskor	1	1	1	1
	Doğruluk	1	1	1	1
BG	Duyarlılık	1	1	1	1
	Kesinlik	1	1	1	1
	Fskor	1	1	1	1
	Doğruluk	1	1	1	1
CG	Duyarlılık	1	1	1	1
	Kesinlik	1	1	1	1
	Fskor	1	1	1	1
	Doğruluk	1	1	1	1
AB	Duyarlılık	1	1	1	0.9524
	Kesinlik	1	1	1	1
	Fskor	1	1	1	0.9756
	Doğruluk	1	1	1	0.9956
BC	Duyarlılık	1	0.9762	0.9762	0.9524
	Kesinlik	1	1	0.9535	0.9302
	Fskor	1	0.988	0.9647	0.9412
	Doğruluk	1	0.9979	0.9937	0.9895


Tablo 5.4. (Devamı) Her bir etiket için karşılaştırmalı performans analizi.

CA	Duyarlılık	1	1	1	0.98
	Kesinlik	0.9434	0.9259	0.9259	0.9245
	Fskor	0.9709	0.9615	0.9615	0.9514
	Doğruluk	0.9937	0.9916	0.9916	0.9895
ABG	Duyarlılık	1	1	1	1
	Kesinlik	1	1	1	0.9565
	Fskor	1	1	1	0.9778
	Doğruluk	1	1	1	0.9958
BCG	Duyarlılık	1	1	0.9512	0.9268
	Kesinlik	1	0.9762	0.975	0.95
	Fskor	1	0.988	0.9630	0.9383
	Doğruluk	1	0.9979	0.9937	0.9895
CAG	Duyarlılık	0.9286	0.9048	0.9048	0.9048
	Kesinlik	1	1	1	0.9473
	Fskor	0.9630	0.95	0.95	0.9383
	Doğruluk	0.9937	0.9916	0.9916	0.9895
ABCG	Duyarlılık	1	1	1	1
	Kesinlik	1	1	1	1
	Fskor	1	1	1	1
	Doğruluk	1	1	1	1

ilgili hedef sınıfındaki etiketlerin ne kadar doğru bir şekilde tahmin edildiği; diğer yandan kesinlik ölçütü ile hedef sınıfında olmayan sınıf etiketlerinin ne kadar doğru bir şekilde tahmin edildiği gösterilmektedir [128]. Değerlendirme ölçütleri arasındaki en dikkat çeken parametrenin Fskor olduğu ve bu ölçüt hem kesinlik hem de duyarlılık ölçütlerini barındırması açısından arıza türlerinin sınıflandırılması ile ilgili gerçek bir yorum yapılmasını sağlamaktadır.

5.3.4. Önerilen OAOM'nin üç ve dört temel sınıflandırıcıdan oluşma durumuna göre performans analizi

Bu bölümde farklı sayılardaki temel sınıflandırıcılardan oluşan önerilen OAOM yapısının performans analizi tartışılmıştır. Bu tez kapsamında 4 temel sınıflandırıcıdan oluşan OAOM ile ATSP'ye yönelik bir çalışma gerçekleştirilmiştir. Ancak önerilen OAOM yapısı 4 temel sınıflandırıcı değil de 3 temel sınıflandırıcı ile oluşması durumunda söz konusu ATSP üzerinde performans analizinin nasıl bir etki yapacağı araştırılmıştır. Şekil 5.9'da 4 temel sınıflandırıcı ile oluşturulan OAOM yapısının daha başarılı olduğu görülmüştür. Bu gerçekleştirilen çalışma ile sınıflandırıcı çeşitliliğinin oylama modelleri üzerindeki olumlu etkisi görülmektedir.



Şekil 5.9. Farklı sayılarda temel sınıflandırıcılardan oluşturulmuş OAOM yapılarının doğruluk performansı açısından karşılaştırılması.


MLP-RF-ETC ve MLP-RF-ETC-SVM karşılaştırmasından şu sonuç çıkmaktadır: en yüksek başarı ölçütüne sahip temel sınıflandırıcının dışarısında yer alan sınıflandırıcılar; en yüksek doğruluk performansına sahip sınıflandırıcının performansını yukarı doğru çekmeye çalışmaktadır.

5.3.5. Farklı sayıda özellik setleri ile hazırlanan eğitim ve test setlerinin önerilen oylama modeli (OAOM) üzerindeki performans analizi

Bu bölümde, db10 ana dalgacık ailesine bağlı olarak 9. ayrıştırma seviyesi (11th ve 13th harmonik bileşenleri) ve 10. ayrıştırma seviyesi (5th, 7th ve 9th harmonik bileşenleri)

için ayrı ayrı (12x1584) boyutunda yeni özellik setleri oluşturularak önerilen OAOM'nın performansı analiz edilecektir.

Ayrıştırma seviyesi 9 ve 10 durumları için ayrı ayrı oluşturulan özellik setlerinin sınıflandırma performansları orijinal durumdaki (9. ve 10. ayrıştırma seviyelerinin birlikte olması) gerçekleştirilen sınıflandırma performansı doğruluk açısından yaklaşık olarak aynı değerdedir. Ancak bu özellik setlerini 20 dB oranında gürültü ile katılanması durumunda gerçekleştirilen arıza tespit ve sınıflandırma performansı; ayrıştırma seviyesi 9 olma durumunun 10 olma durumuna göre daha yüksek değerde olduğu Şekil 5.10'da görülmektedir.



Şekil 5.10. Farklı ayrıştırma seviyelerinden oluşturulmuş özellik setlerine bağlı olarak OAOM yapısının doğruluk performansı açısından karşılaştırılması.

5.3.6. Arıza tespit ve sınıflandırmasına yönelik kullanılan oylama modellerinin istatistiksel analizi

Bu bölümde arıza tespit ve sınıflandırmasına yönelik kullanılan oylama modellerinin kabul edilebilirliğini belirlemek için istatistiksel analiz gerçekleştirilecektir.

Ortalama p-değerlerinin hesaplanmasıyla elde edilen bir istatistiksel testin gücü, sıfır hipotezinin reddedilme olasılığı ile ilgilidir (Demsar, 2006) [198]. Bunun için, birden çok sınıflandırıcının performansını çeşitli veri kümeleri üzerinden istatistiksel olarak karşılaştırmak için Friedman testi kullanılır.

p-değeri 0,05'ten küçükse, bu sıfır hipotezinin reddedilmesi anlamına gelir. Böylece, Friedman testi ile sınıflandırıcıların performanslarında önemli bir fark olduğu doğrulanmıştır [196]. Önerdiğimiz yöntem ile diğer oylama yöntemleri arasındaki anlamlı fark Finner post hoc testi ile doğruluk açısından istatistiksel olarak incelenmiştir.

Friedman testinin ortalama sıralama (OS) sonuçları, oylama modellerinin en düşük sıralamadan en yüksek sıralamaya doğru sıralandığını göstermektedir. Yani performans açısından en iyiden en kötüye doğru oylama modellerinin sıralanması Tablo 5.5'te görüldüğü gibi; OAOM, olasılıklar çarpımı (M2), olasılıklar toplamı (M1), ağırlıklı (M6), olasılıklar maksimumu (M3), olasılıklar minimumu (M4) ve son olarak çoğunluk (M5) modelidir [128]. Finner post hoc testleri, Tablo 5.5'te gösterildiği gibi, önerilen OAOM yapısı, ATSP'ye yönelik oylama modellerinden daha kabul edilebilir sonuçlar ürettiği doğrulanmıştır.

Tablo 5.5. Friedman ve Finner Post Testi.

Finner Post-Hoc Testi			
Oylama Modeli	OS	Düzeltilmiş-p	Sıfır Hipotezi
OAOM	1	-	-
M2	3.542	0.0039	Red
M1	3.875	0.0013	Red
M6	4.042	8,44e-4	Red
M3	4.125	7.898e-4	Red
M4	4.792	5,14e-5	Red
M5	6.625	1,08e-9	Red

5.4. Bilinen Veri Setleri ile Önerilen Oylama Modelinin Doğruluğunun Test Edilmesi

Önerilen OAOM yapısının verimliliği, UCI ve KEEL veri havuzu web sitelerinden alınan 4'ü çok sınıflı ve 2'si ikili olmak üzere toplamda 6 veri seti (VS) üzerinde değerlendirilmiştir [199, 200]. Tablo 5.6'da görüldüğü gibi, veri setlerinin özellikleri listelenmiştir. Satellite, Vehicle, Mammographic, Segmentation, Vowel ve Pima gibi ilgili veri kümeleri için karşılaştırmalı sonuçlar Tablo 5.7'de gösterilmektedir [128].

Oylama modellerinin performansları doğruluk, Kappa ve MCC açısından değerlendirilmiştir.

Fang ve ark. çalışmalarında öğrenme algoritmalarının uyumunu test etmek için istatistiksel bir ölçü olan Kappa terimini kullanılmıştır [201].

Boughorbel ve ark. dengesiz veri setlerinde optimal sınıflandırıcıyı belirlemek için MCC'nin uygun bir ölçüt olduğunu belirtmiştir [202].

Önerilen oylama modeli, literatürde yer alan oylama modellerinden daha iyi performans gösterdiği istatistiksel analizlerle de kanıtlanmıştır [128].

Modellerin performanslarının değerlendirilmesinde sınıflandırma doğruluğuna göre kappa ve MCC değerlerinin ayırt edici olduğu görülmektedir.

Tablo 5.6. Gerçek veri setleri.

Veri seti	Gözlem	Özellik	Sınıf
VS 1. Satellite	6435	36	6
VS 2. Vehicle	846	18	4
VS 3. Mammographic	830	5	2
VS 4. Segmentation	2310	19	7
VS 5. Vowel	990	13	11
VS 6. Pima	768	8	2

Tablo 5.7. Önerilen OAOM'nin farklı veri setlerindeki performans analizi.

Oylama Modeli	Ölçüt	VS 1	VS 2	VS 3	VS 4	VS 5	VS 6
M1	Doğruluk	0.917	0.8425	0.8353	0.9841	0.9848	0.7783
	MCC	0.8975	0.7898	0.6706	0.9815	0.9833	0.5155
	Kappa	0.8974	0.7895	0.6704	0.9815	0.9833	0.5115
M2	Doğruluk	0.9185	0.8464	0.8353	0.9841	0.9848	0.7739
	MCC	0.8994	0.7952	0.6706	0.9815	0.9833	0.5044
	Kappa	0.8992	0.7949	0.6704	0.9815	0.9833	0.4983
M3	Doğruluk	0.917	0.8543	0.8273	0.9841	0.9899	0.7826
	MCC	0.8975	0.8057	0.6546	0.9815	0.9889	0.5247
	Kappa	0.8974	0.8052	0.6545	0.9815	0.9888	0.5200
M4	Doğruluk	0.9175	0.8583	0.8273	0.9812	0.9899	0.7826
	MCC	0.8981	0.8108	0.6546	0.9781	0.9889	0.5247
	Kappa	0.8980	0.8107	0.6545	0.9781	0.9888	0.5200
M5	Doğruluk	0.9165	0.8228	0.8434	0.9798	0.9899	0.7696
	MCC	0.8970	0.7651	0.6881	0.9764	0.9889	0.4991
	Kappa	0.8968	0.7635	0.6870	0.9764	0.9888	0.4972
M6	Doğruluk	0.9135	0.7992	0.7751	0.9538	0.9747	0.7609
	MCC	0.8935	0.7444	0.5588	0.9466	0.9724	0.4744
	Kappa	0.8932	0.7305	0.5483	0.9461	0.9721	0.4437
OAOM	Doğruluk	0.921	0.8819	0.8715	0.9870	0.9949	0.7913
	MCC	0.9025	0.8425	0.7440	0.9848	0.9944	0.5434
	Kappa	0.9022	0.8421	0.7431	0.9848	0.9944	0.5369

5.5. Diğer Çalışmalarla Karşılaştırma

Bu bölümde önerilen OAOM'nin karakteristik özellikleri ve yukarıda elde edilen sonuçlar ile ilgili olarak diğer çalışmalarla karşılaştırma yapılacaktır.

İlk olarak ölçüm sinyalinin alındığı yer incelenmiştir. Tablo 5.8'de görüldüğü üzere çalışmaların hepsinde arızalı sinyaller arızanın olduğu hattan alındığı belirtilmiştir. Bu çalışmalarda kullanılan modellerin gürültülü veriler üzerindeki etkisi [111, 113-114] çalışmalarında incelenmiştir. Diğer bir parametre olarak sınıflandırma problemi için kullanılan veri setine ilişkin sınıf etiketi sayısı incelenmiştir.

Çeşitli arıza türlerinin sınıflandırılmasında [109, 111-112] çalışmalarında arızalı olmayan veriler dikkate alınmamış bunun yerine simetrik arıza olarak hem FFFTA hem de FFFA arızaları dikkate alınmıştır. Diğer bir parametre ise kullandıkları makine öğrenme modelinin genelleme kabiliyetini verimliliğini değerlendirmek için farklı oranlardaki 60-40 ve 50-50 gibi eğitim-test setleri [109-114] çalışmalarında ele alınmamıştır. Ayrıca, [109-114] çalışmalarında kullandıkları öğrenme modellerinin kabul edilebilirliğinin testi için istatistiksel analiz gerçekleştirilmemiştir.

Bu tez kapsamında önerilen OAOM yapısına sahip ATSS'de [109-114] çalışmalarından farklı şekilde hedefteki hattan arızalı ya da arızalı olmayan sinyalleri almak yerine tek bir noktadan OBN'den alınmıştır.

Diğer bir değerlendirme parametresi olarak farklı oranlardaki eğitim-test veri setleriyle önerilen makine öğrenme modeline ait genelleme yeteneğinin değerlendirilmesidir.

Ayrıca önerilen oylama modeli (OAOM) ve diğer oylama modellerinin arıza tespiti ve sınıflandırması problemine yönelik olarak istatistiksel analiz gerçekleştirilmesi ve son olarak önerilen modeli bilinen farklı veri setleri üzerindeki performansının incelenmesidir.

Kısıtlı performans kabiliyeti olan makine öğrenme modellerinin performansları, önerilen OAOM (99.37 %) ile arttığı önceki bölümlerde elde edilen sonuçlardan görülmüştür. Bu tez kapsamında ele alınan çalışmalar ve hedefler önerilen OAOM yapısının ve ATSS'nin öne çıkan özelliklerini ortaya koymaktadır.

Tablo 5.8. Farklı çalışmalarla karşılaştırma.

	[109]	[110]	[111]	[112]	[113]	[114]	Önerilen
<i>a</i>	ELM	CNN	ELM	SSML	MKELM	Adaboost	OAOM
<i>b</i>	Hedef	Hedef	Hedef	Hedef	Hedef	Hedef	OBN
<i>c</i>	Hayır	Hayır	Evet	Hayır	Evet	Evet	Evet
<i>d</i>	93.93 %	98.98 %	92.92 %	97.81 %	99.04 %	98.75 %	99.37 %
<i>e</i>	11	6	11	11	10	4	11
<i>f</i>	Hayır	Hayır	Hayır	Hayır	Hayır	Hayır	Evet
<i>g</i>	Hayır	Hayır	Hayır	Hayır	Hayır	Hayır	Evet

a : Yöntem
b : Ölçüm yeri
c : Gürültülü verilerin etkisi
d : Genel doğruluk
e : Sınıf etiket sayısı
f : Farklı oranlardaki eğitim-test veri setleri ile sınıflandırma modelinin performans analizi
g : İstatistiksel analiz

6. SONUÇLAR VE ÖNERİLER

Literatür çalışmasında çok sayıda koruma yöntemleri sunulmuş olup bunlarla ilgili avantaj ve dezavantajları vurgulanmıştır. Bu tez kapsamında DEÜK'lerin güç dağıtım sistemine entegrasyonu sonucu ortaya çıkan koruma sorunlarına yönelik koruma yöntemlerinden yapay zekâ destekli koruma yöntemi uygun bulunmuştur. Yapay zekâ destekli koruma yöntemlerinde, veri setlerinde veri sayısı fazlalığına rağmen belirli makine öğrenme modellerinin öğrenme kabiliyetlerindeki kısıtlılıktan dolayı sınırlı bir genelleme kabiliyetine sahiptir. Bu sorun ise sınıflandırıcıların tahmin edebilme gücüne (genelleme) ait zayıflığı göstermektedir. Önerdiğimiz sınıflandırma modeli ile sınırlı öğrenme kabiliyetine sahip sınıflandırıcıların öğrenme kapasitelerini üst seviyeye çıkarabilmenin yolları araştırılmıştır. Bu anlamda, klasik makine öğrenme modellerinin genelleme kabiliyetini artırmak için farklı temel sınıflandırıcılardan oluşan birleştirilmiş bir öğrenme modeli ortaya konulmuştur. Diğer çalışmalarda olduğu gibi klasik makine öğrenme modellerinin öğrenme hatalarını telafi edecek ve genelleme ve öğrenme kabiliyetlerini geliştirecek bir model yerine kısıtlı öğrenme yapısına sahip bu klasik modeller için farklı bir öğrenme yapısı önerilmiştir. Bu bağlamda çok çeşitli öğrenme modellerinden oluşan olasılıksal ağırlıklı oylama modeli (OAOM) ile bir arıza tespit ve sınıflandırma şeması (ATSS) sunulmuştur.

Arıza tespit ve sınıflandırmasına yönelik olarak önerilen OAOM'nin ve bu modeli oluşturan temel sınıflandırıcıların/öğrencilerin performanslarını değerlendirmek için kapsamlı bir karşılaştırmalı performans analizi gerçekleştirilmiştir. Önerilen OAOM ve bu modeli oluşturan temel öğrencilerin arıza tespit ve sınıflandırmasına yönelik performansları karşılaştırmalı olarak değerlendirilmiştir. ATSS bünyesinde önerilen OAOM yapısının farklı veri setleri (normal ve gürültülü veriler) üzerinde performansı klasik öğrenme modellerinden daha yüksektir.

Literatürde yer alan oylama tabanlı makine öğrenmesi modellerini ilgili arıza tespit ve sınıflandırmasında kullanarak önerilen OAOM'nin verimliliği değerlendirilmiştir. Hem normal hem de gürültülü veri setleri üzerinde incelenen oylama modelleri;

olasılıklar toplamı, olasılıklar çarpımı, olasılıklar maksimumu, olasılıklar minimumu, çoğunluk ve ağırlıklı olmak üzere 6 çeşittir.

OAOM'nın tahmin edebilme gücünü ya da genelleme kabiliyetini doğrulamak için ilgili arıza tespit ve sınıflandırma probleminin 70-30, 60-40, 50-50 gibi farklı oranlara bölünmüş eğitim-test veri setleri üzerinde kapsamlı bir analizi gerçekleştirilmiştir. Bu değerlendirme ile farklı orandaki test setleri üzerinde OAOM'nin diğer oylama modellerine karşılık genelleme kabiliyeti en yüksek olduğu görülmüştür. Farklı oranlarda bölünmüş eğitim-test veri setlerinden (normal ve gürültülü setler) elde edilen ortalama doğruluk başarı ölçütüne göre 97.26 % ile önerilen OAOM modeli ile en yüksek başarı oranına sahiptir. OAOM modelini sırasıyla 96.23 % ile olasılıklar maksimumu, 96.19 % ile olasılıklar çarpımı, 96.16 % ile ağırlıklı, 95.95 % ile olasılıklar toplamı, 95.87 % ile olasılıklar minimumu ve 95.03 % ile çoğunluk modelleri şeklinde sıralanmıştır. 70-30 oranında bölünmüş Normal veri seti ile test edilmesi durumunda OAOM ve OAOM'den sonra en yüksek başarı oranına sahip olan modellerinin (olasılıklar toplamı ve olasılıklar çarpımı) test başarı oranları sırasıyla 99.37 % ve 99.16 %. Ancak veri setlerinin gürültülü ve test seti oranın fazla olması durumlarında en yüksek iki oylama modeli 97.26 % ile OAOM ve 96.23 % ile olasılıklar maksimumu modelleri olmaktadır. Önerilen oylama modeli (OAOM) ve diğer modeller arasındaki doğruluk performansı açısından farkın arttığı gözlenmiştir.

Çalışmada farklı sayılardaki temel sınıflandırıcılardan oluşturulmuş önerilen OAOM yapılarının ATSS üzerinde doğruluk ölçütü açısından performans verimliliği araştırılmıştır. 4 sınıflandırıcıdan oluşan OAOM yapısının 3 sınıflandırıcıdan oluşan OAOM yapısından daha başarılı olduğu görülmüştür. Bu sayede topluluk öğrenme modelleri için sınıflandırıcı çeşitliliği kavramının önemi ortaya çıkmıştır. Dört temel sınıflandırıcı ile OAOM oluşturulması durumunda 99.37 % doğruluk başarı oranı edilmiştir diğer yandan üç temel sınıflandırıcı ile OAOM oluşturulması durumunda 98.95 % doğruluk başarı oranı edilmiştir. Topluluk içerisindeki öğrenme modellerinin sayısının artması ile OAOM modelinin başarı performansını arttığı görülmektedir.

Veri setleri oluşturulurken kullanılan özellik seti oluşturma aşamasının katkılarının anlaşılabilmesi amacıyla ana dalgacık ailesine bağlı olarak 9. ayrıştırma seviyesi (11th ve 13th harmonik bileşenleri) ve 10. ayrıştırma seviyesi (5th, 7th ve 9th harmonik bileşenleri) için ayrı ayrı yeni özellik setleri oluşturulmuş ve önerilen OAOM'nin performansı analiz edilmiştir. Burada normal (gürültüsüz) ve SNR 20 dB ile

katkılanmış gürültülü veri setleri OAOM yapısında test edilmiştir. Bu gerçekleştirilen analizde SNR 20 dB'deki verilerin sınıflandırılmasında, 9. ayırıştırma seviyesine ait özellik setinin 10. ayırıştırma seviyesindeki özellik setinden daha iyi başarı oranına sahip olduğu görülmüştür. (9. – 10.), 9. ve 10. ayırıştırma seviyelerine ait ayrı ayrı üç özellik setlerini 20 dB oranındaki gürültülü veriler ile test edilmesi durumunda elde edilen doğruluk başarı performansları; 97.47 %, 96.42 % ve 95.78 % olarak elde edilmiştir. Bu sonuçlardan 9. ayırıştırma seviyesinin kapsadığı 11th ve 13th harmonik bileşenlerine sahip özellik seti, 20 dB oranındaki gürültülü veriler ile testinde 10. ayırıştırma seviyesinden (5th, 7th ve 9th harmonik bileşenleri) elde edilen özellik setinden daha başarılı olduğuna ulaşılmıştır.

Farklı oylama modellerine karşı üstünlük durumunun ortaya konulabilmesi amacıyla arıza tespit ve sınıflandırmasına yönelik kullanılan oylama modellerinin performans sonuçlarına bağlı olarak Friedman and Finner post hoc testleri ile istatistiksel analiz gerçekleştirilmiştir. Elde edilen sonuçlardan oylama modeller içerisinde en iyi performans gösteren modelin OAOM olduğuna ulaşılmıştır.

Önerilen yöntemin birçok açıdan diğer yöntemlerden üstünlüğü sunulmuş olmasına rağmen uluslararası platformlarda kabul gören farklı karakteristiğe sahip farklı veri setleri kullanılarak OAOM verimliliği analiz edilmiş ve farklı alanlarda da kullanılabileceği doğrulanmıştır.

İleriye yönelik çalışmalara yol gösterilmesi adına ada çalışma moduna sahip mikroşebekelerde geliştirilmiş metasezgisel algoritmalar ile gerilim ve frekans kontrolünün gerçekleştirilmesi konusunda veya ada çalışma moduna sahip mikroşebekelerde geliştirilmiş istifleme modeli ile güç kalitesi olaylarının sınıflandırılması problemleri üzerinde yeni çalışmalar gerçekleştirilebilir. Ayrıca önerdiğimiz modelin esas alınmasıyla daha sonra ortaya çıkabilecek çeşitli problemlerin çözümünde farklı baz modelleri de içerecek yeni çalışmaların türetilmesi mümkündür.

KAYNAKLAR

- [1] Mehigan, L., Deane, J. P., Gallachóir, B. P. Ó., & Bertsch, V. (2018). A review of the role of distributed generation (DG) in future electricity systems. *Energy*. Elsevier Ltd. <https://doi.org/10.1016/j.energy.2018.08.022>
- [2] Barker, P. P., & De Mello, R. W. (2000). Determining the impact of distributed generation on power systems: Part 1 - Radial distribution systems. *Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference*, 3, 1645–1656. <https://doi.org/10.1109/PSS.2000.868775>
- [3] Islam, M. R., Lu, H., Hossain, M. J., & Li, L. (2019). Mitigating unbalance using distributed network reconfiguration techniques in distributed power generation grids with services for electric vehicles: A review. *Journal of Cleaner Production*, 239, 117932. <https://doi.org/10.1016/J.JCLEPRO.2019.117932>
- [4] Emirođlu, S. (2017). *Dađıtık Üretimli Elektrik Enerji Sistemlerinde Gerilim Azaltım Yöntemi ile Enerji Optimizasyonu* [Doktora tezi]. Sakarya Üniversitesi.
- [5] Bidram, A., & Davoudi, A. (2012). Hierarchical structure of microgrids control system. *IEEE Transactions on Smart Grid*, 3(4), 1963–1976. <https://doi.org/10.1109/TSG.2012.2197425>
- [6] Lo, C. H., & Ansari, N. (2012). The progressive smart grid system from both power and communications aspects. *IEEE Communications Surveys and Tutorials*, 14(3), 799–821. <https://doi.org/10.1109/SURV.2011.072811.00089>
- [7] Brown, R. E. (2008). Impact of Smart Grid on Distribution System design. *IEEE Power and Energy Society 2008 General Meeting: Conversion and Delivery of Electrical Energy in the 21st Century*, PES. <https://doi.org/10.1109/PES.2008.4596843>
- [8] Huang, B. B., Xie, G. H., Kong, W. Z., & Li, Q. H. (2012). Study on smart grid and key technology system to promote the development of distributed generation. In *2012 IEEE Innovative Smart Grid Technologies - Asia, ISGT Asia 2012*. <https://doi.org/10.1109/ISGT-Asia.2012.6303265>
- [9] Smart Grid: The Smart Grid | SmartGrid.gov. https://www.smartgrid.gov/the_smart_grid/smart_grid.html adresinden 4 Mayıs 2023 tarihinde alınmıştır
- [10] Siewierski, T., Szypowski, M., & Wędzik, A. (2018). A review of economic aspects of voltage control in LV smart grids. *Renewable and Sustainable Energy Reviews*, 88, 37–45. <https://doi.org/10.1016/J.RSER.2018.02.013>

- [11] Zahedi, A. (2011). A review of drivers, benefits, and challenges in integrating renewable energy sources into electricity grid. *Renewable and Sustainable Energy Reviews*, 15(9), 4775–4779. <https://doi.org/10.1016/J.RSER.2011.07.074>
- [12] Iweh, C. D., Gyamfi, S., Tanyi, E., & Effah-Donyina, E. (2021). Distributed Generation and Renewable Energy Integration into the Grid: Prerequisites, Push Factors, Practical Options, Issues and Merits. *Energies* 2021, 14(17), 1-34. <https://doi.org/10.3390/EN14175375>
- [13] Renewable Capacity Statistics 2023. *The International Renewable Energy Agency (IRENA)*. <https://www.irena.org/Publications/2023/Mar/Renewable-capacity-statistics-2023> adresinden 5 Mayıs 2023 tarihinde alınmıştır.
- [14] Executive summary – Renewables 2022 – Analysis - IEA. <https://www.iea.org/reports/renewables-2022/executive-summary> adresinden 5 Mayıs 2023 tarihinde alınmıştır.
- [15] El-Khattam, W., & Salama, M. M. A. (2004). Distributed generation technologies, definitions and benefits. *Electric Power Systems Research*, 71(2), 119–128. <https://doi.org/10.1016/J.EPSR.2004.01.006>
- [16] Pepermans, G., Driesen, J., Haeseldonckx, D., Belmans, R., & D’haeseleer, W. (2005). Distributed generation: definition, benefits and issues. *Energy Policy*, 33(6), 787–798. <https://doi.org/10.1016/J.ENPOL.2003.10.004>
- [17] Ackermann, T., & Knyazkin, V. (2002). Interaction between distributed generation and the distribution network: Operation aspects. *Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference*, 2(ASIA PACIFIC), 1357–1362. <https://doi.org/10.1109/TDC.2002.1177677>
- [18] Georgilakis, P. S., & Hatziargyriou, N. D. (2013). Optimal distributed generation placement in power distribution networks: Models, methods, and future research. *IEEE Transactions on Power Systems*, 28(3), 3420–3428. <https://doi.org/10.1109/TPWRS.2012.2237043>
- [19] Hatziargyriou, N., Asano, H., Iravani, R., & Marnay, C. (2007). Microgrids. *IEEE Power and Energy Magazine*, 5(4), 78–94. <https://doi.org/10.1109/MPAE.2007.376583>
- [20] Adefarati, T., & Bansal, R. C. (2016). Integration of renewable distributed generators into the distribution system: A review. *IET Renewable Power Generation*, 10(7), 873–884. <https://doi.org/10.1049/IET-RPG.2015.0378>
- [21] Quijano, D. A., & Padilha-Feltrin, A. (2019). Optimal integration of distributed generation and conservation voltage reduction in active distribution networks. *International Journal of Electrical Power and Energy Systems*, 113, 197–207. <https://doi.org/10.1016/j.ijepes.2019.05.039>

- [22] Ma, C., Dasenbrock, J., Töbermann, J. C., & Braun, M. (2019). A novel indicator for evaluation of the impact of distributed generations on the energy losses of low voltage distribution grids. *Applied Energy*, 242, 674–683. <https://doi.org/10.1016/J.APENERGY.2019.03.090>
- [23] Papaioannou, I. T., Purvins, A., & Tzimas, E. (2013). Demand shifting analysis at high penetration of distributed generation in low voltage grids. *International Journal of Electrical Power & Energy Systems*, 44(1), 540–546. <https://doi.org/10.1016/J.IJEPES.2012.07.054>
- [24] Malik, M. Z., Kumar, M., Soomro, A. M., Baloch, M. H., Gul, M., Farhan, M., & Kaloi, G. S. (2020). Strategic planning of renewable distributed generation in radial distribution system using advanced MOPSO method. *Energy Reports*, 6, 2872–2886. <https://doi.org/10.1016/J.EGYR.2020.10.002>
- [25] Baran, M. E., Hooshyar, H., Shen, Z., & Huang, A. (2012). Accommodating high PV penetration on distribution feeders. *IEEE Transactions on Smart Grid*, 3(2), 1039–1046. <https://doi.org/10.1109/TSG.2012.2190759>
- [26] Coster, E. J., Myrzik, J. M. A., Kruimer, B., & Kling, W. L. (2011). Integration issues of distributed generation in distribution grids. *Proceedings of the IEEE*, 99(1), 28–39. <https://doi.org/10.1109/JPROC.2010.2052776>
- [27] Lasseter, R. H. (n.d.). MicroGrids. *2002 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.02CH37309)*, 1, 305–308. <https://doi.org/10.1109/PESW.2002.985003>
- [28] Abu-Sharkh, S., Arnold, R. J., Kohler, J., Li, R., Markvart, T., Ross, J. N., ... Yao, R. (2006). Can microgrids make a major contribution to UK energy supply? *Renewable and Sustainable Energy Reviews*, 10(2), 78–127. <https://doi.org/10.1016/J.RSER.2004.09.013>
- [29] Cagnano, A., De Tuglie, E., & Mancarella, P. (2020). Microgrids: Overview and guidelines for practical implementations and operation. *Applied Energy*, 258, 114039. <https://doi.org/10.1016/J.APENERGY.2019.114039>
- [30] Kroposki, B., Lasseter, R., Ise, T., Morozumi, S., Papathanassiou, S., & Hatziargyriou, N. (2008). Making microgrids work. *IEEE Power and Energy Magazine*, 6(3), 40–53. <https://doi.org/10.1109/MPE.2008.918718>
- [31] Kroposki, B., Pink, C., DeBlasio, R., Thomas, H., Simoes, M., & Sen, P. K. (2006). Benefits of power electronic interfaces for distributed energy systems. *2006 IEEE Power Engineering Society General Meeting, PES*. <https://doi.org/10.1109/PES.2006.1709502>
- [32] IEEE Standards Coordinating Committee 21 (Fuel Cells, P., IEEE-SA Standards Board., & Institute of Electrical and Electronics Engineers. (2003). *IEEE standard for interconnecting distributed resources with electric power systems*. Institute of Electrical and Electronics Engineers.

- [33] Singh, A., & Singh Surjan, B. (n.d.). MICROGRID: A REVIEW. *IJRET: International Journal of Research in Engineering and Technology*, 2321–7308. <http://www.ijret.org>
- [34] Dang, K., He, X., Bi, D., & Feng, C. (2011). An adaptive protection method for the inverter dominated microgrid. *2011 International Conference on Electrical Machines and Systems, ICEMS 2011*. <https://doi.org/10.1109/ICEMS.2011.6073457>
- [35] Chaitusaney, S., & Yokoyama, A. (2006). Reliability analysis of distribution system with distributed generation considering loss of protection coordination. *2006 9th International Conference on Probabilistic Methods Applied to Power Systems, PMAPS*. <https://doi.org/10.1109/PMAPS.2006.360428>
- [36] Ali, S., Javadian, M., & Massaeli, M. (2011). Impact of distributed generation on distribution system's reliability considering recloser-fuse miscoordination- A practical case study. *Indian Journal of Science and Technology*, 4(10). <http://www.indjst.orgIndianJ.Sci.Technol>.
- [37] Girgis, A., & Brahma, S. (2001). Effect of distributed generation on protective device coordination in distribution system. *LESCOPE 2001 - 2001 Large Engineering Systems Conference on Power Engineering: Powering Beyond 2001, Conference Proceedings*, 115–119. <https://doi.org/10.1109/LESCPE.2001.941636>
- [38] Loix, T., S., Wijnhoven, T., & Deconinck, G. (2009). *Protection of microgrids with a high penetration of inverter-coupled energy sources; Protection of microgrids with a high penetration of inverter-coupled energy sources*. *2009 CIGRE/IEEE PES Joint Symposium Integration of Wide-Scale Renewable Resources Into the Power Delivery System*.
- [39] Wei, J., He, Z. Y., & Bo, Z. Q. (2010). The overview of research on microgrid protection development. *Proceedings - 2010 International Conference on Intelligent System Design and Engineering Application, ISDEA 2010*, 2, 692–697. <https://doi.org/10.1109/ISDEA.2010.69>
- [40] Fazanehrafat, A., Javadian, S. A. M., Bathaee, S. M. T., & Haghifam, M. R. (2008). Maintaining the recloser-fuse coordination in distribution systems in presence of DG by determining DG's size. *IET Conference*, 132–137. <https://doi.org/10.1049/CP:20080024>
- [41] Dodiya, P., Shah, P., Doshi, R., Shrimali, D., & Faldu, A. (2016). Threat of Mismatch between Recloser-Fuse in Radial Distribution Networks during Multi DG Interconnections. *International Journal of Emerging Technology and Advanced Engineering*, 6(6), 77–84. <https://ijetae.com/Volume6Issue6.html>
- [42] Hussain, B., Sharkh, S. M., Hussain, S., & Abusara, M. A. (2010). Integration of distributed generation into the grid: Protection challenges and solutions. *IET Conference*. <https://doi.org/10.1049/CP.2010.0347>

- [43] Mäki, K., Repo, S., & Järventausta, P. (2004). Effect of wind power based distributed generation on protection of distribution network. *IEE Conference*, 327–330. <https://doi.org/10.1049/CP:20040129>
- [44] Khederzadeh, M., Javadi, H., & Mousavi, S. M. A. (2010). Source type impact of Distributed Generation (DG) on the distribution protection. *IET Conference*. <https://doi.org/10.1049/CP.2010.0299>
- [45] Memon, A. A., & Kauhaniemi, K. (2015). A critical review of AC Microgrid protection issues and available solutions. *Electric Power Systems Research*, 129, 23–31. <https://doi.org/10.1016/J.EPSR.2015.07.006>
- [46] Zeineldin, H., & Huchel, L. (2016). Planning the coordination of directional overcurrent relays for distribution systems considering DG, *IEEE Transactions on Smart Grid*, 7(3), 1642-1649. doi: 10.1109/TSG.2015.2420711
- [47] Manditereza, P. T., & Bansal, R. (2016). Renewable distributed generation: The hidden challenges – A review from the protection perspective. *Renewable and Sustainable Energy Reviews*, 58, 1457–1465. <https://doi.org/10.1016/J.RSER.2015.12.276>
- [48] Naiem, A. F., Hegazy, Y., Abdelaziz, A. Y., & Elsharkawy, M. A. (2012). A classification technique for recloser-fuse coordination in distribution systems with distributed generation. *IEEE Transactions on Power Delivery*, 27(1), 176–185. <https://doi.org/10.1109/TPWRD.2011.2170224>
- [49] Brahma, S. M., & Girgis, A. A. (2002). Microprocessor-based reclosing to coordinate fuse and recloser in a system with high penetration of distributed generation. *Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference*, 1, 453–458. <https://doi.org/10.1109/PESW.2002.985041>
- [50] Baran, M., & El-Markabi, I. (2004). Adaptive over current protection for distribution feeders with distributed generators. *2004 IEEE PES Power Systems Conference and Exposition*, 2, 715–719. <https://doi.org/10.1109/PSCE.2004.1397672>
- [51] Choudhary, N. K., Mohanty, S. R., & Singh, R. K. (2014). A review on Microgrid protection. *2014 International Electrical Engineering Congress, IEECON 2014*. <https://doi.org/10.1109/IEECON.2014.6925919>
- [52] Coster, E., Myrzik, J., & Kling, W. (2010). Effect of DG on distribution grid protection. *Distributed Generation*. <https://www.intechopen.com/chapters/10133>
- [53] Brahma, S. M., Trejo, J., & Stamp, J. (2015). Insight into microgrid protection. *IEEE PES Innovative Smart Grid Technologies Conference Europe, 2015-January*. <https://doi.org/10.1109/ISGTEUROPE.2014.7028820>

- [54] Haron, A. R., Mohamed, A., Shareef, H., & Zayandehroodi, H. (2012). Analysis and solutions of overcurrent protection issues in a microgrid. *PECon 2012 IEEE International Conference on Power and Energy*, 644–649. <https://doi.org/10.1109/PECON.2012.6450293>
- [55] Haron, A. R., Mohamed, A., & Shareef, H. (2013). Coordination of Overcurrent, Directional and Differential Relays for the Protection of Microgrid System. *Procedia Technology*, 11, 366–373. <https://doi.org/10.1016/j.protcy.2013.12.204>
- [56] Chaitusaney, S., & Yokoyama, A. (2008). Prevention of reliability degradation from recloser-fuse miscoordination due to distributed generation. *IEEE Transactions on Power Delivery*, 23(4), 2545–2554. <https://doi.org/10.1109/TPWRD.2007.915899>
- [57] Martinez, J. A., & Martin-Arnedo, J. (2009). Impact of distributed generation on distribution protection and power quality. *2009 IEEE Power and Energy Society General Meeting, PES '09*. <https://doi.org/10.1109/PES.2009.5275777>
- [58] Adel, M., Sedighi, A. R., & Akbari, H. R. (2015). An adaptive protection scheme to prevent recloser-fuse miscoordination in distribution feeders with distributed generation units, a case study, 10(6), 23–34. <https://doi.org/10.9790/1676-10622334>
- [59] Viawan, F. A., Karlsson, D., Sannino, A., & Daalder, J. (2006). Protection scheme for meshed distribution systems with high penetration of distributed generation. *Power Systems Conference 2006: Advanced Metering, Protection, Control, Communication and Distributed Resources, PSC*, 99–104. <https://doi.org/10.1109/PSAMP.2006.285378>
- [60] Shah, P. H., & Bhalja, B. R. (2014). New adaptive digital relaying scheme to tackle recloser-fuse miscoordination during distributed generation interconnections. *IET Generation, Transmission and Distribution*, 8(4), 682–688. <https://doi.org/10.1049/IET-GTD.2013.0222/CITE/REFWORKS>
- [61] Tailor, J. K., & Osman, A. H. (2008). Restoration of fuse-recloser coordination in distribution system with high DG penetration. *IEEE Power and Energy Society 2008 General Meeting: Conversion and Delivery of Electrical Energy in the 21st Century, PES*. <https://doi.org/10.1109/PES.2008.4596422>
- [62] Tang, G., & Iravani, M. R. (2005). Application of a Fault Current Limiter To Minimize Distributed Generation Impact on Coordinated Relay Protection. *The International Conference on Power Systems Transients (IPST'05)*.
- [63] El-Khattam, W., & Sidhu, T. S. (2008). Restoration of directional overcurrent relay coordination in distributed generation systems utilizing fault current limiter. *IEEE Transactions on Power Delivery*, 23(2), 576–585. <https://doi.org/10.1109/TPWRD.2008.915778>

- [64] Choudhary, N. K., Mohanty, S. R., & Singh, R. K. (2015). Protection coordination of over current relays in distribution system with DG and superconducting fault current limiter. *2014 18th National Power Systems Conference, NPSC 2014*. <https://doi.org/10.1109/NPSC.2014.7103818>
- [65] Al-Nasseri, H., Redfern, M. A., & Li, F. (2006). A voltage based protection for micro-grids containing power electronic converters. *2006 IEEE Power Engineering Society General Meeting, PES*. <https://doi.org/10.1109/PES.2006.1709423>
- [66] Al-Nasseri, H., & Redfern, M. A. (2008). Harmonics content based protection scheme for micro-grids dominated by solid state converters. *2008 12th International Middle East Power System Conference, MEPCON 2008*, 50–56. <https://doi.org/10.1109/MEPCON.2008.4562361>
- [67] Mohamed, N. A., & Salama, M. M. A. (2016). A review on the proposed solutions to microgrid protection problems. *Canadian Conference on Electrical and Computer Engineering, 2016-October*. <https://doi.org/10.1109/CCECE.2016.7726697>
- [68] Nikkhajoei, H., & Lasseter, R. (2006). Microgrid Fault Protection Based on Symmetrical and Differential Current Components. *University of Wisconsin Madison*
- [69] Zeineldin, H. H., El-Saadany, E. F., & Salama, M. M. A. (2006). Distributed generation micro-grid operation: Control and protection. *Power Systems Conference 2006: Advanced Metering, Protection, Control, Communication and Distributed Resources, PSC*, 105–111. <https://doi.org/10.1109/PSAMP.2006.285379>
- [70] Conti, S., Raffa, L., & Vagliasindi, U. (2009). Innovative solutions for protection schemes in autonomous MV micro-grids. *2009 International Conference on Clean Electrical Power, ICCEP 2009*, 647–654. <https://doi.org/10.1109/ICCEP.2009.5211985>
- [71] Sortomme, E., Venkata, M., & Mitra, J. (2010). Microgrid protection using communication-assisted digital relays, *IEEE Transactions on Power Delivery*, 25(4), 2789 – 2796. <https://doi.org/10.1109/TPWRD.2009.2035810>
- [72] Dewadasa, M., Ghosh, A., & Ledwich, G. (2011). *Protection of microgrids using differential relays. AUPEC 2011*.
- [73] Kar, S., Samantaray, S. R., & Zadeh, M. D. (2017). Data-Mining Model Based Intelligent Differential Microgrid Protection Scheme. *IEEE Systems Journal*, 11(2), 1161–1169. <https://doi.org/10.1109/JSYST.2014.2380432>
- [74] Gashteroodkhani, O. A., Majidi, M., & Etezadi-Amoli, M. (2020). A combined deep belief network and time-time transform based intelligent protection Scheme for microgrids. *Electric Power Systems Research*, 182, 106239. <https://doi.org/10.1016/J.EPSR.2020.106239>

- [75] Gadanayak, D. A. (2021). Protection algorithms of microgrids with inverter interfaced distributed generation units—A review. *Electric Power Systems Research*, 192, 106986. <https://doi.org/10.1016/J.EPSR.2020.106986>
- [76] Dewadasa, M., Majumder, R., Ghosh, A., & Ledwich, G. (2009). Control and protection of a microgrid with converter interfaced micro sources. *2009 International Conference on Power Systems, ICPS '09*. <https://doi.org/10.1109/ICPWS.2009.5442654>
- [77] Uthitsunthorn, D., & Kulworawanichpong, T. (2010). Distance protection of a renewable energy plant in electric power distribution systems. *2010 International Conference on Power System Technology: Technological Innovations Making Power Grid Smarter, POWERCON2010*. <https://doi.org/10.1109/POWERCON.2010.5666058>
- [78] Huang, W., Nengling, T., Zheng, X., Fan, C., Yang, X., & Kirby, B. J. (2014). An impedance protection scheme for feeders of active distribution networks. *IEEE Transactions on Power Delivery*, 29(4), 1591–1602. <https://doi.org/10.1109/TPWRD.2014.2322866>
- [79] Bin Li; Yongli Li; Zhiqian Bo; A Klimek. (2009). Design of protection and control scheme for microgrid systems. *44th International Universities Power Engineering Conference (UPEC)*, 1–5.
- [80] Zamani, M. A., Sidhu, T. S., & Yazdani, A. (2011). A protection strategy and microprocessor-based relay for low-voltage microgrids. *IEEE Transactions on Power Delivery*, 26(3), 1873–1883. <https://doi.org/10.1109/TPWRD.2011.2120628>
- [81] Oureilidis, K. O., & Demoulias, C. S. (2016). A Fault Clearing Method in Converter-Dominated Microgrids with Conventional Protection Means. *IEEE Transactions on Power Electronics*, 31(6), 4628–4640. <https://doi.org/10.1109/TPEL.2015.2476702>
- [82] Gupta, P., Bhatia, R. S., & Jain, D. K. (2013). Adaptive protection schemes for the microgrid in a Smart Grid scenario: Technical challenges. *2013 IEEE Innovative Smart Grid Technologies - Asia, ISGT Asia 2013*. <https://doi.org/10.1109/ISGT-ASIA.2013.6698729>
- [83] Tumilty, R. M., Brucoli, M., Burt, G. M., & Green, T. C. (2006). Approaches to network protection for inverter dominated electrical distribution systems, 622–626. <https://doi.org/10.1049/CP:20060183>
- [84] Brahma, S. M., & Girgis, A. A. (2004). Development of Adaptive Protection Scheme for Distribution Systems with High Penetration of Distributed Generation. *IEEE Transactions on Power Delivery*, 19(1), 56–63. <https://doi.org/10.1109/TPWRD.2003.820204>

- [85] Oudalov, A., & Fidigatti, A. (2009). *Adaptive Network Protection in Microgrids*. *International Journal of Distributed Energy Resources* 5 (3), 201-226
- [86] Yi, H., Hu, X., & Dongxia, Z. (2010). Study of adaptive fault current algorithm for microgrid dominated by inverter based distributed generators. *2nd International Symposium on Power Electronics for Distributed Generation Systems, PEDG 2010*, 852–854. <https://doi.org/10.1109/PEDG.2010.5545889>
- [87] Schaefer, N., Degner, T., Shustov, A., Keil, T., & Jaeger, J. (2010). Adaptive protection system for distribution networks with distributed energy resources. *IET Conference*. <https://doi.org/10.1049/CP.2010.0344>
- [88] Ustun, T. S., Ozansoy, C., & Zayegh, A. (2011). A microgrid protection system with central protection unit and extensive communication. *2011 10th International Conference on Environment and Electrical Engineering*. <https://doi.org/10.1109/EEEIC.2011.5874777>
- [89] Khederzadeh, M. (2012). Adaptive setting of protective relays in microgrids in grid-connected and autonomous operation. *IET Conference*. <https://doi.org/10.1049/CP.2012.0076>
- [90] Turan, M. T., & Gökalp, E. (2016). Relay coordination analysis and protection solutions for smart grid distribution systems. *Turkish Journal of Electrical Engineering and Computer Sciences*, 24(2), 474–482. <https://doi.org/10.3906/elk-1309-123>
- [91] Ustun, T. S., Ozansoy, C., & Zayegh, A. (2013). Fault current coefficient and time delay assignment for microgrid protection system with central protection unit. *IEEE Transactions on Power Systems*, 28(2), 598–606. <https://doi.org/10.1109/TPWRS.2012.2214489>
- [92] Brearley, B. J., & Prabu, R. R. (2017). A review on issues and approaches for microgrid protection. *Renewable and Sustainable Energy Reviews*, 67, 988–997. <https://doi.org/10.1016/J.RSER.2016.09.047>
- [93] Perera, N., & Rajapakse, A. D. (2006). Agent-based protection scheme for distribution networks with distributed generators. *2006 IEEE Power Engineering Society General Meeting, PES*. <https://doi.org/10.1109/PES.2006.1709528>
- [94] Wan, H., Li, K. K., & Wong, K. P. (2010). An adaptive multiagent approach to protection relay coordination with distributed generators in industrial power distribution system. *IEEE Transactions on Industry Applications*, 46(5), 2118–2124. <https://doi.org/10.1109/TIA.2010.2059492>
- [95] Liu, Z., Su, C., Hoidalén, H. K., & Chen, Z. (2017). A Multiagent System-Based Protection and Control Scheme for Distribution System with Distributed-Generation Integration. *IEEE Transactions on Power Delivery*, 32(1), 536–545. <https://doi.org/10.1109/TPWRD.2016.2585579>

- [96] Maali Amiri, E., & Vahidi, B. (2020). Integrated protection scheme for both operation modes of microgrid using S-Transform. *International Journal of Electrical Power & Energy Systems*, 121, 106051. <https://doi.org/10.1016/J.IJEPES.2020.106051>
- [97] Hosseini, S. A., Abyaneh, H. A., Sadeghi, S. H. H., Razavi, F., & Nasiri, A. (2016). An overview of microgrid protection methods and the factors involved. *Renewable and Sustainable Energy Reviews*, 64, 174–186. <https://doi.org/10.1016/J.RSER.2016.05.089>
- [98] Tuitemwong, K., & Premrudeepreechacharn, S. (2011). Expert system for protection coordination of distribution system with distributed generators. *International Journal of Electrical Power & Energy Systems*, 33(3), 466–471. <https://doi.org/10.1016/J.IJEPES.2010.10.009>
- [99] Rezaei, N., & Haghifam, M. R. (2008). Protection scheme for a distribution system with distributed generation using neural networks. *International Journal of Electrical Power & Energy Systems*, 30(4), 235–241. <https://doi.org/10.1016/J.IJEPES.2007.07.006>
- [100] Zayandehroodi, H., Mohamed, A., Shareef, H., & Farhoodnea, M. (2012). A novel neural network and backtracking based protection coordination scheme for distribution system with distributed generation. *International Journal of Electrical Power & Energy Systems*, 43(1), 868–879. <https://doi.org/10.1016/J.IJEPES.2012.06.061>
- [101] Jin, L., Jiang, M., & Yang, G. (2014). Fault analysis of microgrid and adaptive distance protection based on complex wavelet transform. *Proceedings - 2014 International Power Electronics and Application Conference and Exposition, IEEE PEAC 2014*, 360–364. <https://doi.org/10.1109/PEAC.2014.7037882>
- [102] Abdulwahid, A. H., & Wang, S. (2016). A new differential protection scheme for microgrid using Hilbert space based power setting and fuzzy decision processes. *Proceedings of the 2016 IEEE 11th Conference on Industrial Electronics and Applications*, 6–11. <https://doi.org/10.1109/ICIEA.2016.7603542>
- [103] Mishra, D. P., Samantaray, S. R., & Joos, G. (2016). A combined wavelet and data-mining based intelligent protection scheme for microgrid. *IEEE Transactions on Smart Grid*, 7(5), 2295–2304. <https://doi.org/10.1109/TSG.2015.2487501>
- [104] Harish, A., Prince, A., & Jayan, M. V. (2022). Fault Detection and Classification for Wide Area Backup Protection of Power Transmission Lines Using Weighted Extreme Learning Machine. *IEEE Access*, 10, 82407–82417. <https://doi.org/10.1109/ACCESS.2022.3196769>

- [105] Casagrande, E., Woon, W. L., Zeineldin, H. H., & Kan'an, N. H. (2013). Data mining approach to fault detection for isolated inverter-based microgrids. *IET Generation, Transmission and Distribution*, 7(7), 745–754. <https://doi.org/10.1049/IET-GTD.2012.0518/CITE/REFWORKS>
- [106] Casagrande, E., Woon, W. L., Zeineldin, H. H., & Svetinovic, D. (2014). A differential sequence component protection scheme for microgrids with inverter-based distributed generators. *IEEE Transactions on Smart Grid*, 5(1), 29–37. <https://doi.org/10.1109/TSG.2013.2251017>
- [107] Hong, Y. Y., & Cabatac, M. T. A. M. (2020). Fault Detection, Classification, and Location by Static Switch in Microgrids Using Wavelet Transform and Taguchi-Based Artificial Neural Network. *IEEE Systems Journal*, 14(2), 2725–2735. <https://doi.org/10.1109/JSYST.2019.2925594>
- [108] Manohar, M., Koley, E., & Ghosh, S. (2020). Microgrid protection under weather uncertainty using joint probabilistic modeling of solar irradiance and wind speed. *Computers & Electrical Engineering*, 86, 106684. <https://doi.org/10.1016/J.COMPELECENG.2020.106684>
- [109] Mishra, M., & Rout, P. K. (2018). Detection and classification of micro-grid faults based on HHT and machine learning techniques. *IET Generation, Transmission and Distribution*, 12(2), 388–397. <https://doi.org/10.1049/IET-GTD.2017.0502/CITE/REFWORKS>
- [110] Bukhari, S. B. A., Kim, C. H., Mehmood, K. K., Haider, R., & Zaman, M. S. U. (2020). Convolutional neural network-based intelligent protection strategy for microgrids. *IET Generation, Transmission and Distribution*, 14(7), 1177–1185. <https://doi.org/10.1049/IET-GTD.2018.7049/CITE/REFWORKS>
- [111] Mishra, M., Panigrahi, R. R., & Rout, P. K. (2019). A combined mathematical morphology and extreme learning machine techniques based approach to micro-grid protection. *Ain Shams Engineering Journal*, 10(2), 307–318. <https://doi.org/10.1016/J.ASEJ.2019.03.011>
- [112] Abdelgayed, T. S., Morsi, W. G., & Sidhu, T. S. (2017). Fault detection and classification based on co-training of semisupervised machine learning. *IEEE Transactions on Industrial Electronics*, 65(2), 1595–1605. <https://doi.org/10.1109/TIE.2017.2726961>
- [113] Gush, T., Bukhari, S. B. A., Mehmood, K. K., Admasie, S., Kim, J. S., & Kim, C. H. (2019). Intelligent Fault Classification and Location Identification Method for Microgrids Using Discrete Orthonormal Stockwell Transform-Based Optimized Multi-Kernel Extreme Learning Machine. *Energies* 2019, 12(23), 1-16. <https://doi.org/10.3390/EN12234504>
- [114] Baloch, S., & Muhammad, M. S. (2021). An Intelligent Data Mining-Based Fault Detection and Classification Strategy for Microgrid. *IEEE Access*, 9, 22470–22479. <https://doi.org/10.1109/ACCESS.2021.3056534>

- [115] Pan, P., Mandal, R. K., & Rahman Redoy Akanda, Md. M. (2022). Fault Classification with Convolutional Neural Networks for Microgrid Systems. *International Transactions on Electrical Energy Systems*, 2022, 1–21. <https://doi.org/10.1155/2022/8431450>
- [116] Granados-Lieberman, D., Romero-Troncoso, R. J., Osornio-Rios, R. A., Garcia-Perez, A., & Cabal-Yepez, E. (2011). Techniques and methodologies for power quality analysis and disturbances classification in power systems: A review. *IET Generation, Transmission and Distribution*, 5(4), 519–529. <https://doi.org/10.1049/IET-GTD.2010.0466/CITE/REFWORKS>
- [117] Moussa, A. E., Abdallah, E. N., El-Gammal, M., & El-Seoud, A. A. (2004). Hardware - Software structure for on-line power quality assessment: Part. I. *American Society of Mechanical Engineers, Rail Transportation Division (Publication) RTD*, 27, 147–152. <https://doi.org/10.1115/RTD2004-66022>
- [118] Kim, I. S. (2016). On-line fault detection algorithm of a photovoltaic system using wavelet transform. *Solar Energy*, 126, 137–145. <https://doi.org/10.1016/J.SOLENER.2016.01.005>
- [119] Mahela, O. P., Shaik, A. G., & Gupta, N. (2015). A critical review of detection and classification of power quality events. *Renewable and Sustainable Energy Reviews*, 41, 495–505. <https://doi.org/10.1016/J.RSER.2014.08.070>
- [120] Lee, C., Yi, L., Tan, L. H., Goh, W., Lee, B. S., & Yeo, C. K. (2015). A wavelet entropy-based change point detection on network traffic: a case study of heartbleed vulnerability. *Proceedings of the International Conference on Cloud Computing Technology and Science, CloudCom, 2015-February*, 995–1000. <https://doi.org/10.1109/CLOUDCOM.2014.78>
- [121] Rioul, O., & Vetterli, M. (1991). Wavelets and Signal Processing. *IEEE Signal Processing Magazine*, 8(4), 14–38. <https://doi.org/10.1109/79.91217>
- [122] Shariatinasab, R., Rahmani, M. A. and B., Shariatinasab, R., & Rahmani, M. A. and B. (2012). Application of Wavelet Analysis in Power Systems. *Advances in Wavelet Theory and Their Applications in Engineering, Physics and Technology*. <https://doi.org/10.5772/36843>
- [123] Netsanet, S., Zhang, J., & Zheng, D. (2018). Bagged Decision Trees Based Scheme of Microgrid Protection Using Windowed Fast Fourier and Wavelet Transforms. *Electronics* 2018, 7(5), 61. <https://doi.org/10.3390/ELECTRONICS7050061>
- [124] Kanirajan, P., & Suresh Kumar, V. (2015). Power quality disturbance detection and classification using wavelet and RBFNN. *Applied Soft Computing*, 35, 470–481. <https://doi.org/10.1016/J.ASOC.2015.05.048>
- [125] Poisson, O., Rioual, P., & Meunier, M. (2000). Detection and measurement of power quality disturbances using wavelet transform. *IEEE Transactions on Power Delivery*, 15(3), 1039–1044. <https://doi.org/10.1109/61.871372>

- [126] Oliveira, M. O., & Bretas, A. S. (2011). Application of discrete wavelet transform for differential protection of power transformers. In *Discrete Wavelet Transforms - Biomedical Applications*. <https://doi.org/10.1109/PTC.2009.5282195>
- [127] Dağ, O. (2002). *Combined Wavelet-Neural Classifier For Power Distribution Systems*. [Yüksek Lisans Tezi]. İstanbul Teknik Üniversitesi
- [128] Ülker, F., & Küçüker, A. (2022). Probabilistic weighted voting model using multiple machine learning methods for fault detection and classification. *COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, 41(5), 1542–1565. <https://doi.org/10.1108/COMPEL-06-2021-0200>
- [129] Roura, J.C., and Martínez, J.L.M. (2011). Transient Analysis and Motor Fault Detection using the Wavelet Transform. In *Discrete Wavelet Transforms - Theory and Applications*.
- [130] Sayed, T.S.A.A. (2017). *Automated Wavelet-Based Fault Detection And Diagnosis For Smart Distribution Systems And Microgrids*. [Doktora Tezi], University of Ontario Institute of Technology.
- [131] Dehghani, M., Khooban, M. H., & Niknam, T. (2016). Fast fault detection and classification based on a combination of wavelet singular entropy theory and fuzzy logic in distribution lines in the presence of distributed generations. *International Journal of Electrical Power & Energy Systems*, 78, 455–462. <https://doi.org/10.1016/J.IJEPES.2015.11.048>
- [132] Li, W., Monti, A., & Ponci, F. (2014). Fault detection and classification in medium voltage dc shipboard power systems with wavelets and artificial neural networks. *IEEE Transactions on Instrumentation and Measurement*, 63(11), 2651–2665. <https://doi.org/10.1109/TIM.2014.2313035>
- [133] Karthik Thirumala; M. Siva Prasad; Trapti Jain; Amod C. Umarikar. (2018). Tunable-Q Wavelet Transform and Dual Multiclass SVM for Online Automatic Detection of Power Quality Disturbances. *IEEE Transactions on Smart Grid*, 9(4), 3018–3028.
- [134] Samui, A., & Samantaray, S. R. (2013). Wavelet singular entropy-based islanding detection in distributed generation. *IEEE Transactions on Power Delivery*, 28(1), 411–418. <https://doi.org/10.1109/TPWRD.2012.2220987>
- [135] Zhang, Y., Wu, H., & Cheng, L. (2012). Some new deformation formulas about variance and covariance. *2012 Proceedings of International Conference on Modelling, Identification and Control*.
- [136] MATLAB and Simulink Toolbox Release 2011b, The MathWorks, Inc., Natick, Massachusetts, United States.

- [137] Pintelas, P., & Livieris, I. E. (2020). Special issue on ensemble learning and applications. *Algorithms*. MDPI 13(6), 1-4. <https://doi.org/10.3390/A13060140>
- [138] Dietterich, T. G. (2000). Ensemble methods in machine learning. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1857 LNCS, 1–15. https://doi.org/10.1007/3-540-45014-9_1/COVER
- [139] Polikar, R., Zhang, C., & Ma, Y. (2012). Ensemble Learning. *Ensemble Machine Learning*, 1–34. https://doi.org/10.1007/978-1-4419-9326-7_1
- [140] Araya, D. B., Grolinger, K., ElYamany, H. F., Capretz, M. A. M., & Bitsuamlak, G. (2017). An ensemble learning framework for anomaly detection in building energy consumption. *Energy and Buildings*, 144, 191–206. <https://doi.org/10.1016/J.ENBUILD.2017.02.058>
- [141] Lv, Y., Peng, S., Yuan, Y., Wang, C., Yin, P., Liu, J., & Wang, C. (2019). A classifier using online bagging ensemble method for big data stream learning. *Tsinghua Science and Technology*, 24(4), 379–388. <https://doi.org/10.26599/TST.2018.9010119>
- [142] Onan, A., Korukoğlu, S., & Bulut, H. (2016). A multiobjective weighted voting ensemble classifier based on differential evolution algorithm for text sentiment classification. *Expert Systems with Applications*, 62, 1–16. <https://doi.org/10.1016/J.ESWA.2016.06.005>
- [143] Pourdarbani, R., Sabzi, S., Kalantari, D., Paliwal, J., Benmouna, B., García-Mateos, G., & Molina-Martínez, J. M. (2020). Estimation of different ripening stages of Fuji apples using image processing and spectroscopy based on the majority voting method. *Computers and Electronics in Agriculture*, 176, 105643. <https://doi.org/10.1016/J.COMPAG.2020.105643>
- [144] Wang, Y., Guo, Y., Zeng, X., Chen, J., Kong, Y., & Sun, S. (2020). Stator Single-Line-to-Ground Fault Protection for Bus-Connected Powerformers Based on S-Transform and Bagging Ensemble Learning. *IEEE Access*, 8, 88322–88332. <https://doi.org/10.1109/ACCESS.2020.2993692>
- [145] Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4). <https://doi.org/10.1002/WIDM.1249>
- [146] Chandra, A., & Yao, X. (2006). Evolving hybrid ensembles of learning machines for better generalisation. *Neurocomputing*, 69(7–9), 686–700. <https://doi.org/10.1016/J.NEUCOM.2005.12.014>
- [147] Woźniak, M., Graña, M., & Corchado, E. (2014). A survey of multiple classifier systems as hybrid systems. *Information Fusion*, 16(1), 3–17. <https://doi.org/10.1016/J.INFFUS.2013.04.006>

- [148] Tanwani, A. K., Afridi, J., Shafiq, M. Z., & Farooq, M. (2009). Guidelines to select machine learning scheme for classification of biomedical datasets. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 5483 LNCS, 128–139. https://doi.org/10.1007/978-3-642-01184-9_12/COVER
- [149] Li, Y., & Chen, W. (2020). A Comparative Performance Assessment of Ensemble Learning for Credit Scoring. *Mathematics* 2020, 8(10), 1-19. <https://doi.org/10.3390/MATH8101756>
- [150] Wang, B., & Pineau, J. (2016). Online Bagging and Boosting for Imbalanced Data Streams. *IEEE Transactions on Knowledge and Data Engineering*, 28(12), 3353–3366. <https://doi.org/10.1109/TKDE.2016.2609424>
- [151] Wolpert, D. H. (1992). Stacked generalization. *Neural Networks*, 5(2), 241–259. [https://doi.org/10.1016/S0893-6080\(05\)80023-1](https://doi.org/10.1016/S0893-6080(05)80023-1)
- [152] Gajowniczek, K., Grzegorzczak, I., Ząbkowski, T., & Bajaj, C. (2020). Weighted Random Forests to Improve Arrhythmia Classification. *Electronics* 2020, 9(1), 1-20. <https://doi.org/10.3390/ELECTRONICS9010099>
- [153] Zhi-Hua Zhou, & Biometrics, E. (2009). Ensemble Learning. *Encyclopedia of Biometrics*, 270–273. https://doi.org/10.1007/978-0-387-73003-5_293
- [154] Li, Y., & Chen, W. (2021). Entropy method of constructing a combined model for improving loan default prediction: A case study in China. *Journal of the Operational Research Society*, 72(5), 1099–1109. <https://doi.org/10.1080/01605682.2019.1702905>
- [155] Parvin, H., Mirnabibaboli, M., & Alinejad-Rokny, H. (2015). Proposing a classifier ensemble framework based on classifier selection and decision tree. *Engineering Applications of Artificial Intelligence*, 37, 34–42. <https://doi.org/10.1016/J.ENGAPPAL.2014.08.005>
- [156] Roshan, S. E., & Asadi, S. (2020). Improvement of Bagging performance for classification of imbalanced datasets using evolutionary multi-objective optimization. *Engineering Applications of Artificial Intelligence*, 87, 103319. <https://doi.org/10.1016/J.ENGAPPAL.2019.103319>
- [157] Assiri, A. S., Nazir, S., & Velastin, S. A. (2020). Breast Tumor Classification Using an Ensemble Machine Learning Method. *Journal of Imaging*, 6(6). <https://doi.org/10.3390/JIMAGING6060039>
- [158] Kittler, J., Hatef, M., Duin, R. P. W., & Matas, J. (1998). On combining classifiers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(3), 226–239. <https://doi.org/10.1109/34.667881>

- [159] Sherazi, S. W. A., Bae, J. W., & Lee, J. Y. (2021). A soft voting ensemble classifier for early prediction and diagnosis of occurrences of major adverse cardiovascular events for STEMI and NSTEMI during 2-year follow-up in patients with acute coronary syndrome. *PLOS ONE*, *16*(6), e0249338. <https://doi.org/10.1371/JOURNAL.PONE.0249338>
- [160] Gao, X., Shan, C., Hu, C., Niu, Z., & Liu, Z. (2019). An Adaptive Ensemble Machine Learning Model for Intrusion Detection. *IEEE Access*, *7*, 82512–82521. <https://doi.org/10.1109/ACCESS.2019.2923640>
- [161] Catal, C., & Nangir, M. (2017). A sentiment classification model based on multiple classifiers. *Applied Soft Computing*, *50*, 135–141. <https://doi.org/10.1016/J.ASOC.2016.11.022>
- [162] Rustam, F., Mehmood, A., Ullah, S., Ahmad, M., Muhammad Khan, D., Choi, G. S., & On, B. W. (2020). Predicting pulsar stars using a random tree boosting voting classifier (RTB-VC). *Astronomy and Computing*, *32*. <https://doi.org/10.1016/J.ASCOM.2020.100404>
- [163] Żabiński, G., Gramacki, J., Gramacki, A., Miśta-Jakubowska, E., Birch, T., & Disser, A. (2020). Multi-classifier majority voting analyses in provenance studies on iron artefacts. *Journal of Archaeological Science*, *113*. <https://doi.org/10.1016/J.JAS.2019.105055>
- [164] Rahimi, N., Eassa, F., & Elrefaei, L. (2020). An Ensemble Machine Learning Technique for Functional Requirement Classification. *Symmetry* *2020*, *12*(10), 1-25. <https://doi.org/10.3390/SYM12101601>
- [165] Livieris, I. E., Kanavos, A., Tampakas, V., & Pintelas, P. (2019). A Weighted Voting Ensemble Self-Labeled Algorithm for the Detection of Lung Abnormalities from X-Rays. *Algorithms* *2019*, *12*(3), 1-15. <https://doi.org/10.3390/A12030064>
- [166] Yijing, L., Haixiang, G., Xiao, L., Yanan, L., & Jinling, L. (2016). Adapted ensemble classification algorithm based on multiple classifier system and feature selection for classifying multi-class imbalanced data. *Knowledge-Based Systems*, *94*, 88–104. <https://doi.org/10.1016/J.KNOSYS.2015.11.013>
- [167] Bashir, S., Qamar, U., & Khan, F. H. (2016). IntelliHealth: A medical decision support application using a novel weighted multi-layer classifier ensemble framework. *Journal of Biomedical Informatics*, *59*, 185–200. <https://doi.org/10.1016/J.JBI.2015.12.001>
- [168] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research* *12*. <http://arxiv.org/abs/1201.0490>
- [169] Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, *63*(1), 3–42. <https://doi.org/10.1007/S10994-006-6226-1/METRICS>

- [170] Wang, X., Tan, L., & Fan, J. (2023). Performance Evaluation of Mangrove Species Classification Based on Multi-Source Remote Sensing Data Using Extremely Randomized Trees in Fucheng Town, Leizhou City, Guangdong Province. *Remote Sensing* 2023, 15(5). <https://doi.org/10.3390/RS15051386>
- [171] Yan, X., & Jia, M. (2018). A novel optimized SVM classification algorithm with multi-domain feature and its application to fault diagnosis of rolling bearing. *Neurocomputing*, 313, 47–64. <https://doi.org/10.1016/J.NEUCOM.2018.05.002>
- [172] Rahman, M. H., Shahjalal, M., Hasan, M. K., Ali, M. O., & Jang, Y. M. (2021). Design of an SVM Classifier Assisted Intelligent Receiver for Reliable Optical Camera Communication. *Sensors* 2021, 21(13). <https://doi.org/10.3390/S21134283>
- [173] Zhang, X., Qiu, D., & Chen, F. (2015). Support vector machine with parameter optimization by a novel hybrid method and its application to fault diagnosis. *Neurocomputing*, 149, 641–651. <https://doi.org/10.1016/J.NEUCOM.2014.08.010>
- [174] Ding, S., Hao, M., Cui, Z., Wang, Y., Hang, J., & Li, X. (2023). Application of multi-SVM classifier and hybrid GSAPSO algorithm for fault diagnosis of electrical machine drive system. *ISA Transactions*, 133, 529–538. <https://doi.org/10.1016/J.ISATRA.2022.06.029>
- [175] Asteris, P. G., Roussis, P. C., & Douvika, M. G. (2017). Feed-Forward Neural Network Prediction of the Mechanical Properties of Sandcrete Materials. *Sensors* 2017, 17(6), 1344. <https://doi.org/10.3390/S17061344>
- [176] Mouloudi, S., Rahmanpanah, H., Gohari, S., Burvill, C., & Davies, H. M. S. (2022). Feedforward backpropagation artificial neural networks for predicting mechanical responses in complex nonlinear structures: A study on a long bone. *Journal of the Mechanical Behavior of Biomedical Materials*, 128. <https://doi.org/10.1016/J.JMBBM.2022.105079>
- [177] Le, T. H., Dai, L., Jang, H., & Shin, S. (2022). Robust Process Parameter Design Methodology: A New Estimation Approach by Using Feed-Forward Neural Network Structures and Machine Learning Algorithms. *Applied Sciences* 2022, 12(6). <https://doi.org/10.3390/APP12062904>
- [178] Samantaray, S. R., Kamwa, I., & Joos, G. (2010). Ensemble decision trees for phasor measurement unit-based wide-area security assessment in the operations time frame. *IET Generation, Transmission and Distribution*, 4(12), 1334–1348. <https://doi.org/10.1049/iet-gtd.2010.0201>
- [179] Huang, N., Lu, G., Cai, G., Xu, D., Xu, J., Li, F., & Zhang, L. (2016). Feature Selection of Power Quality Disturbance Signals with an Entropy-Importance-Based Random Forest. *Entropy* 2016, 18(2). <https://doi.org/10.3390/E18020044>

- [180] Chawla, N. V., & Sylvester, J. (2007). Exploiting diversity in ensembles: improving the performance on unbalanced datasets. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 397–406. https://doi.org/10.1007/978-3-540-72523-7_40/COVER
- [181] Kuncheva, L. I., & Whitaker, C. J. (2003). Measures of diversity in classifier ensembles and their relationship with the ensemble accuracy. *Machine Learning*, 51(2), 181–207. <https://doi.org/10.1023/A:1022859003006/METRICS>
- [182] Kuncheva, L. I. (2004). Combining Pattern Classifiers. *Combining Pattern Classifiers*. <https://doi.org/10.1002/0471660264>
- [183] Hush, D., & Horne, B. G. (1993). Progress in Supervised Neural Networks: What's New Since Lip. *IEEE Signal Processing Magazine*, 10(1), 8–39. <https://doi.org/10.1109/79.180705>
- [184] Reich, Y., & Travitzky, N. (1995). Machine learning of material behaviour knowledge from empirical data. *Materials & Design*, 16(5), 251–259. [https://doi.org/10.1016/0261-3069\(96\)00007-6](https://doi.org/10.1016/0261-3069(96)00007-6)
- [185] Liu, Y., Zhao, T., Ju, W., & Shi, S. (2017). Materials discovery and design using machine learning. *Journal of Materiomics*, 3(3), 159–177. <https://doi.org/10.1016/J.JMAT.2017.08.002>
- [186] Xiao, Y., Wu, J., Lin, Z., & Zhao, X. (2018). A deep learning-based multi-model ensemble method for cancer prediction. *Computer Methods and Programs in Biomedicine*, 153, 1–9. <https://doi.org/10.1016/J.CMPB.2017.09.005>
- [187] Cai, R., Han, T., Liao, W., Huang, J., Li, D., Kumar, A., & Ma, H. (2020). Prediction of surface chloride concentration of marine concrete using ensemble machine learning. *Cement and Concrete Research*, 136. <https://doi.org/10.1016/J.CEMCONRES.2020.106164>
- [188] Piagi, P., & Lasseter, R. H. (2006). Autonomous control of microgrids. *2006 IEEE Power Engineering Society General Meeting, PES*. <https://doi.org/10.1109/PES.2006.1708993>
- [189] Tsai, H. L. (2010). Insolation-oriented model of photovoltaic module using Matlab/Simulink. *Solar Energy*, 84(7), 1318–1326. <https://doi.org/10.1016/j.solener.2010.04.012>
- [190] King, M., Li, D., Dooner, M., Ghosh, S., Nath Roy, J., Chakraborty, C., & Wang, J. (2021). Mathematical Modelling of a System for Solar PV Efficiency Improvement Using Compressed Air for Panel Cleaning and Cooling. *Energies* 2021, 14(14). <https://doi.org/10.3390/EN14144072>

- [191] Kotb, K. M., Elkadeem, M. R., Elmorshedy, M. F., & Dán, A. (2020). Coordinated power management and optimized techno-enviro-economic design of an autonomous hybrid renewable microgrid: A case study in Egypt. *Energy Conversion and Management*, 221. <https://doi.org/10.1016/J.ENCONMAN.2020.113185>
- [192] Rosyadi, M., Umemura, A., Takahashi, R., & Tamura, J. (2022). Detailed and Average Models of a Grid-Connected MMC-Controlled Permanent Magnet Wind Turbine Generator. *Applied Sciences* 2022, 12(3). <https://doi.org/10.3390/APP12031619>
- [193] Majout, B., Bossoufi, B., Bouderbala, M., Masud, M., Al-Amri, J. F., Taoussi, M., ... Karim, M. (2022). Improvement of PMSG-Based Wind Energy Conversion System Using Developed Sliding Mode Control. *Energies* 2022, 15(5). <https://doi.org/10.3390/EN15051625>
- [194] Hossain, M. A., Pota, H. R., Issa, W., & Hossain, M. J. (2017). Overview of AC Microgrid Controls with Inverter-Interfaced Generations. *Energies* 2017, 10(9). <https://doi.org/10.3390/EN10091300>
- [195] Balaguer, I. J., Lei, Q., Yang, S., Supatti, U., & Peng, F. Z. (2011). Control for grid-connected and intentional islanding operations of distributed power generation. *IEEE Transactions on Industrial Electronics*, 58(1), 147–157. <https://doi.org/10.1109/TIE.2010.2049709>
- [196] Chandra, T. B., Verma, K., Singh, B. K., Jain, D., & Netam, S. S. (2021). Coronavirus disease (COVID-19) detection in Chest X-Ray images using majority voting based classifier ensemble. *Expert systems with applications*, 165. <https://doi.org/10.1016/J.ESWA.2020.113909>
- [197] Arabameri, A., Nalivan, O. A., Pal, S. C., Chakraborty, R., Saha, A., Lee, S., ... Bui, D. T. (2020). Novel Machine Learning Approaches for Modelling the Gully Erosion Susceptibility. *Remote Sensing* 2020, 12(17). <https://doi.org/10.3390/RS12172833>
- [198] Demšar, J. (2006). Statistical Comparisons of Classifiers over Multiple Data Sets. *Journal of Machine Learning Research*, 7(1), 1–30. <http://jmlr.org/papers/v7/demsar06a.html>
- [199] Dua, D., & Gra, C. (2019). UCI Machine Learning Repository. *University of California, School of Information and Computer Science, Irvine, CA*. <http://archive.ics.uci.edu/ml>.
- [200] Alcalá-Fdez, J., Fernández, A., Luengo, J., Derrac, J., García, S., Sánchez, L., & Herrera, F. (2011). *KEEL Data-Mining Software Tool: Data Set Repository, Integration of Algorithms and Experimental Analysis Framework*, 17. <http://the-data-mine.com/bin/view/Software>

- [201] Fang, P., Zhang, X., Wei, P., Wang, Y., Zhang, H., Liu, F., & Zhao, J. (2020). The Classification Performance and Mechanism of Machine Learning Algorithms in Winter Wheat Mapping Using Sentinel-2 10 m Resolution Imagery. *Applied Sciences* 2020, 10(15). <https://doi.org/10.3390/APP10155075>
- [202] Boughorbel, S., Jarray, F., & El-Anbari, M. (2017). Optimal classifier for imbalanced data using Matthews Correlation Coefficient metric. *PLOS ONE*, 12(6). <https://doi.org/10.1371/JOURNAL.PONE.0177678>

ÖZGEÇMİŞ

Ad-Soyad : Fevzeddin ÜLKER

ÖĞRENİM DURUMU:

- **Lisans** : 2013, Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü
- **Yüksek lisans** : 2015, Yıldız Teknik Üniversitesi, Elektrik Mühendisliği Ana Bilim Dalı, Elektrik Tesisleri Bilim Dalı

MESLEKİ DENEYİM:

- 2015 yılında Sakarya Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümünde Araştırma Görevlisi olarak başlamış ve halen devam etmektedir.

TEZDEN TÜRETİLEN ESERLER:

- Ülker, F., & Küçüker, A. (2022). Probabilistic weighted voting model using multiple machine learning methods for fault detection and classification. *COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, 41(5), 1542–1565. <https://doi.org/10.1108/COMPEL-06-2021-0200>

DİĞER ESERLER:

- Ülker, F., & Küçüker, A. (2022). A Combined Primary-Secondary Control for Voltage and Frequency Regulation in Islanded Microgrids. In *2nd International Conference on Engineering and Applied Natural Sciences*, 390–394. <https://www.iceans.org/>