



T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**MİKROŞEBEKELERDE ADA MOD ÇALIŞMANIN TESPİTİ VE GÜÇ
KALİTESİ OLAYLARININ SINIFLANDIRILMASI İÇİN YAPAY ZEKÂ
TABANLI KONTROL YÖNTEMLERİNİN GELİŞTİRİLMESİ**

DOKTORA TEZİ

Alper YILMAZ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

EKİM 2023

T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MİKROŞEBEKELERDE ADA MOD ÇALIŞMANIN TESPİTİ VE GÜÇ
KALİTESİ OLAYLARININ SINIFLANDIRILMASI İÇİN YAPAY ZEKÂ
TABANLI KONTROL YÖNTEMLERİNİN GELİŞTİRİLMESİ

DOKTORA TEZİ

Alper YILMAZ
(181331541002)

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Gökay BAYRAK

EKİM 2023

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 181331541002 numaralı Doktora Öğrencisi Alper YILMAZ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “MİKRO ŞEBEKELERDE ADA MOD ÇALIŞMANIN TESPİTİ VE GÜÇ KALİTESİ OLAYLARININ SINIFLANDIRILMASI İÇİN YAPAY ZEKÂ TABANLI KONTROL YÖNTEMLERİNİN GELİŞTİRİLMESİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Gökay BAYRAK**

Bursa Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Hakan GÜRKAN**

Bursa Teknik Üniversitesi

Doç. Dr. Engin Cemal MENGÜÇ

Kayseri Üniversitesi

Doç. Dr. Mahmut Temel ÖZDEMİR

Fırat Üniversitesi

Dr. Öğr. Üyesi Ahmet KÜÇÜKER

Sakarya Üniversitesi

Teslim Tarihi :

Savunma Tarihi : 23.10.2023



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu tez, TÜBİTAK 1002 Hızlı Destek Programı kapsamında 121E023 numaralı proje ile desteklenmiştir.

Bu tez, BTÜ Bilimsel Araştırma Projeleri Birimi tarafından Öncelikli Alan Projesi kapsamında (Proje No: 210ÖAP04) desteklenmiştir.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Alper YILMAZ

İmzası:

X



Eşime ve aileme,

ÖNSÖZ

Bu tez çalışması, Bursa Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Programı'nda hazırlanmıştır.

Doktora eğitimim boyunca bana her zaman yardımcı olan, bilgi ve tecrübelerinden çokça yararlandığım değerli tez danışmanım Doç. Dr. Gökay BAYRAK'a sonsuz teşekkürlerimi sunarım.

Tez çalışmamda ve akademik hayatımda bilgi ve tecrübelerinden yararlandığım Dr. Öğr. Üyesi Ahmet KÜÇÜKER'e, Dr. Öğr. Üyesi Recep ÇAKMAK'a ve Prof. Dr. Hakan GÜRKAN'a teşekkür ederim.

Proje kapsamında tanıştığım ve ortak çalışma fırsatı bulduğum Siberetik Makina & Otomasyon Ar-Ge Merkezi'nde çalışan Yüksek Mühendis Hasan MERAL'e, Ar-Ge Mühendisi Tolga ATEŞÇİ'ye ve Yüksek Mühendis Samet ÖNER'e yaptığımız çalışmalar için teşekkür ederim.

Tez çalışması boyunca her zaman yanımda olan sevgili eşime ve desteklerini daima hissettiğim anneme, babama ve kardeşime teşekkür ederim.

Ayrıca, TÜBİTAK'a 1002 Hızlı Destek Programı kapsamında 121E023 numaralı projeye ve BTÜ Bilimsel Araştırma Projeleri Birimi'ne Öncelikli Alan Projesi'ne (Proje No: 210ÖAP04) desteklerinden dolayı teşekkür ederim.

Ekim 2023

Alper YILMAZ
(Elektrik-Elektronik Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	x
SEMBOLLER	xiii
ÇİZELGE LİSTESİ.....	xvi
ŞEKİL LİSTESİ.....	xvii
ÖZET.....	xix
SUMMARY	xxi
1. GİRİŞ	1
1.1 Literatür Araştırması	5
1.1.1 Literatürde önerilen Ada mod çalışma tespit yöntemleri.....	5
1.1.2 Literatürde önerilen GKO sınıflandırma yöntemleri	14
1.2 Tezin Amacı, Özgün Değer ve Çalışmanın Literatüre Katkısı	19
1.3 Metnin Organizasyonu	23
2. GÜÇ KALİTESİ OLAYLARI VE ADA MOD ÇALIŞMA	24
2.1 Ada Mod Çalışma Tanımı ve İlgili Standartlar	24
2.2 GK / GKO Tanımları ve İlgili Standartlar	27
3. TEORİK ARKA PLAN	32
3.1 Dalgacık Dönüşümü	32
3.1.1 Sürekli dalgacık dönüşümü (SDD)	32
3.1.2 Ayrık dalgacık dönüşümü (ADD).....	33
3.1.3 Örnek indirgenmemiş dalgacık dönüşümü (ÖİDD).....	35
3.1.3.1 à trous algoritması ile ÖİDD ayrıştırması	35
3.1.3.2 Piramidal algoritma ile ÖİDD ayrıştırması	36
3.2 Sınıflandırıcılar.....	38
3.2.1 k-en yakın komşu (kNN) algoritması.....	38
3.2.2 Destek vektör makinesi (DVM).....	39
3.2.3 Karar ağaçları (KA)	40
3.2.4 Rastgele orman (RO) algoritması	41
3.2.5 Gradyan artırıcı karar ağaçları (GAKA) algoritması	42
3.3 Derin Öğrenme Yaklaşımı	43
3.3.1 Evrişimsel sinir ağları (ESA)	44
3.3.2 Uzun kısa süreli bellek (UKSB).....	47
3.3.3 Hibrit yaklaşımlar (DESA-DUKSB)	49
3.4 Bulanık Mantık Karar Verici (BKV)	50
3.4.1 BKV-Tip1	51
4. VERİ ÜRETİMİ.....	53
4.1 İntegral-Tabanlı Matematiksel Modelle Veri Üretimi	54
4.2 Mikroşebeke Benzetim Modeliyle Veri Üretimi.....	58
4.3 Deneysel Kurulum ve Verilerin Toplanması	64

4.3.1 AMOD test sistemi ve olay verilerinin toplanması.....	64
4.3.2 AMOD olmayan (GKO) verilerinin toplanması	74
4.4 Ayarlanabilir AC Kaynak ile Veri Üretimi	78
5. ÖNERİLEN AMOD ÇALIŞMA TESPİT YÖNTEMİ	80
5.1 SDD ile AMOD Tespiti.....	80
5.2 ADD ile AMOD Tespiti.....	80
5.3 Önerilen Piramidal ÖİDD-Tabanlı AMOD Tespiti.....	81
5.3.1 ÖİDD ayrıştırmasının avantajları	82
5.4 DD Yöntemlerinde Parametre Seçimi	84
5.4.1 Ana dalgacık seçimi	84
5.4.2 Eşik değeri seçimi	86
5.5 Deneysel Sonuçlar	87
5.5.1 AMOD koşullarının tespiti.....	87
5.5.2 AMOD olmayan koşullarda yöntem performansı.....	90
6. ÖNERİLEN GKO TESPİT VE SINIFLANDIRMA YÖNTEMLERİ	95
6.1 Tip-1 Bulanık Mantık Karar Verici ile GKO Tespiti ve Sınıflandırma	95
6.1.1 BKV parametrelerinin seçimi	98
6.1.2 Farklı gürültü koşullarında performans analizi	103
6.1.3 Performans Doğrulama	105
6.2 Sinyal Analiz ve Sınıflandırıcı Modelleri ile GKO Sınıflandırma.....	106
6.2.1 ÖİDD parametrelerinin belirlenmesi	108
6.2.2 Öznitelik çıkarımı	108
6.2.3 DD ile öznitelik analizi	111
6.2.4 Önerilen ÖİDD-DVM-Tabanlı hibrit GKO sınıflandırma yöntemi.....	112
6.2.5 Yöntem performansının veri seti üzerinde değerlendirilmesi.....	114
6.3 Derin Öğrenme-Tabanlı Yöntem ile GKO Sınıflandırma.....	122
6.3.1 Önerilen derin ağ modelleri ve AÇO-Tabanlı yöntem.....	122
6.3.2 Tekli-çoklu GKO içeren veri seti ve donanım/yazılım sistemi.....	124
6.3.3 Önerilen yöntemin farklı koşullarda performans değerlendirmesi	126
7. LİTERATÜRDEKİ YÖNTEMLERLE KARŞILAŞTIRILMA.....	130
7.1 Önerilen AMOD Tespit Yönteminin Literatürle Karşılaştırılması	130
7.2 Önerilen GKO Sınıflandırma Yöntemlerinin Literatürle Karşılaştırılması....	132
8. ENDÜSTRİYEL PROTOTİP GERÇEKLEŞTİRİLMESİ	137
8.1 Geliştirilen LabVIEW-Tabanlı Yazılım.....	137
8.2 Uygulamaya İlişkin Donanım Sistemi	141
8.3 Gerçek Zamanlı Test Sisteminden Elde Edilen Sonuçlar	143
9. SONUÇLAR VE TARTIŞMA	146
KAYNAKLAR	151
ÖZGEÇMİŞ.....	164

KISALTMALAR

AÇO	: Ağırlıklı Çoğunluk Oylaması
ADB	: Algılama Dışı Bölge
ADD	: Ayrık Dalgacık Dönüşümü
AKDD	: Ampirik Dalgacık Dönüşümü
AMA	: Ampirik Mod Ayırıştırması
AMOD	: Ada Mod
AOSA	: Adaptif Olasılıksal Sinir Ağı
BKV	: Bulanık Mantık Karar Verici
CB	: Kesici
ÇÇA	: Çoklu Çözünürlük Analizi
CD	: Curvelet Dönüşümü
CP	: Control Pilot
DAQ	: Data Acquisition
DbN	: Daubechies-N
DD	: Dalgacık Dönüşümü
DESA	: Derin Evrişimsel Sinir Ağları
DG	: Dağıtık Generatör
DGM	: Darbe Genişlik Modülasyonu
DMD	: Değişken Mod Dönüşümü
DÖ	: Derin Öğrenme
DPD	: Dalgacık Paket Dönüşümü
DSA	: Derin Sinir Ağı
DUKSB	: Derin Uzun Kısa Süreli Bellek
DVM	: Destek Vektör Makinesi
EA	: Elektrikli Araç
EÖK	: Elektronik Ölçüm Kartı
ESA	: Evrişimsel Sinir Ağları
EVSE	: Electric Vehicle Supply Equipment
FD	: Fourier Dönüşümü
FV	: Fotovoltaik

GA	: Genetik Algoritma
GAKA	: Gradyan Artırıcı Karar Ağaçları
GK	: Güç Kalitesi
GKO	: Güç Kalitesi Olayı
HFD	: Hızlı Fourier Dönüşümü
HHD	: Hilbert-Huang Dönüşümü
IEC	: International Electrotechnical Commission
IEEE	: Institute of Electrical and Electronics Engineers
KA	: Karar Ağacı
KDD	: Kuaternion Dalgacık Dönüşümü
kNN	: k-en Yakın Komşu
KOYP	: Katı Oksit Yakıt Pili
KZFD	: Kısa Zamanlı Fourier Dönüşümü
NSGA-II	: Baskın Olmayan Sıralama Genetik Algoritması-II
OBN	: Ortak Bağlantı noktası
OFP	: Over Frequency Protection
ÖİDD	: Örnek İndirgenmemiş Dalgacık Dönüşümü
OSA	: Olasılıksal Sinir Ağı
OVP	: Over Voltage Protection
PC	: Personal Computer
PCA	: Temel Bileşen Analizi
PP	: Proximity Pilot
ReLU	: Rectified Linear Unit
RES&SGs	: Renewable Energy Systems and Smart Grids
RMS	: Root Mean Square
RO	: Rastgele Orman
RoCoF	: Frekans Değişim Oranı
RoCoP	: Güç Değişim Oranı
SA	: Sıkıştırılmış Algılama
SD	: S-Dönüşümü
SDD	: Sürekli Dalgacık Dönüşümü
SNR	: Sinyal-Gürültü-Oranı
SSR	: Katı Hal Rölesi
THB	: Toplam Harmonik Bozulma
TTD	: Zaman-Zaman Dönüşümü

UABCŞ	: Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
UFP	: Under Frequency Protection
UKSB	: Uzun Kısa Süreli Bellek
UVP	: Under Voltage Protection
V2G	: Araçtan Şebekeye
WVD	: Wigner-Ville Dağılımı
YE	: Yenilenebilir Enerji
YEK	: Yenilenebilir Enerji Kaynağı
YÖK	: Yığılanmış Özdevimli Kodlayıcılar
YSA	: Yapay Sinir Ağı
YZ	: Yapay Zeka



SEMBOLLER

\tilde{V}_j	: ÖİDD ölçeklendirme katsayıları vektörü
\tilde{W}_j	: ÖİDD dalgacık katsayıları vektörü
\tilde{g}_k	: Yeniden ölçeklendirililen g_k
\tilde{h}_k	: Yeniden ölçeklendirililen h_k
$\Psi_{s,b}^*$: $\psi_{s,b}$ 'nin karmaşık eşleniği
σ_i^2	: Varyans
C_j	: Sınıflandırıcı oyu
D_i	: Giriş görüntüsü derinliği
H_i	: Giriş görüntüsü yüksekliği
I_{PN}	: Akım sensörü birincil sargı nominal RMS akımı
O_t	: Çıkış kapısı
P_{inv}	: İnverter çıkış gücü
P_n	: Gürültü ortalama gücü
P_s	: Sinyal ortalama gücü
$P_{yük}$: RLC yükünün gücü
Q_f	: Kalite faktörü
S_n	: Görünür güç
U_c	: Aday katman tekrarlayan ağırlık matrisleri
U_f	: Unutma kapısı tekrarlayan ağırlık matrisleri
U_i	: Giriş kapısı tekrarlayan ağırlık matrisleri
U_o	: Çıkış kapısı tekrarlayan ağırlık matrisleri
V_{max}	: Aşırı gerilim eşik sınırı
V_{min}	: Düşük gerilim eşik sınırı
V_{nom}	: Nominal gerilim
W_c	: Aday katman ağırlık matrisleri
W_f	: Unutma kapısı ağırlık matrisleri
W_i	: Giriş görüntüsü genişliği
W_i	: Giriş kapısı ağırlık matrisleri

W_o	: Çıkış kapısı ağırlık matrisleri
b_c	: Aday katman ek girdisi
b_f	: Unutma kapısı ek girdisi
b_i	: Giriş kapısı ek girdisi
b_o	: Çıkış kapısı ek girdisi
c_t	: Mevcut hücre durumu
c_{t-1}	: Önceki hücre durumu
c_0	: 1-D giriş sinyali
f_{max}	: Aşırı frekans eşik sınırı
f_{min}	: Düşük frekans eşik sınırı
$f_{resonance}$: Rezonans frekansı
f_t	: Unutma (forget) kapısı
g_k	: Ölçeklendirme filtresi (dörtlü ayna filtresi)
h_k	: Dalgacık filtresi
h_t	: Gizli hücre durumu
h_{t-1}	: Gizli durum
h_0	: Yüksek geçiren filtre
h_1	: Alçak geçiren filtre
i_t	: Giriş kapısı
n_n	: Devir sayısı
w_o	: Açısal rezonans frekansı
\hat{y}	: Sınıf etiketi
$\Psi_{s,b}$: Sürekli dalgacık fonksiyonu
α_i	: AÇO değişim katsayısı
ΔP	: Gerçek güç uyumsuzluğu
ΔQ	: Reaktif güç uyumsuzluğu
A	: Amper
C	: Ceza (penalty) katsayı
cA_n	: Yaklaşım katsayıları
cD_n	: Detay katsayıları
dB	: Desibel
Hz	: Hertz
kb/s	: Kilo Byte/Sn
kHz	: Kilohertz
mF	: Milifarad

mH	: Milihenry
pu	: Birim deęer
V	: Volt
Ω	: Ohm
W	: Watt
$ADD(s, b)$: ADD iřlemi
E	: Entropi
En	: Enerji
K	: Alt rnekleme yntemi filtre boyutu
$K(x_i, x_j)$: ekirdek fonksiyonu
S	: Kaydırma penceresi adım boyutu
$SDD(s, b)$: SDD iřlemi
V	: Sistem gerilimi
X	: Zaman serisi sinyal
Y	: ıktı grnts meknsal boyutu
b	: Kaydırma faktr
b	: Sapma
$d(p1, p2)$: Euclidean mesafesi
f	: Sistem frekansı
$f(t)$: Srekli zamanlı sinyal
ms	: milisaniye
s	: leklendirme faktr
sn	: Saniye
t	: Zaman adımı
\tanh	: Hiperbolik tanjant
μ	: Ortalama
$\mu(x)$: gen bulanık yelik fonksiyonu
σ	: Sigmoid
σ	: Standart sapma

ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1 : Pasif AMOD tespit yöntemlerinin ayrıntılı karşılaştırması.....	12
Çizelge 1.2 : DD tekniklerinin, GKO tespit ve sınıflandırılma performansları.....	16
Çizelge 2.1 : AMOD çalışma ile ilgili standartlar.	25
Çizelge 2.2 : Şebeke etkileşimi için gerilim ve frekans sınırları.	26
Çizelge 2.3 : GKO kategorizasyonu [115].	28
Çizelge 2.4 : Gerilim THB sınır değerleri	28
Çizelge 2.5 : Ara harmonikler için sınır değerler	29
Çizelge 2.6 : Anahtarlama elemanlarında kaynaklı çentiklerinde önerilen sınırlar...	29
Çizelge 2.7 : GKO'ların nedenleri, etkileri ve dalga biçimleri.....	30
Çizelge 4.1 : GKO üretiminin matematiksel modeli.	56
Çizelge 4.2 : Benzetim modeli oluşturulan sistem parametreleri.	60
Çizelge 5.1 : Farklı dalgacık türleri için hesaplama süreleri.	85
Çizelge 5.2 : Farklı dalgacık türleri için hesaplama süreleri.	86
Çizelge 5.3 : Çalışılan DD-Tabanlı yöntemler için katsayı tepe değerleri.	94
Çizelge 6.1 : BKV kuralları.	102
Çizelge 6.2 : ÖİDD-BKV tabanlı yöntemin doğruluğu.	105
Çizelge 6.3 : Gerçek GKO veriler için sınıflandırma sonuçları.	106
Çizelge 6.4 : Uygulanan istatistiksel süreç sonrasında seçilmiş öznelilikler.....	110
Çizelge 6.5 : Parametre seti.	115
Çizelge 6.6 : Sınıflandırıcıların test veri seti doğruluk performansı.	116
Çizelge 6.7 : ÖİDD-DVM test sonuçları için karışıklık matrisi (gürültüsüz).	117
Çizelge 6.8 : ÖİDD-DVM test sonuçları için karışıklık matrisi (SNR=40 dB).	117
Çizelge 6.9 : ÖİDD-DVM test sonuçları için karışıklık matrisi (SNR=30 dB).	118
Çizelge 6.10 : ÖİDD-DVM test sonuçları için karışıklık matrisi (SNR=25 dB). ...	118
Çizelge 6.11 : Benzetim modelinden üretilen veri seti üzerindeki performans.....	121
Çizelge 6.12 : Gerçek veri seti üzerindeki performans.....	122
Çizelge 6.13 : Tekli ve kompleks GKO sınıfları.	125
Çizelge 6.14 : GKO parametreleri.	125
Çizelge 6.15 : Derin modellerin performans karşılaştırması.	126
Çizelge 6.16 : En çok karıştırılan ve en iyi tahmin edilen sınıflar.	127
Çizelge 6.17 : AÇO mekanizması ile tekli ve çoklu ağ modellerinin performansı.	127
Çizelge 6.18 : Simülatif veri sonuçları.	128
Çizelge 6.19 : Gerçek veri sonuçları.....	129
Çizelge 7.1 : Önerilen yöntemin literatürdeki yöntemlerle karşılaştırılması.....	131
Çizelge 7.2 : DD-Tabanlı otomatik tespit yöntemlerinin karşılaştırılması.....	132
Çizelge 7.3 : Önerilen yöntemin literatürdeki yöntemlerle karşılatırılması.	132
Çizelge 7.4 : GKO sınıflandırma yöntemlerinin literatürle karşılaştırılması.	133
Çizelge 8.1 : Chroma 61500-5 sınıf için veri dağılımı.	144

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : DG sistemlerin şebeke üzerindeki olumlu ve olumsuz etkileri.....	1
Şekil 1.2 : AMOD çalışma tespit yöntemleri.....	6
Şekil 1.3 : Geleneksel pasif AMOD tespit yöntemlerinin genel çalışma şeması	7
Şekil 1.4 : Aktif AMOD tespit yöntemlerinin genel çalışma blok şeması	8
Şekil 1.5 : Uzaktan izleme ile AMOD tespit yöntemlerinin genel blok şeması	8
Şekil 1.6 : Hibrit AMOD tespit yöntemlerinin genel blok şeması [28].....	9
Şekil 1.7 : Gelişmiş pasif AMOD tespit yöntemlerinin genel blok şeması.....	10
Şekil 1.8 : GKO tespitinde kullanılan sinyal analiz yöntemleri [22, 88].....	14
Şekil 1.9 : GKO sınıflandırmasında kullanılan YZ yöntemleri.....	18
Şekil 2.1 : EA ve EA şarj istasyonlarının etkileri.....	31
Şekil 3.1 : ÇÇA ile ADD ayrıştırmasında detay ve yaklaşım katsayıları.....	34
Şekil 3.2 : Önerilen DESA Modeli.....	46
Şekil 3.3 : UKSB birim yapısı.....	48
Şekil 3.4 : Önerilen DUKSB Modeli.....	49
Şekil 3.5 : Önerilen hibrit model.....	50
Şekil 3.6 : BKV-Tip1 blok diyagramı	52
Şekil 4.1 : İntegral-Tabanlı yöntemle GKO üretim yazılımının arayüzü.....	54
Şekil 4.2 : Matematiksel model ile üretilen (a) C2 ve (b) C19 sınıfları.....	56
Şekil 4.3 : (a) Modellenen sistemin şematik görünümü, (b) Simulink modeli	59
Şekil 4.4 : OBN noktasındaki nominal, gerilim kesintisi ve gerilim çökmesi olayları anındaki anlık ve etkin gerilim dalga formları.....	62
Şekil 4.5 : Salınlımlı geçici ve darbeli geçici olaylar ile çentiklerin oluşturduğu OBN'deki gerilim dalga biçimleri	63
Şekil 4.6 : Test sistemi üzerinden elde edilen verilerin dağılımı.....	64
Şekil 4.7 : Farklı Qf değerleri için geleneksel yöntem ADB yanıtları.....	67
Şekil 4.8 : AMOD test sistemi-IEEE Std. 929-2000.....	67
Şekil 4.9 : Test sistemi genel yapısı ve kontrol ve izleme sistemi.....	68
Şekil 4.10 : Laboratuvar içi test sistemi genel görünüm.....	69
Şekil 4.11 : Deneysel sistem (Ayrıntılı görünüm).....	71
Şekil 4.12 : Test sistemi izleme ve kontrol arayüzü (ana sayfa).....	72
Şekil 4.13 : Test sistemi izleme ve kontrol arayüzü (dalga şekilleri sekmesi).....	73
Şekil 4.14 : Doğrusal/doğrusal olmayan yüklerden oluşan deneysel kurulum.....	74
Şekil 4.15 : AC-Mod-3 EA şarj ünitesi blok diyagramı.....	75
Şekil 4.16 : EA şarj sistemleri	76
Şekil 4.17 : BTÜ Yenilenebilir Enerji Sistemleri ve Akıllı Şebekeler Laboratuvarı genel şeması.....	77
Şekil 4.18 : Chroma AC 61501 serisi güç kaynağı yardımıyla veri üretimi.....	79
Şekil 5.1 : (a) SDD ile eşik değer-Tabanlı yöntem akış diyagramı, (b) SDD yönteminin LabVIEW blok diyagramı.....	81
Şekil 5.2 : ADD ile eşik değer-Tabanlı yöntem akış diyagramı.....	81

Şekil 5.3 : Önerilen Piramidal ÖİDD-Tabanlı yöntem akış diyagramı.	82
Şekil 5.4 : DD-Tabanlı gürültü azaltma yöntemlerinin karşılaştırılması.....	83
Şekil 5.5 : DD-Tabanlı tepe/çukur tespit yöntemlerinin karşılaştırılması.	84
Şekil 5.6 : Daubechies dalgacık ailesi örnekleri (db4, db8 ve db12).	84
Şekil 5.7 : Dalgacık türleri için süre hesaplamada kullanılan blok diyagram.	85
Şekil 5.8 : Senaryo-1 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.....	88
Şekil 5.9 : Senaryo-2 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.....	89
Şekil 5.10 : Senaryo-3 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.....	90
Şekil 5.11 : Senaryo-4 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.....	91
Şekil 5.12 : Senaryo-5 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.....	92
Şekil 5.13 : Senaryo-6 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.....	93
Şekil 6.1 : Geleneksel sinyal analiz yöntemleri için GKO tespit akış şeması.	96
Şekil 6.2 : Önerilen ÖİDD-BKV yöntemi.	97
Şekil 6.3 : Önerilen BKV sürecinin oluşturulması ve test edilmesi.	99
Şekil 6.4 : ÖİDD ayrıştırma işlemi ile elde edilen özellikleri içeren matris.	100
Şekil 6.5 : BKV'nin girişlerinin(d1-d8) ve çıkışının (C) bulanık alt kümeleri.	101
Şekil 6.6 : İşlenen aktif kuralların yüzey grafikleri.	102
Şekil 6.7 : C5 sınıfı için gürültüsüz ve gürültülü sinyallerde detay katsayılarının tepe değeri karşılaştırması.	104
Şekil 6.8 : Geliştirilen ÖİDD ve Sınıflandırıcı-Tabanlı yöntemler için geliştirme süreci.	107
Şekil 6.9 : 8-seviyeli ayrıştırmada katsayı bileşenlerinin frekans aralıkları.	108
Şekil 6.10 : Önerilen öznelik çıkarma işleminin mimarisi.	109
Şekil 6.11 : Geliştirilen ÖİDD analizi ve özellik çıkarım yazılımı blok paneli.	110
Şekil 6.12 : Gerilim çökmesi olayı için ADD ve önerilen ÖİDD-Tabanlı özneliklerin karşılaştırma sonuçları.	111
Şekil 6.13 : Salınlı geçici olay için ADD ve önerilen ÖİDD-Tabanlı özneliklerin karşılaştırma sonuçları.	112
Şekil 6.14 : Önerilen ÖİDD ve DVM-Tabanlı yöntemin akış şeması.	113
Şekil 6.15 : ÖİDD-GAKA test sonuçları (gürültüsüz veri seti).....	119
Şekil 6.16 : ÖİDD-GAKA test sonuçları (SNR=40 dB).	120
Şekil 6.17 : ÖİDD-GAKA test sonuçları (SNR=30 dB).	120
Şekil 6.18 : Önerilen yöntem ile geleneksel yöntemlerin karşılaştırılması.	123
Şekil 8.1 : Geliştirilen yazılım için genel akış diyagramı.....	138
Şekil 8.2 : 8-seviyeli ÖİDD ayrıştırması için LabVIEW blok diyagramı.	139
Şekil 8.3 : Öznelik çıkarımı LabVIEW blok diyagramı.	139
Şekil 8.4 : LabVIEW-Tabanlı model eğitim yazılımı.	140
Şekil 8.5 : Donanım sistemi.....	142
Şekil 8.6 : Test Sistemi.	142
Şekil 8.7 : Test 1 için inverter çıkış gerilimi grafiği.....	143
Şekil 8.8 : Test 2 için inverter çıkış gerilimi grafiği.....	144
Şekil 8.9 : GKO sınıflandırma test sonuçları.....	145

MİKROŞEBEKELERDE ADA MOD ÇALIŞMANIN TESPİTİ VE GÜÇ KALİTESİ OLAYLARININ SINIFLANDIRILMASI İÇİN YAPAY ZEKÂ TABANLI KONTROL YÖNTEMLERİNİN GELİŞTİRİLMESİ

ÖZET

Bu tez çalışmasında, şebeke koduna ve belirli standartlara uygun şekilde Ada mod (AMOD) çalışma ve güç kalitesi olaylarının (GKO) tespiti ve sınıflandırılması için literatüre katkıda bulunan özgün akıllı yöntemler önerilmiştir. Önerilen yöntemi kullanan izleme-tespit-koruma sistemi için prototip bir ürünün geliştirilmesi de tez kapsamında gerçekleştirilmiştir. Bu kapsamda, yenilenebilir enerji kaynakları (YEK) ve elektrik araç (EA) şarj ünitelerini içeren bir mikroşebeke test sistemi de oluşturulmuştur. Literatürde, konu hakkında araştırma yapan bilim insanlarının çalışmalarında kullanmak için bulmakta zorlandığı doğrulanmış bir veri setinin olmaması önemli bir sorundur. Deneysel sistem ile üretilerek doğrulanmış ve çok çeşitli GKO'larını içerisinde barındıran geniş kapsamlı bir GKO ve AMOD çalışma veri setinin tez kapsamında sunulması, tezin önemli diğer bir katkısı olarak değerlendirilmiştir.

AMOD Çalışma'nın tespiti, GKO'ların ve AMOD Çalışma'nın birbirinden ayırt edilmesi konuları, güç sisteminin kararlılığı ve güvenilirliği, DG'lerin şebekeye entegrasyonu ve güç kalitesi açısından literatürde oldukça önemlidir. AMOD çalışma tespit yöntemleri, YEK-Tabanlı DG'lerin ve EA şarj sistemleri gibi lineer olmayan yüklerin olduğu sistemlerde hatalı açma yapabilmektedir. Bu problemin üstesinden gelmek için tek fazlı DG'lerdeki AMOD çalışma araştırılmış ve fotovoltaik (FV)-Tabanlı bir sistem için yeni bir örnek indirgenmemiş dalgacık dönüşümü (ÖİDD)-Tabanlı yöntem önerilmiştir. Piramidal ÖİDD-Tabanlı AMOD çalışma tespit yaklaşımı, güç uyumsuzluğunun minimum olduğu en zor şartlar da dahil olmak üzere farklı mod çalışma koşulları ve üretilen GKO'lar için geliştirilen gerçek zamanlı deneysel sistemle de doğrulanmıştır. Önerilen yöntem, yüksek gürültü koşulları için bile AMOD çalışma tespit performansını önemli ölçüde iyileştirmektedir. ÖİDD-Tabanlı yöntem, ortalama 75 ms'de AMOD çalışmayı yaklaşık sıfır ADB ile tespit edebilmektedir. Bu avantajlarıyla, önerilen yöntem, farklı DG'ler için güvenilir ve kolaylıkla kullanılabilir bir koruma sağlar.

Mikroşebekelerde meydana gelen güç kalitesi (GK) sorunları, geleneksel güç sistemindeki olaylara benzemekle beraber, bazı şebeke işletim operasyonları nedeniyle çok daha zor tanımlanır. Mikroşebekelerde, rüzgar hızı ve güneş ışınım değerlerindeki değişim gibi çevresel faktörler, şebeke ve yük tarafında dengesizliklere neden olabilir. Ayrıca, DG'lerin devreye girmesi/çıkması, YEK-Tabanlı DG'lerin şebekeye entegrasyonunda kullanılan dönüştürücü ve inverter gibi güç elektroniği cihazlarındaki artış ve son yıllardaki gelişmelerle birlikte sayıları hızla artan EA şarj istasyonları gibi lineer olmayan yüklerdeki çoğalma, geleneksel sistemlerdekinden farklı tipte GKO'lara sebep olmaktadır.

Bu problemlerin üstesinden gelmek için tez çalışmasında GKO olaylarının sınıflandırılması için dört farklı yöntem önerilmiştir. İlk önerilen yöntem, ÖİDD-Tabanlı öznelik çıkarma işlemi ve çoklu çekirdek içeren destek vektör makinesi (DVM) sınıflandırıcı içeren hibrit bir makine öğrenmesi yapısıdır. Önerilen öznelik çıkarım sürecinin performans iyileştirmesini kanıtlamak için diğer DD-Tabanlı yöntemlerle karşılaştırmalar yapılmıştır. Ayrıca ÖİDD'nin performansı farklı sınıflandırıcı modelleri için de incelenmiştir. Sonuçta, DD'ye dayalı olarak geliştirilen ancak gürültü altında düşük performansa sahip olan sınıflandırıcıların performansı, ÖİDD ile önemli ölçüde iyileştirilmiştir. ÖİDD ve DVM-Tabanlı hibrit yöntem, 25 dB ile 40 dB gürültü altında bile yüksek doğruluk ve güvenilirlikle GKO sınıflandırması yapabilmektedir. GKO'lar için genel tanıma testi doğruluğu, önerilen ÖİDD ve DVM tabanlı hibrit yöntem için %99,85'tir. Önerilen ikinci yöntem olan ÖİDD-Gradyan artırıcı karar ağaçları (GAKA)-Tabanlı GKO sınıflandırma yönteminde ise Piramidal ÖİDD ile sınıflandırma başarımları oldukça yükseltilmiştir. Test/tahminde en hızlı algoritma olan GAKA'nın performansındaki düşüşler genellikle sinyaldeki gürültünün aşırı uydurulmasından kaynaklanmaktadır. ÖİDD süreci ile bu dezavantaj ortadan kalkmakta ve nominal koşullardaki gibi yüksek bir sınıflandırma doğruluğu elde edilebilmektedir. Önerilen yöntem düşük seviyeli gürültü koşullarında %99,50, yüksek seviyeli gürültü koşullarında ise %99,29 sınıflandırma doğruluğuna sahiptir. Üçüncü önerilen yöntem ise bulanık mantık karar verici (BKV) ile ÖİDD ayrıştırmasından oluşan adaptif özellikteki şemadır. Bu şema, özellikle eşik değeri içeren tespit ve sınıflandırma yöntemlerindeki gürültülü koşullardan kaynaklanan belirsiz durumlar nedeniyle yanlış algılama ve eksik algılama eğilimini önlemek için oluşturulmuştur. 20-40 dB yüksek seviyeli gürültü koşullarında ise %94,96 sınıflandırma doğruluğuna sahiptir. Önerilen dördüncü yöntem ise derin ağ modelleri ve ağırlıklı çoğunluk oylaması (AÇO) içeren yöntemdir. Otomatik özellik çıkarma ve sınıflandırma için kapalı döngü derin evrimsel sinir ağları (ESA), uzun kısa süreli bellek (UKSB) ve hibrit (ESA-UKSB) modeller kullanılmaktadır. Derin ESA-UKSB yapısında, öznelik çıkarımı için ESA'nın ve zaman serisi veri işleme için UKSB'nin avantajları, karmaşık GKO sınıflandırma doğruluğunu iyileştirmek için kullanılmıştır. Önerilen derin ağlar-AÇO gürültüsüz ortamda %99,26, düşük seviyeli gürültüde %98,58 ve yüksek seviyeli gürültüde %98,05 doğruluk oranına sahiptir. Ayrıca, gerçek veriler için sınıflandırma doğruluğu %97,78'dir.

Tez sonrasındaki AMOD çalışma tespitine yönelik yaklaşımların, veri sayısının artırılması ve önerilen algoritmanın FPGA-Tabanlı bir karta gömülmesine odaklanması hedeflenmektedir. Tezde önerilen gelişmiş yapay zeka temelli pasif yöntem, çoklu inverter yapılarına uygundur. Ancak gerçek zamanlı testleri laboratuvar imkanları nedeni ile bu çalışmada gerçekleştirilememiştir. İlerleyen süreçte iki veya daha fazla şebeke bağlantılı DG içeren bir test sistemi kurularak bu testlerin de gerçekleştirilmesi düşünülmektedir. Diğer yandan, IoT ve 5G teknolojisini içeren akıllı şebekelerde GKO'ların tespiti ve sınıflandırılması da gelecek çalışmalar kapsamında değerlendirilecektir. Bununla birlikte, gelecekteki GKO sınıflandırma/tespit çalışmaları, optimizasyon yöntemleri gibi özellik seçim tekniklerini kullanarak özellik vektörünü azaltmaya da odaklanmalıdır.

Anahtar kelimeler: Ada mod çalışma, Güç kalitesi olayları, Dalgacık Dönüşümü, Makine Öğrenmesi, Dağıtık generatörler, Akıllı şebekeler

DEVELOPMENT OF ARTIFICIAL INTELLIGENCE BASED CONTROL METHODS FOR DETECTION OF ISLANDING CONDITIONS AND CLASSIFICATION OF POWER QUALITY EVENTS IN MICROGRIDS

SUMMARY

This thesis proposes intelligent methods for islanding condition and Power Quality Event (PQE) detection/classification in accordance with the Grid Code and certain standards. At the same time, a prototype product for the monitoring-detection-protection system using the proposed method has been developed. In this context, a microgrid test system including renewable energy sources (RES) and electric vehicle (EV) charging stations has been established. In addition, the lack of a common data set that can be used and evaluated for the performance of the method, which is an important gap in the literature, has been attempted to be overcome. Data sets consisting of mathematical, simulated and test system real data for event signals will provide convenience to researchers in the field.

Conventional passive and advanced passive islanding detection methods can lead to inaccurate tripping in systems with non-linear loads such as renewable energy based DG and EV charging systems. To overcome this problem, islanding in single-phase DGs is investigated and a new un-decimated wavelet transform (UWT)-based method is proposed for a PV system. The pyramidal UWT-based approach for detecting islanding mode operation is validated by a real-time experimental setup for different mode operation conditions and generated PQEs, including the most severe conditions where the power mismatch is minimal. The proposed method significantly improves the islanding detection performance even under high noise conditions. The UWT-based method is able to detect the islanding mode operation in an average of 75 ms with approximately zero non-detection zone(NDZ). With these advantages, the proposed method provides reliable and easy-to-use protection for various DGs.

Power quality (PQ) problems occurring in microgrids are similar to the phenomena in conventional power systems, but are much more difficult to identify due to some operating operations. In microgrids, environmental factors such as variations in wind speed and solar irradiance can cause instabilities on both the grid and load side. In addition, the start-up/start-up of DGs, the increase in power electronics devices such as converters and inverters used in the integration of RES-based DGs into the grid, and the proliferation of non-linear loads such as EV charging stations, the number of which has been increasing rapidly with the developments in recent years, cause different PQEs than in conventional systems. To overcome these problems, four different methods are proposed in this thesis for the classification of PQEs. The first proposed method is a UWT-based feature extraction process and a support vector machine (SVM) classifier with multiple kernels for the classification of SCOs in DGs. Comparisons with other WT-based methods are made to prove the performance improvement of the proposed feature extraction process. In addition, the performance of the WT-based feature extraction process is also analysed for different classifier

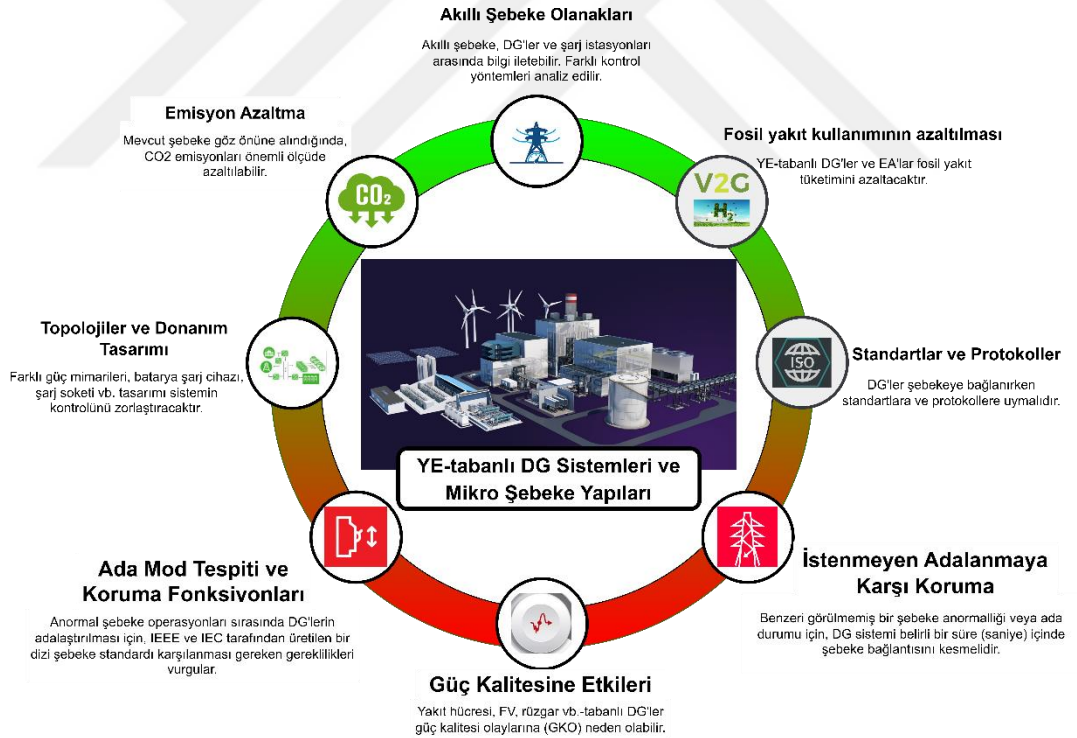
models. As a result, the performance of the classifiers developed based on WT, which have poor performance under noise, is significantly improved by the UWT. The proposed hybrid method based on UWT and SVM is able to classify PQEs with high accuracy and reliability even under 25 to 40 dB noise. The overall recognition test accuracy for PQEs is 99.85% for the proposed UWT and DVM-based hybrid method. The classification accuracy under low level noise and high level noise conditions are 99.66% and 99.32%, respectively. In the second proposed method, the UWT-Gradient boosting decision tree (GBDT)-based PQE classification method, the classification performance is significantly improved with pyramidal UWT. The performance degradation of GBDT, which is the fastest algorithm in test/forecast, is usually due to over-fitting of the noise in the signal. This disadvantage is eliminated with the UWT process and a high classification accuracy can be obtained as in nominal conditions. The test accuracy is 99.59 per cent for the UWT-GBDT under noise-free conditions. In addition, the proposed method has a classification accuracy of 99.50% under low level noise conditions and 99.29% under high level noise conditions. The third proposed method is an adaptive scheme consisting of a fuzzy logic decision maker (FDM) and a UWT decomposition. This scheme was created to avoid the tendency of false detection and underdetection due to uncertainty caused by noisy conditions, especially in threshold detection and classification methods. The test accuracy of the mathematical and simulated data is 96.13% for the FDM method using pyramidal UWT under noiseless conditions. In 20-40 dB high level noise conditions, the classification accuracy is 94.96%. The fourth proposed method includes deep network models and weighted majority voting (WMV). Closed-loop deep convolutional neural networks (CNN), long short-term memory (LSTM) and hybrid (CNN-LSTM) models are used for automatic feature extraction and classification. In the deep CNN-LSTM structure, the advantages of CNN for feature extraction and LSTM for time series data processing are utilised to improve the complex PQE classification accuracy. The proposed deep networks-WMV has an accuracy of 99.26% in noise-free environment, 98.58% in low-level noise and 98.05% in high-level noise. Moreover, the classification accuracy for real data is 97.78%

Future island mode detection work focuses on increasing the number of data and embedding the proposed algorithm on a field programmable gate array (FPGA)-based board. The proposed advanced passive method is suitable for multiple inverter structures, but real-time tests could not be performed. In the future, a test system with two or more grid-connected DGs is planned to be built to perform these tests. On the other hand, the focus will be on the detection and classification of PQEs in smart grids including IoT and 5G technology. However, future PQE classification/detection studies should focus on reducing the feature vector using feature selection techniques such as optimisation methods.

Keywords: Islanding operation, Power quality events, Wavelet transform, Machine learning, Distributed generators, Smart grids

1. GİRİŞ

Bugünlerde araştırmacılar tarafından sınırlı fosil yakıt sürdürülebilirliği, çevresel endişeler ve artan enerji talebi evrensel konular olarak kabul edilmekte ve uygun çözümler bulmak için geniş çapta ele alınmaktadır. Fotovoltaik (FV), rüzgar, hidrojen vb. yenilenebilir enerji (YE)-Tabanlı dağıtık generatörler (DG) ile araç-şebeke bağlantı (V2G) desteği içeren elektrikli araç (EA) şarj üniteleri bu sorunların çözümünde ön plana çıkmaktadır [1,2]. Bu nedenle, sayıları hızla artan bu sistemlerin şebekeye entegrasyonu önemli bir konu haline gelmiştir [3]. Şekil 1.1’de, YE-destekli DG’ler ile mikroşebeke yapılarının şebeke üzerindeki olumlu ve olumsuz etkileri özetlenmektedir.



Şekil 1.1 : DG sistemlerin şebeke üzerindeki olumlu ve olumsuz etkileri.

Sürdürülebilir güç akışının sağlanması hem tüketici hem de üretici tarafı için güvenilir bir şebeke entegrasyonu ile mümkündür. Güç sisteminin sürdürülebilirliği ve güvenilirliğini sağlamada yüksek güç kalitesi (GK) ile birlikte en önemli kriter ise Ada

Mod (AMOD) çalışmanın tespiti ve gerekli koruma yapısının sağlanmasıdır. IEEE 929-2000 [4] standardı tarafından tanımlanan AMOD çalışma, dağıtım sisteminin şebekeye elektriksel olarak izole olduğu ancak bir veya daha fazla yerel DG tarafından ortak bağlantı noktası (OBN) üzerinden hala enerjilendirildiği durumdur [5,6]. Bir mikroşebekede istenmeyen AMOD çalışma durumunun tespit edilememesi hem sistem (DG ve ilgili ekipmanın hasarı) hem de insan hayatı (bakım çalışanları ve tüketiciler) için ciddi zararlara neden olabilir. Sonuç olarak, AMOD çalışmanın zamanında tespiti, bir DG sistemi için en gerekli koruma tedbiri olarak kabul edilir. DG’de üretilen gücün, yükün gücüne yakın ya da eşit olması durumunda AMOD çalışmanın tespiti, daha da zor bir konu haline gelmektedir [7]. IEEE 1547-2018 standardına göre AMOD tespiti, 0.16 ile 2 saniye arasında bir süre içinde gerçekleştirilmelidir [8]. Bu nedenle AMOD tespiti, şebeke kodunda belirtilen güvenilirlik, güvenlik ve hızlı tepki süresi gereksinimlerini karşılamalıdır.

Güç sisteminde meydana gelen herhangi bir gerilim ve frekans değeri standartlarla belirlenen kabul edilebilir sınırları aşarsa, DG sistemi mümkün olan en kısa sürede şebekeden fiziksel olarak izole edilmelidir. Bu açıdan bakıldığında, DG sisteminin AMOD çalışmayı standartlarda belirtilen süre içinde tespit edebildiği etkin yöntemlere ihtiyaç duyulmaktadır [9]. YE-Destekli DG sistemler yaygın hale geldikçe AMOD tespiti çeşitli zorlukları da beraberinde getirmektedir. Rüzgar hızı ve ışınım gibi değişken durumlardaki DG sistem tepkileri, DG’lerin devreye alınması/devreden çıkarılması, sistemdeki kısa devre arızaları, motorların ve trafoların enerjilendirilmesi, büyük güçte yük/kapasite banklarının devreye alınması/çıkarılması, lineer olmayan yükler, sürücüler, vb. olaylar güç kalitesi olayı (GKO) olarak adlandırılan küçük bozulmalara neden olur. GKO’lar, AMOD çalışma durumu olarak algılanırsa, DG sistemler istenilmeden kontrolsüzce devreden çıkabilir ve şebekede büyük kesintiler (blackout) oluşabilir. Ayrıca, bu durum hem üretici hem de tüketici için ekonomik kayıplara neden olur. Sonuç olarak, AMOD çalışma ve AMOD olmayan arıza durumlarını (GKO vb. küçük bozulmalar) doğru bir şekilde tespit etmek ve ayırt etmek son derece önemlidir. Burada, DG yük talebinin farklı şebeke koşullarında değerlendirilmesi ve tüm olası yük durumu senaryolarında testlerin yapılması, sistem güvenilirliği ve sürdürülebilirliği için önemlidir [10].

Geleneksel AMOD tespit yöntemleri, uzaktan ve yerel (pasif, aktif ve hibrit) yöntemler olmak üzere iki ana başlık altında incelenebilir [9]. Pasif yöntemler, AMOD çalışmayı

tespit etmek için gerilim, akım, güç, frekans, harmonik bozulma vb. değerleri ölçerek belirlenen eşik değerlere göre karar verir [11,12]. Pasif yöntemler hızlıdır ve sistemde bir bozulmaya neden olmazlar. Ancak AMOD çalışmanın tespitinde hatalara neden olan, büyük bir algılama dışı bölgeye (ADB-Non Detection Zone) sahiptirler. ADB, AMOD olayının meydana geldiği ancak tespit edilemediği alanı ifade etmekte olup, başarımı yüksek bir AMOD tespit yönteminde ADB'nin minimum hatta sifıra yakın olması beklenmektedir. Aktif yöntemler genellikle şebekeye eklenen küçük genlikli sinyallerde meydana gelen değişimleri kontrol eder. Bu yöntemlerde ADB pasif yöntemlere göre oldukça küçük olmasına karşın, ADB tam olarak sıfırlanamadığı için GK'yi olumsuz etkilerler. Hibrit yöntemler hem aktif hem de pasif yöntemlerin bir arada olduğu yöntemlerdir. Hibrit yöntemlerde, pasif yöntemlerdeki yüksek ADB, aktif yöntemle giderilmeye çalışılmaktadır. Ayrıca yerel yöntemler, eşik değerinin belirlenmesinde zorluk, çalışma koşullarından kaynaklanan belirsizlikler ve gürültüye karşı hassasiyet gibi önemli dezavantajlara sahiptir. Uzaktan izleme yöntemleri ise şebeke ve DG'ler arasındaki iletişime dayalı olarak çalışmaktadır. Bu yöntemler minimum ADB içermekte olup GK'yi olumsuz etkilememektedir. Ancak bu yöntemlerde de şebeke tarafında ek iletişim aygıtlarına ve özel sensörlere ihtiyaç duyulduğundan sistem ve işletme maliyetleri aşırı yüksektir [11].

Son yıllarda ise geleneksel metodolojilerin sınırlamalarının üstesinden gelmek için, sinyal analizi, optimizasyon teknikleri ve makine öğrenmesi yöntemleri kullanan gelişmiş veya değiştirilmiş pasif yöntemler literatüre sunulmaktadır [10,13]. Gelişmiş pasif teknikler sinyal analizi teknikleriyle beraber durum tahmini-Tabanlı, optimizasyon yöntemi-Tabanlı [14] ve sınıflandırıcı-Tabanlı [15] olmak üzere gruplandırılabilir. Sinyal Analizi-Tabanlı tekniklerin uygulandığı bazı çalışmalarda gürültüsüz koşullarda çok yüksek doğruluk elde edilirken, yüksek gürültülü koşullarda bu doğruluğun düştüğü gözlemlenmiştir [10]. Sınıflandırıcı kullanan yöntemlerde ise özellik çıkarım süreci optimizasyon yöntemi kullanıldığında uzun sürmekte aksi halde keyfi bir hal almaktadır [16]. Bu yöntemlerin dezavantajı, hibrit bir yöntemin [17] kullanılmasının gerekliliği, gerçek zamanlı sistemlere uygulanmasındaki zorluklar ve çalışmaların sadece simülasyon aşamasında kalmasıdır.

Sonuç olarak başarımı yüksek bir AMOD tespit yönteminin aşağıdaki özelliklere sahip olması gerekir [8]:

- FV, rüzgar, yakıt pili gibi farklı özelliklere sahip DG sistemleri için uygulanabilir olmalıdır.
- Sınırlı sayıda ölçüm cihazı kullanarak minimum maliyette tasarlanmalıdır.
- Kullanılan ölçüm parametreleri gerilim, akım, toplam harmonik vb. minimum sayıda olmalıdır.
- Özellikle DG'deki güç üretimin yükün gücüne eşit veya yakın olması durumu başta olmak üzere farklı şebeke çalışma senaryoları gerçekleştirilerek yöntem doğrulanmalıdır.
- AMOD koşulları ve AMOD olmayan küçük bozulmalar (GKO), DG yük talebi de dikkate alınarak kapsamlı bir şekilde test edilmelidir.
- ADB minimum olmalı ve algılama süresi IEEE 929-2000, IEEE 1547-2018 ve IEC 62116 standartlarında belirtilen sürenin altında olmalıdır.
- AMOD tespit sistemi, sistem kararlılığını bozmamalı ve GK'ye olumsuz etkide bulunmamalıdır.

GK tanımı, ilk kez 1968 yılındaki bir kaynakta [18] geçmekle beraber, lineer olmayan yüklerin giderek artması, akıllı şebeke yapılarının temel bileşeni olan mikroşebeke yapılarının oluşması ve DG'lerin yaygınlaşması gibi nedenlerle ilgi çeken bir konu haline gelmiştir. GK, gerilim ve akım karakteristiği ile doğrudan ilgilidir ve ideal dalga formundan sapmaya yol açan bir problem GKO olarak isimlendirilir [19]. Gerilim çökmesi, gerilim sıçraması, gerilim kesintisi, akım ve gerilim harmonikleri, geçici rejim olayları, çentik oluşumu, kırpışma ve sistemdeki gerilim dengesizlikleri GKO tanımları ayrıntılı olarak [20] referansında bulunabilir.

Mikroşebeke uygulamalarında GKO sinyallerini tanımlamak geleneksel güç sistemlerine oranla daha zor olmakla beraber, mikroşebekede meydana gelen sorunlar geleneksel sistemlere benzer özellikler gösterir. Geleneksel sistemlerde olduğu gibi, kısa devre arızaları, büyük güçlü yüklerin ve büyük kapasitör banklarının anahtarlanması, sürücü sistemleri varlığı ve transformatörlerin enerjilendirilmesi mikroşebekede geçici veya ani akım/gerilim yükselmelerine, gerilimde dalgalanmalara ve yol açacaktır [21]. Bununla birlikte, DG yapısı mikroşebekelerin önemli bir parçasıdır [22]. DG'lerin devreye alınması veya devreden çıkarılması, doğrusal olmayan yüklerin varlığı, inverter kontrol stratejileri, çalışma modu değiştirme gibi mikroşebekelere özgü GKO'lara neden olan durumlar da oluşmaktadır [23]. Ayrıca, güneş ışınımı ve rüzgar hızı gibi çevresel etkenlerdeki değişim de YE-

temelli DG sistemlerinde GK'nin olumsuz etkilenmesine neden olabilir [24]. Eger DG-Tabanlı sistemlerde GKO'lar ayrıntılı olarak sınıflandırılıp önceden bilinirse, uygun bir operasyon yaklaşımı benimsenir ve bu sayede DG'lerdeki güç elektroniği ekipmanlarının ve kontrol cihazlarının performansı arttırılabilir. GK tespitinin gerçek zamanlı olarak yapılması, şebeke bağlantılı veya AMOD yapıdaki mikroşebekelerde enerji yönetimi için büyük önem taşır. Ayrıca, GK parametreleri hem enerji üretimi ve düzenlemelerinde hem de tüketimde elektrik kullanım maliyetini belirlemede önemli bir faktördür [25,26]. Sonuç olarak, DG sisteminin etkin çalışması, kontrolü ve istenmeyen işlemlerden korunması, GKO'ların uygun bir yöntemle tespit edilmesi ve sınıflandırılmasıyla mümkündür.

1.1 Literatür Araştırması

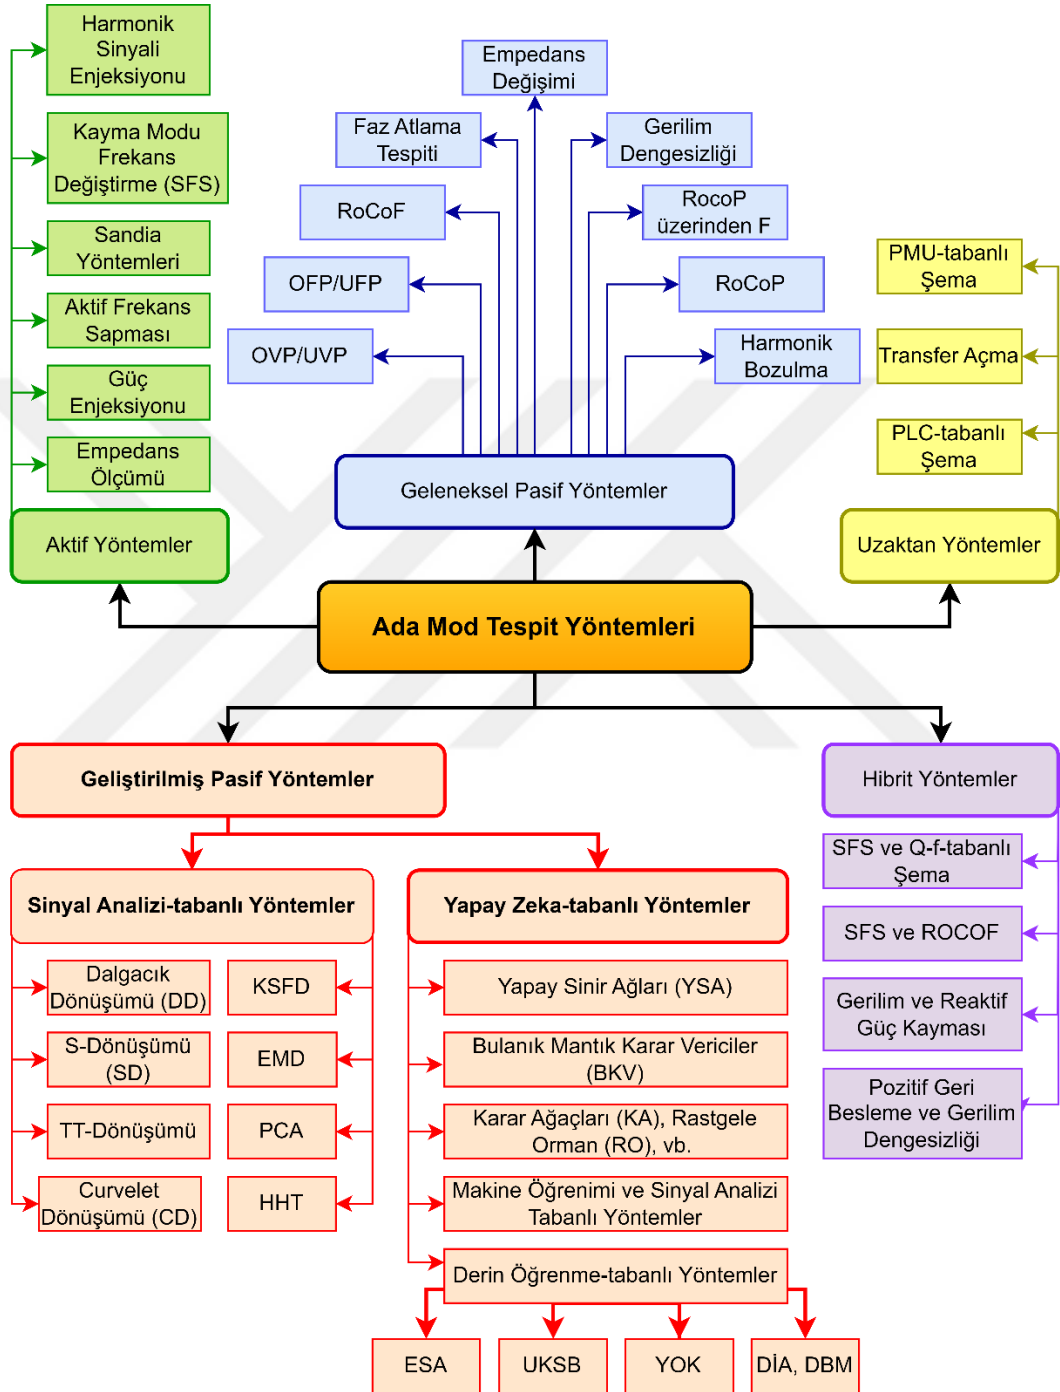
Tez çalışmasında AMOD tespit yöntemleri ve GKO sınıflandırma yöntemleri iki ayrı alt başlıkta verilmiştir. Literatürde hem geleneksel yöntemler hem de güncel yöntemler ayrıntılı olarak ele alınmış olup önerilen yöntemlerin avantaj ve dezavantajları vurgulanmıştır.

1.1.1 Literatürde önerilen AMOD çalışma tespit yöntemleri

Özellikle şebekeye entegre edilen FV, rüzgâr, batarya gibi dağıtık sistemler ve elektrikli araç şarj üniteleri gibi elektrikselsel karakteristiği farklı yüklerle beraber AMOD çalışmanın tespiti önemli bir konu haline gelmiştir [3]. AMOD çalışma, bir dağıtım sistemi güç sisteminin kalan kısmından elektrikselsel olarak izole edildiğinde, enerji akışının halen kendisine bağlı bulunan dağıtık üretim kaynağı tarafından devam ettirilme durumudur. Bu durum, sistemin belirlenen gerilim ve frekans değerlerinin dışında kalmasına neden olur ve sonuçta, sistem ekipmanlarının zarar görmesi, şebeke işletim operatörlerinde can kaybına varacak tehlikeler, büyük boyutta elektrik kesintileri ve ekonomik kayıplar meydana gelebilir. Literatürde AMOD tespiti için önerilen yöntemlerin, bu kayıpların önüne geçmek için minimum algılama dışı bölge (ADB) içermesi, hızlı tespit yapabilmesi ve uygun koruma sağlama kriterlerini dikkate alması gerekmektedir.

AMOD tespit yöntemlerinin temel amacı, şebeke ve DG taraflarındaki bazı elektrikselsel parametreleri ve yük talebini izleyerek adalanmanın meydana gelip gelmediğinin tespit edilmesidir. Yapılan çalışmalar incelendiğinde, AMOD tespiti için

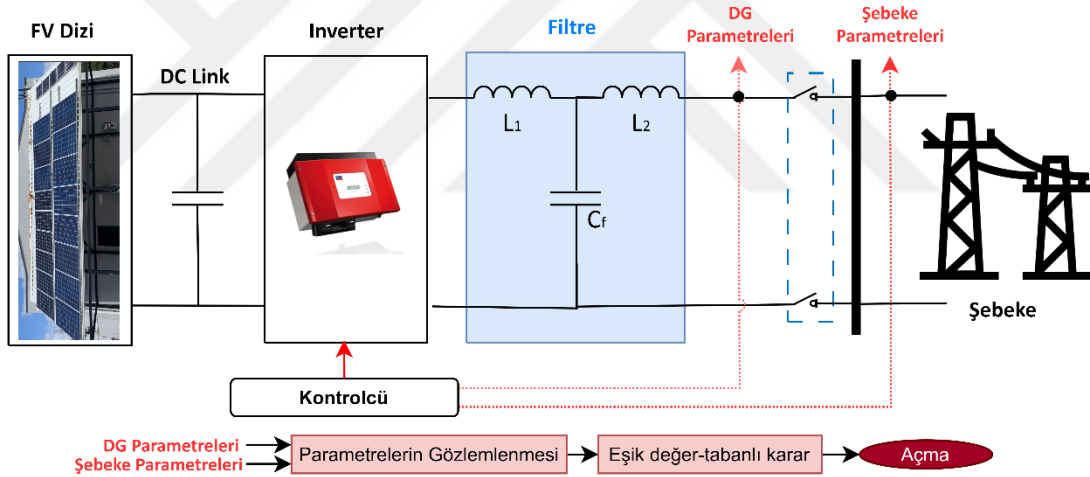
önerilen yöntemler 5 kategoriye ayrılabilir: Geleneksel pasif yöntemler, geliştirilmiş pasif (sinyal analizi ve makine öğrenmesi-tabanlı) yöntemler, aktif yöntemler, uzaktan izleme yöntemleri ve hibrit yöntemler. Literatürde AMOD tespiti için önerilen yöntemler Şekil 2.1’de gösterilmiştir [1].



Şekil 1.2 : AMOD çalışma tespit yöntemleri.

Geleneksel pasif yöntemler ile ada çalışma tespiti, OBN gerilim, akım, frekans, güç, harmonik bozulma, faz açısı, empedans vb. gibi sistem parametrelerinin ölçümüne

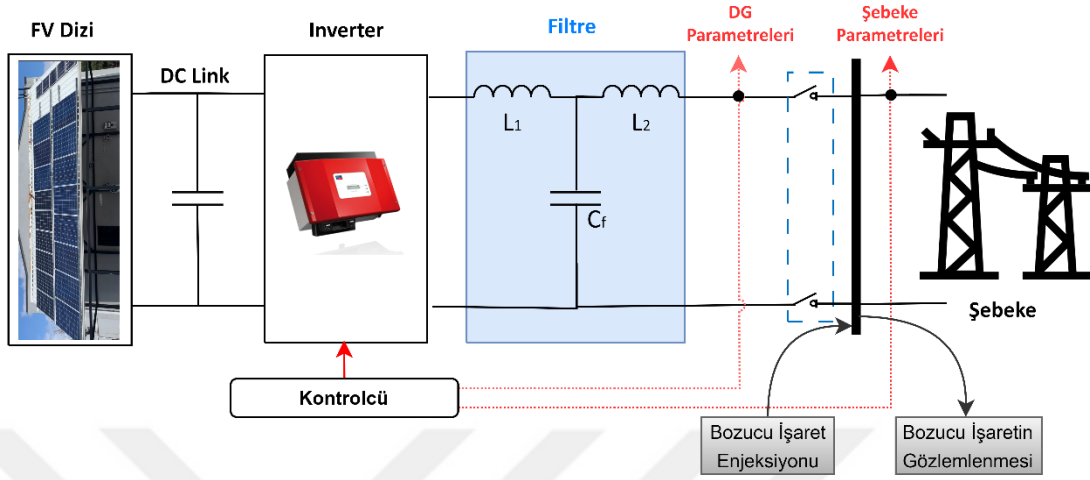
dayanır [27,28]. Ada çalışma olduğunda, izin verilen eşik değerleri aşan bu parametrelerde önemli dalgalanmalar gözlemlenir. İlgili koruma sistemleri, bu değişimleri izler ve gerektiğinde ana devre kesicisini devreye alır. Şekil 1.3'te geleneksel pasif AMOD tespit yöntemlerinin genel çalışma blok şeması gösterilmiştir. Başlıca geleneksel pasif yöntemler şunlardır: Aşırı/düşük frekans ve gerilim (OFP/UFP, OVP/UVP) koruma [29], frekans değişim oranı (RoCoF) [30], faz atlama tespiti [31], empedans değişimi [32], gerilim dengesizliği [33], güç değişim oranı (RoCoP) [34], ROCOP üzerinden frekans değişimi (RoCoP-F) [35] ve harmonik bozulma [36]. Geleneksel pasif yöntemlerin avantajları, hızlı algılama süresine sahip olmak, maliyet etkin bir yöntem sunmak ve GK'yi olumsuz etkilememek olarak sayılabilir. Ancak, bu yöntemler, geniş bir ADB içerir ve DG sistemlerde bu oran güvenilirlik ve sürdürülebilirlik açısından yeterli değildir [37]. Eşik değer belirlemedeki güçlükler ile gürültüye karşı duyarlılık bu yöntemlerin diğer dezavantajlarıdır.



Şekil 1.3 : Geleneksel pasif AMOD tespit yöntemlerinin genel çalışma şeması.

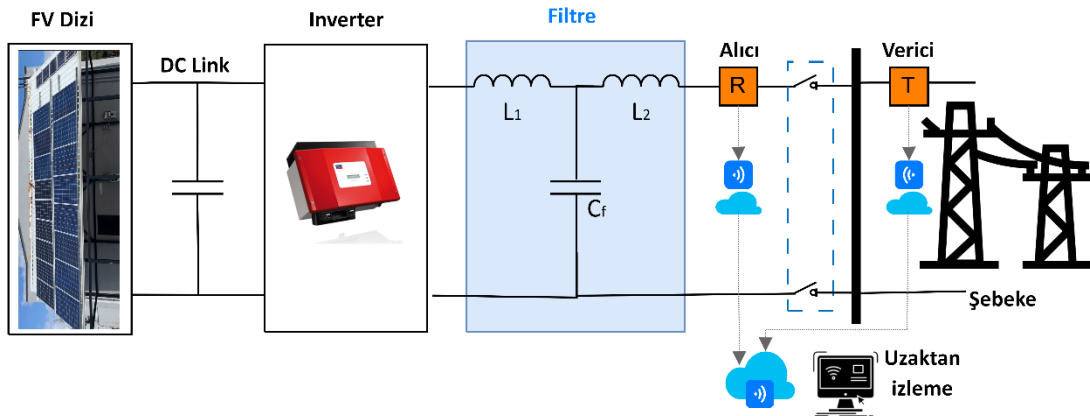
Aktif yöntemlerin temel fikri, bir dizi pasif yaklaşımın AMOD tespit etmekte başarısız olduğu durumda, DG çıkışını değiştirerek harici küçük bir bozucu sinyal kullanmaktır. Bozulmanın büyüklüğü sistemin işleyişinde herhangi bir geçici duruma neden olmayacak kadar küçüktür. Bu küçük bozucu sinyal, sistem parametrelerinde büyük değişikliklere sebep olacaktır. Şekil 1.4'te aktif AMOD tespit yöntemlerinin genel çalışma blok şeması gösterilmiştir [28]. Başlıca aktif yöntemler şunlardır [27]: Empedans Ölçümü [38], Güç Enjeksiyonu [39], Aktif Frekans Sapması [40], Sandia Frekans Öteleme [41], Sandia Gerilim Öteleme [42], Kayma Mod Frekans Öteleme [43] ve Harmonik Sinyal Enjeksiyonu. Bu yöntemlerde, geleneksel pasif yöntemlere

göre ADB küçülmekte olup hızlı adalama tespiti mümkündür. Ancak, aktif yöntemlerde şebekeye enjekte edilen gürültü nedeniyle GK sorunları yaşanabilir. Ayrıca, sistemde kararlılık sorunları da gözlenebilir.



Şekil 1.4 : Aktif AMOD tespit yöntemlerinin genel çalışma blok şeması.

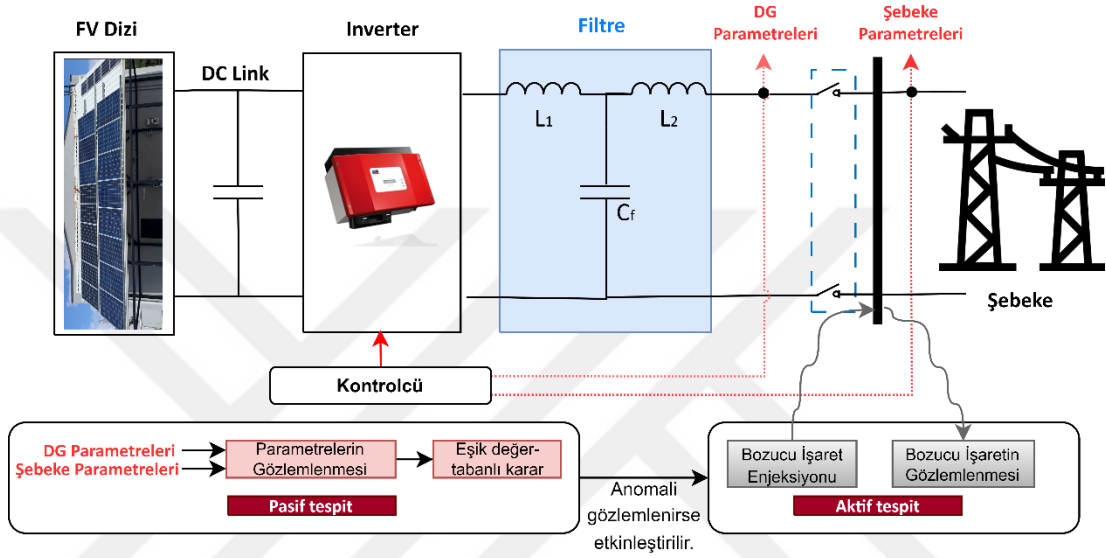
Uzaktan izleme yöntemleri, DG bağlantısının ana şebekeden uzak olduğu konumlarda kullanılır. Ancak bu yöntem sensörler ve telekomünikasyon cihazları gerektiği için oldukça maliyetlidir [44]. Ana şebeke ile DG inverter arasındaki iletişim bu stratejinin temelini oluşturur. Şekil 1.5'te uzaktan AMOD tespit yöntemlerinin genel çalışma blok şeması gösterilmiştir. Aktif ve pasif yöntemlere kıyasla oldukça hassas bir yöntem olup ADB neredeyse sıfırdır [45]. GK'ye olumsuz etki etmez ve yüksek güçlü cihaz uygulamaları için uygundur. Oldukça güvenilir bir yöntem olmakla birlikte, maliyetli ve kompleks iletişim cihazları kullanıldığından devre karmaşıklığı artar.



Şekil 1.5 : Uzaktan izleme ile AMOD tespit yöntemlerinin genel blok şeması.

Hibrit yöntemlerde, AMOD çalışma durumu pasif ve aktif yöntem bir arada kullanılarak her iki yöntemin avantajlı olduğu özelliklerden faydalanılır. Şekil 1.6'da

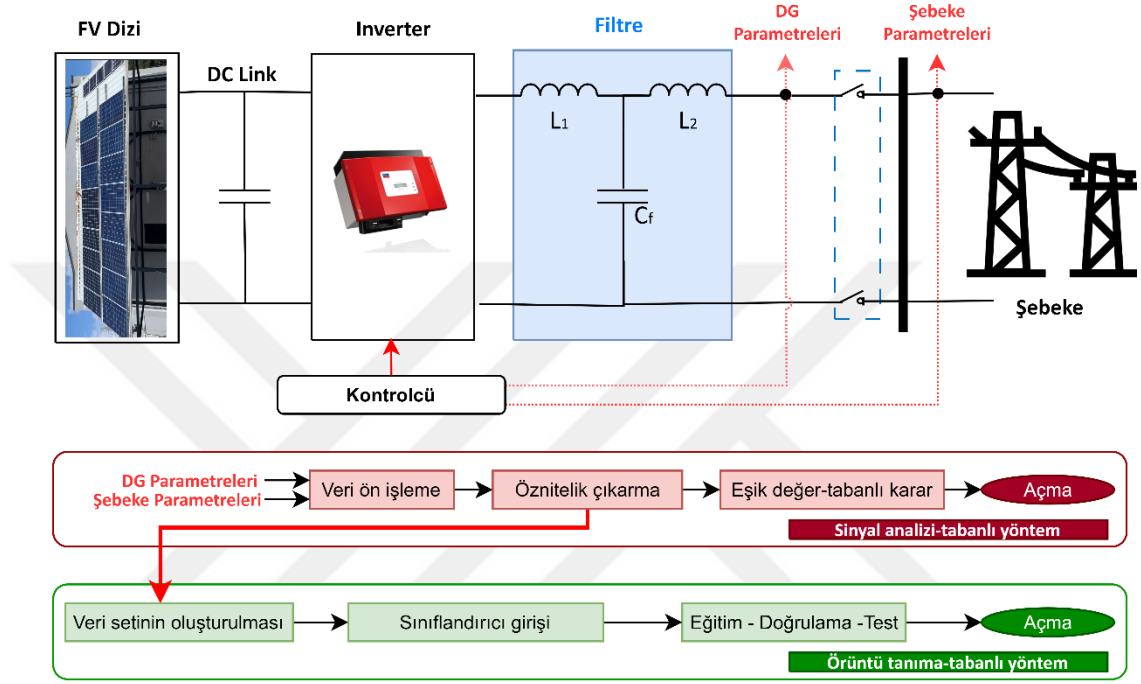
hibrit AMOD tespit yöntemlerinin genel çalışma blok şeması gösterilmiştir [28]. Başlıca aktif yöntemler şunlardır: Sandia Frekans Öteleme-RoCoF [46], Sandia Frekans Öteleme ile Q-f-Tabanlı Şema [47], Gerilim ve Reaktif Güç Kayması [48] ve Pozitif Geri Besleme-Gerilim Dengesizliği [49]. Hem aktif hem de pasif tabanlı yöntemlerin birleştirilmesi, GK standartlarını ihlal etmeden geleneksel pasif tespit yöntemlerine göre ADB'yi önemli ölçüde azaltır [50]. Ancak bu yöntemlerde, aktif ve pasif yöntemlerdeki sorunlar azalmış olsa da devam etmektedir.



Şekil 1.6 : Hibrit AMOD tespit yöntemlerinin genel blok şeması [28].

Gelişmiş pasif AMOD tespit yöntemleri ise geleneksel pasif yöntemlerdeki geniş ADB'yi minimuma indirmek, aktif yöntemlerdeki GK etkisini ortadan kaldırmak ve uzaktan izleme yöntemlerindeki çok yüksek maliyetleri ortadan kaldırmak için önerilmiştir [50,51]. Bu yöntemler, sinyal analizi-Tabanlı yöntemler ve örüntü tanıma-Tabanlı yöntemler olarak temelde iki başlık altında incelenebilir. Şekil 1.7'de Sinyal Analizi-Tabanlı AMOD tespit yöntemi ile Örüntü Tanıma-Tabanlı AMOD tespit yöntemi bir arada verilmiştir. Öncelikle şebekeden gerekli elektriksel ölçümler alındıktan sonra bu ölçümler, bir ön işleme tabi tutulur. Daha sonra, Fourier Dönüşümü (FD), Kısa Zamanlı Fourier Dönüşümü (KZFD), Dalgacık Dönüşümü (DD), Hilbert-Huang Dönüşümü (HHD), s-Dönüşümü (SD), Curvelet Dönüşümü (CD), Ampirik Mod Ayırıştırma (AMA), Zaman-Zaman Dönüşümü (TTD) gibi bir yöntemle ayrıştırılır [9,17,52-54]. Elde edilen katsayılar doğrudan veya istatistiksel işlemlerden geçirilerek eşik değeri parametre setinde kullanılabilir. Bu yöntemler, eşik değere-Tabanlı olması nedeniyle yanlış tespit eğilimleri gösterebilir. Özellikle, nominal

durum ve arıza durumu çok yakın değerler içerdiğinde ve sistemde yüksek gürültü koşulları da varsa hatalı tespit kaçınılmazdır. Sinyal Analiz-Tabanlı Yöntemler'in bu eksiklikleri Örüntü Tanıma-Tabanlı Yöntemler ile giderilmiştir. Bu yöntemlerde, elde edilen bu öznelik matrisi sınıflandırıcı modelinin girişine verilir. Parametre optimizasyonu gerçekleştirildikten sonra eğitilen model yardımıyla AMOD tespiti gerçekleştirilebilir.



Şekil 1.7 : Gelişmiş pasif AMOD tespit yöntemlerinin genel blok şeması.

Sinyal analiz yöntemleri, sinyallerin hem zaman hem de frekans alanı özelliklerini gözlemlene şansı sunduğu için çok daha esnek bir yapıya sahiptir. Bu durum, geleneksel yöntemlere kıyasla AMOD çalışmanın tespitinde önemli ölçüde fayda sağlar. Ayrıca, geleneksel pasif yöntemlere göre ADB yüksek oranda düşürülür ve AMOD çalışma algılama süresi azaltılır [55,56]. FD, HHD, DD, SD, TTD, CD, AMA, temel bileşen analizi (PCA) yöntemleri literatürde AMOD çalışma tespiti için önerilmiştir [1,10]. Ancak bu yöntemlerin çeşitli dezavantajlar mevcuttur. FD zaman verilerinin eksikliğinden dolayı ada tespiti için uygun değildir. KZFD yöntemi de bir DG'deki adalanmayı tespit etmede yetersizdir [57,58]. KZFD'nin sabit bir zaman-frekans pencere çözünürlüğü vardır ve tüm olay sinyalleri için uygun bilgileri sağlayamaz. KZFD'den daha üstün olan DD'de yüksek seviyeli türevlerdeki süreksizlikler yerel olarak araştırılabilir. Ayrıca DD yöntemleri, sinyaldeki geleneksel yöntemlerde tespit edilmesi mümkün olmayan hızlı değişiklikleri tespit

edebilmektedir. Ancak, DD gürültüden büyük ölçüde etkilenir ve yanlış algılamalara sebep olabilir. SD ise gerçek zamanlı uygulamalarda iyi değildir. Ayrıca SD, harmoniklerin yanlış tahmin edilmesine neden olabilir. TTD yüksek karmaşıklığa sahiptir [59].

DD yöntemleri değişken pencere boyutuna sahip olma, çoklu çözünürlük sağlama ve sinyali farklı bir perspektiften analiz etme gibi özellikleri nedeniyle tespit ve sınıflandırma problemlerinde sıkça kullanılmaktadır. Sürekli Dalgacık Dönüşümü (SDD), yoğun hesaplamalar gerektirmekte olup bu problemi aşmak amacıyla sürekli dalgacıkların ölçekleri ve kaymaları için bir dizi ayrık değer seçilir. Şebekeye bağlı DG'ler için SDD-Tabanlı bir AMOD çalışma tespit yöntemi [37, 60]'ta önerilmiştir. Hesaplama verimliliğinin düşük olması ve tespit süresinin uzun olması SDD'nin kullanımını kısıtlamaktadır. Ayrık Dalgacık Dönüşümü (ADD) literatürde yaygın olarak kullanılmaktadır [9]. 4-seviyeli ADD ayrıştırması ile AMOD tespiti Referans [54]'te gerçekleştirilmektedir. Şebekeye bağlı FV sistemler için önerilen yöntem Referans [61]'de sunulmakta olup, gerilim sinyaline ADD uygulandıktan sonra spektral değişikliklere göre AMOD tespit edilmektedir. Başka bir çalışmada [45], ADD yöntemi, AMOD çalışmayı tespit etmek için alanda programlanabilir kapı dizisi ile kullanılmıştır. Adaptif Eşik Değer-Tabanlı ADD yöntemi ile AMOD tespitinin gerçekleştirildiği çalışmada [62], AMOD tespiti %96 doğrulukla gerçekleştirilmiştir. Sonuç olarak, ADD yöntemlerinde aşağı örnekleme işlemi, gerilim sinyalindeki bazı bilgilerin kaybolmasına neden olur. SDD yönteminin uygulama sorunları, performans sınırlamaları [63] vardır. Bununla birlikte, DPD ve ADD, gürültülü koşullardan oldukça etkilenir. Bu dezavantajlar, Piramidal Algoritma kullanan Örnek İndirgenmemiş Dalgacık Dönüşümü (ÖİDD) ile tez çalışmasında ortadan kaldırılmaktadır. Ayrıca, ÖİDD kayma-değişmezdir (shift-invariant) ve her ölçekte aynı sayıda katsayıya sahip bir zaman serisini temsil eder. Bu özellikleri ile durağan ve durağan olmayan sinyallerdeki bilgileri tespit etmek ve daha iyi zaman/frekans konumu elde etmek için kullanılmaktadır. [64-67]. Piramidal ÖİDD Yöntemi'nin tespit doğruluğu gürültülü koşullarda bile diğer DD-Tabanlı yöntemlere göre daha yüksektir.

Akıllı yöntemler, Yapay Sinir Ağı (YSA)-Tabanlı Sınıflandırıcılar [68, 69], Destek Vektör Makinesi (DVM)-Tabanlı Sınıflandırıcılar [70, 71], Bulanık Mantık Karar Verici (BKV)-Tabanlı Sınıflandırıcılar [72], Uyarlamalı Ağ Tabanlı Bulanık Çıkarım

Sistemi (UABCŞ) [73], Karar Ağacı (KA)-Tabanlı Sınıflandırıcılar ve Derin Öğrenme (DÖ)-Tabanlı Sınıflandırıcılar [26] olarak gruplandırılabilir. BKV ve UABCŞ yaklaşımlarında, algoritma, insan zekasına benzer tepkiler üretmesi için eğitilir. Bu yöntemler, elde bulunan işlem temeline dayalı belirli bir önceden tanımlanmış kurallar kümesini izler. Girdi verisinin çeşitliliği, kurallar kümesine dayalı olarak çıktıyı tetikler ve eylemler gerçekleştirilir. Giriş değişkenleri arttıkça, akıllı denetleyicinin verimliliği artar. Ancak denetleyiciyi yüksek hesaplama gereksinimleri olan karmaşık hale getirir. BKV-Tabanlı geliştirilen yöntemde [74], BKV üç girdi değişkeni ile beslenir ve bulanık kurallara dayalı olarak çıktı, sistemin AMOD çalışmada olup olmadığını belirler. Benzer bir çalışmada ise [75], aynı işlem 11 girişlik bir BKV ile gerçekleştirilmiştir. Giriş değişkenleri arttıkça, akıllı denetleyicinin verimliliği artar. Ancak denetleyiciyi yüksek hesaplama gereksinimleri olan karmaşık hale getirir. Bu sorunu gidermek için UABCŞ-Tabanlı bir yöntem [76] önerilmiş olup, girdi sayısı azaltılırken hesaplama yükü de düşürülmüştür. Ayrıca, belirsiz verileri BKV'ye göre daha etkili bir şekilde ele alabilir.

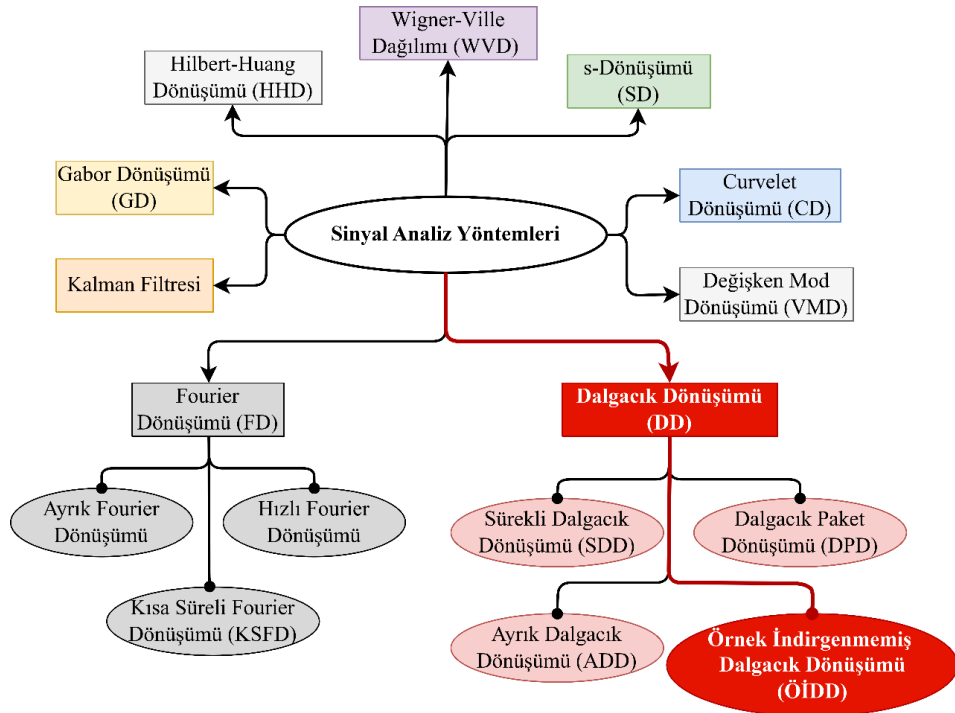
Örüntü Tanıma-Tabanlı yaklaşımda ise, çalışma durumlarının doğru tanımlanmasını sağlamak amacıyla algoritmayı eğitmek için geçmiş veri tabanı kullanılır. Genellikle algoritma, elektrik sinyalini girdi olarak alarak bir ileri beslemeli ağda çalıştırılır. AMOD çalışma durum sinyalleri, tanımlama doğruluğunu artırmayı amaçlayan öznitelikleri çıkarmak için ön işleme tabi tutulur [77]. Daha sonra, oluşturulan öznitelik verisi rastgele test, eğitim ve doğrulamada kullanılmak üzere her bir sınıfta rastgelelik korunarak ayrılır. Öğrenme süreci tamamlandığında, işletim durumunun tanımlanması için modele rastgele bir veri verilir ve sonuçlar gözlemlenir [78]. Öznitelik çıkarmada ADD ve DPD kullanan bir çalışmada [79], elde edilen öznitelik vektörü KA'nın girişine verilmiştir. KA ile alınan karara göre devre kesici aktif/deaktif edilmektedir. Ancak KA aşırı uydurmaya yatkındır. Başka bir çalışmada [80], DG sistemlerde YSA ile AMOD çalışma tespit edilmiştir. Bu yöntemin veri işleme süresi uzun olup, çoklu inverter yapılarında çalışabilmektedir. DVM kullanan bir çalışmada [81], kaydedilen gerilim veya akım sinyallerinin tipik işlevlerini belirlemek için model otoregresif işleme eşleştirilmiştir. DVM'nin doğruluğu yüksek ve durum tespit süresi kısadır. Oldukça karmaşık yapıda ve tespit süresi oldukça fazla olan DSA algoritmaları da AMOD tespitinde kullanılmıştır [82, 83]. Pasif yöntemlerin detaylı karşılaştırması Çizelge 1.1'de verilmiştir.

Çizelge 1.1 : Pasif AMOD tespit yöntemlerinin ayrıntılı karşılaştırması [17, 27, 28].

	Yöntem	Avantajları	Dezavantajları	
Geleneksel Pasif	OVP/UVF [29]		• Düşük güç uyumsuzluklarında yetersiz	
	OFP/UFP [29]		• Eşik değer seçim problemleri	
	ROCOP [34]	• Basit yapısı sayesinde uygulaması kolay	• Yüksek ADB	
	ROCOP-f [35]	• Yüksek güç uyumsuzluklarında etkili	• Tahmin edilemeyen cevap süresi	
	RoCoF [30]	• Kolay uygulanabilir	• Farklı kalite faktörü değerlerinde çalışma problemi	
	Faz atlama [31]	• Ekonomik	• DG sistemlerde çalışma zorlukları	
	Empedans değişimi [32]			
Gelişmiş Pasif (Sinyal Analizi)	DD [60,67]	• Değişken pencere boyutu • Çoklu çözünürlük • Sinyali farklı bir perspektiften analiz etme	• Gürültülü sinyallere duyarlı	
	KZFD [57,58]	• İyi çözünürlük • Çerçeve-Tabanlı süreç	• Sabit pencere boyutu • Lokalizasyon problemleri	
	Kalman Filtresi [44]	• Uyarlanabilir pencere boyutu • Gürültüye karşı sağlam	• KF formülasyonu karmaşık • Belirlenen harmonik tahminiyle sınırlı	
	SD [84]	• Yerel faz bilgisine ulaşma • Yerel spektral özellikleri referanslama özelliği	• Yüksek hesaplama süresi • Küçük Gauss pencereleri sınırlaması	
	HHD [85]	• Zaman-frekansında potansiyel olarak uygulanabilir enerji temsilleri geliştirir	• Dönüşüm tekniğinin ampirik model dağılımı sayısal olarak parçalanma yeteneğine sahip değildir.	
	TTD [44]	• Gürültü altında çalışabilme	• Başlangıç çözünürlüğü iyileştirme gerekliliği	
	YSA [78]	• Gürültü ile baş edebilme • Kompleks problemlere uygulanabilir. • Çoklu algoritmaları eğitme	• Büyük veri gereksinimi • Yüksek hesaplama yükü	
	KA [79]	• Kolay uygulanabilir. • Kompleks problemleri basit yapıya indirgeme • Ölçekleme ve normalizasyona ihtiyaç duymama	• Aşırı uydurmaya yatkınlık • Verideki değişime duyarlı • Büyük veri için örtüşme sorunu	
	Gelişmiş Pasif (Akıllı Yöntemler)	DVM [81]	• Non-lineer ve yüksek boyutlu verilerde başarılı • Aykırı değerlere karşı dayanıklı	• Örtüşmüş sınıflarla zayıf performans • Çekirdek fonksiyonu seçimindeki zorluklar
	BKV [72]	• Kural tabanının pozitif etkisi • Karar vermede esneklik	• Gürültüye karşı hassas • Kural oluşturulmasındaki zorluklar	
UABÇS [73]	• YSA-BKV avantajları • Hızlı yakınsama süresi	• Yüksek hesaplama yükü		
DSA [17]	• Yüksek doğruluk • Yüksek hesaplama gücü • Verilerin hiyerarşik karakterizasyonu	• Büyük veri seti ihtiyacı • Eğitim süresinin fazla olması • Karmaşık yapı		

1.1.2 Literatürde önerilen GKO sınıflandırma yöntemleri

Günümüzde kullanılan GK analizörleri, kısa ve uzun süreli gerilim bozulmalarının tespitinde ve sınıflandırılmasında etkin değer dönüşümünü (RMS) kullanmaktadır. RMS yöntemleri kolayca uygulanabilmekle beraber, eşik değer seçimindeki zorluk, çalışma koşullarından kaynaklanan belirsizlik, algılanmayan bölge içermek ve gürültüden kolay etkilenmek gibi çok sayıda dezavantajı bünyelerinde barındırırlar [25]. Son yıllarda geleneksel GK analizör yöntemlerinden farklı olarak, GKO tespit ve sınıflandırması ile ilgili birçok sinyal analiz ve makine öğrenmesi-tabanlı hibrit yöntem önerilmiş olup, bu yaklaşımlarla geleneksel yöntemlerdeki dezavantajlar ortadan kaldırılmaya çalışılmıştır [26]. Ayrıca, sinyal analizi tabanlı yöntemler diğer yöntemlerden farklı olarak bir sinyalin sadece zaman bilgisi yerine hem zaman hem de frekans bileşenlerini kullanmaktadırlar. Bu nedenle, geleneksel GKO tespit ve sınıflandırma yöntemlerine göre daha esnek ve güvenilirlerdir. Sinyal işleme-tabanlı yöntemler, diğer yöntemlerden farklı olarak bir sinyalin hem zaman hem de frekans bileşenlerini kullanırlar. Bu nedenle, geleneksel GKO tespit yöntemlerine kıyasla daha esnek ve güvenilirlerdir. Literatürde, FD, DD, HHD, SD, CD, Kalman Filtresi, Gabor Dönüşümü (GD) [86], Değişken Mod Dönüşümü (DMD), Wigner-Ville Dağılımı (WVD), AMA [87] vb. çok sayıda yöntem GKO olaylarının tespiti ve sınıflandırılması için kullanılmış olup, Şekil 1.8’de bu yöntemler verilmiştir [22, 88].



Şekil 1.8 : GKO tespitinde kullanılan sinyal analiz yöntemleri [22, 88].

Joseph Fourier tarafından temelleri atılan ve en yaygın kullanılan sinyal analiz tekniği FD yöntemleridir. Bu dönüşüm metotları, frekans bileşenlerinin yerel olarak incelenmesine izin vermediği için özellikle salınımlı ve ani geçici durum olayları, kısa süreli gerilim çökmesi/sıçraması vb. durağan olmayan (non-stationary signal) olaylarda doğru cevap veremezler [57]. Bu sorun KZFD’de kullanılan pencereleme işlemi ile çözülmüştür. Ancak KZFD, sabit bir pencere boyutuna sahiptir ve sinyalin yüksek ve düşük frekanslı bileşenlerini aynı anda incelemeye uygun değildir [89]. GKO sınıflandırılması için kullanılan SD ise gerçek zamanlı gereksinimleri karşılayamaz. Çünkü blok işlemeye dayanmaktadır. Ayrıca, HHD, GKO’lar gibi ani geçişler ve benzer frekans bileşenleri içeren sinyallerde ayrıştırma zorlukları içerir [25]. VMD yönteminin ortaya çıkan en önemli sınırlamaları ise sınır etkileri ve genel olarak ani sinyal başlangıcıdır. Bununla birlikte, DD-Tabanlı yöntemler esnek zaman-frekans temsiline sahiptir. DD yöntemleri, sinyaldeki süreksizlikleri ve diğer sinyal işleme yöntemleri tarafından algılanamayan yüksek derecede türevlerdeki ani değişiklikleri algılayabilir. Ancak, DD yöntemleri gürültü altında düşük performans sergiler. GKO’ların tespit ve sınıflandırılması için en yaygın kullanılan DD-Tabanlı yöntemler SDD, ADD ve DPD olarak 3 grupta incelenebilir [90-94,62]. Referans [92]’de, gerilim çökmesi/sıçraması olaylarını doğru bir şekilde tespit etmek için Daubechies ana dalgacıkları kullanılarak ADD uygulanmıştır. Başka bir çalışmada, rüzgar türbinlerinde arıza tespiti için gerilim sinyali kullanılmış ve katsayıları elde etmek için beş seviyeli ADD uygulanmıştır [93]. Referans [94]’te, FV panellerinden oluşan ve şebekeye bağlı bir DG sistemi incelenmiş ve arızaları tespit etmek için DPD tekniği önerilmiştir. Yapılan çalışmalardan birinde [95], enerji, entropi ve harmoniklerden yararlanarak Daubechies dalgacık ailesini içeren filtre bankaları kullanılmış ve bir eşik değerlendirme yöntemi önerilmiştir. GKO’ları gerçek zamanlı tespit etmek için üç seviyeli DD ayrıştırması gerçekleştirilen çalışmalardan birinde ise adaptif eşik değeri belirlenerek başarımları artırılmaya çalışılmıştır [62]. Kullanılan DD tekniklerinin, GKO tespiti ve sınıflandırılmasındaki performansları Çizelge 1.2’de gösterilmektedir. Yüksek hesaplama yükü nedeniyle, SDD yöntemi yalnızca birkaç gerçek zamanlı uygulamada kullanılmıştır [60]. DPD [96] ve ADD [54], gürültülü koşullardan oldukça etkilenir. Tez çalışmasında, sinyal analizi ve öznel çıkarma süreçlerinde geleneksel tekniklerden farklı olarak görüntü işleme daha çok kullanılan ÖİDD yöntemi kullanılmıştır. Referans [64], FV tabanlı mikroşebekelerde arıza tespiti için ilk kez ÖİDD yöntemini önermektedir. Bu yöntem, gerçek zamanlı

uygulamalarda test edilmiştir ve DD yöntemlerinin dezavantajlarını ve sınırlamalarını ortadan kaldırdığı görülmüştür. Önerilen sinyal analiz yaklaşımı, ölçülen gerilim sinyalindeki salınımları ve gürültüyü azaltır. Ayrıca, ÖİDD ayrıştırması ADD yerine eşik değerleri seçmek için kullanışlıdır ve gürültü hassasiyeti diğer DD tabanlı uygulamalardan çok daha düşüktür [97].

Çizelge 1.2 : DD tekniklerinin, GKO tespit ve sınıflandırılma performansları.

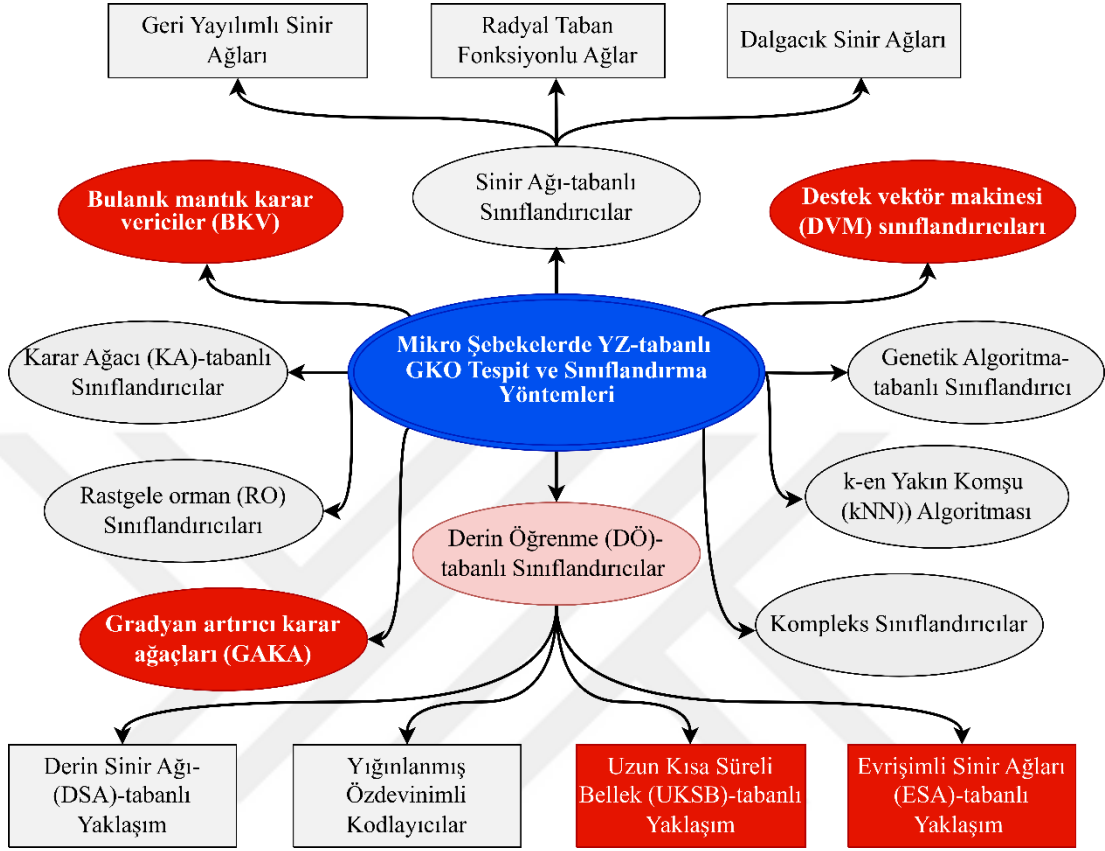
	ADD	SDD	DPD	ÖİDD
Tepe tespit doğruluğu	Güçlü değil	---	Güçlü	Güçlü
Gerçek zamanlı hata tespiti	En uygun	Uygun değil	Uygun	Uygun
Kullanım yaygınlığı	Yüksek	Düşük	Ortalama	GK'de yeni
Tepki süresi	Çok kısa	Uzun	Kısa	Kısa
Gürültü hassasiyeti	Yüksek	Ortalama	Yüksek	Çok düşük
Durağan olmayan analiz	Uygun	Uygun	Uygun	En uygun
Özellik çıkarma işlemi	Gürültülü koşullar için uygun değil	Gerçek zamanlı için uygun değil	Gürültülü koşullar için uygun değil	En uygun

Sinyal analizi ile birlikte istatistiksel parametreler ve eşik değerler kullanan yöntemler, özellikle karmaşık ve gürültü içeren olaylarda hatalı karar verebilmektedir. Bu problemin önüne geçmek için, mikroşebeke uygulamalarında GKO'ları tespit etmede ve sınıflandırmada literatürde çeşitli yapay zeka (YZ)-Tabanlı yöntemler kullanılmıştır (Şekil 1.9). Temelde bu yöntemler, YSA-Tabanlı sınıflandırıcılar [68,69], DVM-Tabanlı sınıflandırıcılar [70,71], BKV-Tabanlı sınıflandırıcılar, KA ile rastgele orman (RO) sınıflandırıcıları, gradyan artırıcı karar ağaçları (GAKA), k-en yakın komşu (kNN) algoritması ve DÖ-Tabanlı sınıflandırıcılar [26] (evrişimli sinir ağları (ESA), uzun kısa süreli bellek (UKSB), yığılanmış özdevinimli kodlayıcılar (YÖK), derin inanç ağları ve hibrit yaklaşımlar (ESA-UKSB)) olarak gruplandırılabilir. Sınıflandırıcı, ham veriyi veya çıkarılan öznitelikleri giriş olarak alır ve sistemin işletim durumu hakkında bir karar verir. Sınıflandırıcılar, orijinal sinyal üzerinden güçlü özelliklerin çıkartılmasını sağlayan sinyal analiz yöntemleri ile birlikte kullanılır. Bu hibrit yaklaşımda, GKO'ların otomatik tanımlanması, üç aşamaya ayrılmıştır: (1) alan dönüşümü (sinyal analizi) yöntemlerini ve sonrasında istatistiksel yöntemleri kullanarak öznitelik çıkarımı [64], (2) optimal özniteliklerin seçilebilmesi için optimizasyon yöntemi uygulamaları ve (3) çok sınıflı sınıflandırıcılar kullanılarak olay sınıflandırması [98].

Referans [89]'da, YSA-Tabanlı sınıflandırıcı ve optimal öznitelik seçimi algoritması içeren yöntem, GKO tespiti için kullanılmıştır. Bir sınıflandırıcı kullanılarak yapılan başka bir çalışmada, GKO'lar DPD-Tabanlı DVM yöntemi kullanılarak sınıflandırılmıştır [90]. ADD ve SA-Tabanlı bir hibrit GKO sınıflandırma yönteminin uygulandığı çalışmada [91], gürültüsüz ve yüksek gürültülü koşullarda sırasıyla %99,87 ve %95,2 sınıflandırma doğruluğunu göstermektedir. Referans [70]'te, çoklu GKO'ları sınıflandırmak için ampirik dalgacık dönüşümü kullanarak çok sınıflı DVM yöntemi önerilmiştir. Önerilen yöntemin gürültülü koşullardaki analizi gerçekleştirmek için IEC 61000-4-7 standartlarına uygun olarak orijinal sinyallere 25 dB ila 55 dB arasında Gauss gürültüsü eklenmiştir. Önerilen yöntemin, sekiz tekli GKO ve yedi kompleks GKO için, toplam doğruluk oranı %97,22'dir. Referans [71]'de, GKO'ların sınıflandırılması için DVM-Tabanlı bir algoritma geliştirilmiştir. Simülatif veri seti için yüksek düzeyde gürültülü koşullarda sınıflandırma doğruluğu %97,77'dir. Referanslar [99,100]'de DG'lerde GKO'ların sınıflandırılması için bulanık dalgacık ağı tabanlı iki farklı yöntem önerilmiştir. Ancak, bu çalışmalarda kullanılan öznitelik sayısının fazla olması nedeniyle hesaplama yükü oldukça yüksektir. Borrás ve diğerleri tarafından gerçekleştirilen çalışmada [101], DG içeren sistemde optimal çoklu olay sınıflandırması için bozulmuş oranı-Tabanlı yöntem olarak adlandırılan bir yaklaşım önerilmiştir. Referans [102]'de, GKO sınıflandırması için SD ve sıkıştırılmış algılama (SA) kullanan bir yöntemi önerilmiştir. SD'nin performansının durağan olmayan geçici sinyallerin analizinde düştüğü görülmüştür.

GKO'ların otomatik tanımlanmasındaki üç aşamalı yaklaşımda, öznitelik çıkarılma süreci sınıflandırma işlemleri için kritik öneme sahiptir. Literatürde genellikle el ile tasarlanmış öznitelik seçimi yöntemi kullanılmaktadır [89,103,104]. Özellik çıkarılma süreci son derece keyfi olduğundan ve çıkarılan özniteliklerin GKO sınıflandırmasına nasıl yardımcı olduğu tam olarak açıklanamamaktadır. Bu sorunu çözmek için araştırmacılar, GKO sınıflandırması için temel öznitelikleri yakalamak için bir optimizasyon algoritması kullanarak özellikleri filtrelemeye odaklanmışlardır [89,91,101]. Optimal öznitelik çıkarılma yöntemleriyle hesaplama hızı artarken doğruluk oranı yüksek seviyede tutulabilir. Ancak, orijinal öznitelik setinin hala manuel olarak oluşturulduğu unutulmamalıdır. Dolayısıyla, bu öznitelik seti birçok ilgisiz ve gereksiz özniteligi içerebilmektedir. Özetlemek gerekirse, öznitelik filtreleme optimizasyon süreci zaman alıcı ve zahmetli olabilir. DÖ yöntemleri, insan

katılımını ortadan kaldırmak ve geleneksel üç aşamalı sürecin kapalı döngü geri bildiriminden yoksun olmasını gidermek amacıyla otomatik öznitelik seçimi yöntemleri kullanmaktadır [23].



Şekil 1.9 : GKO sınıflandırmasında kullanılan YZ yöntemleri.

DÖ algoritmaları, birden çok soyutlama düzeyinde bilgi çıkarır. Ayrıca, herhangi bir geleneksel sinyal işleme yöntemine ihtiyaç duymadan girdi verilerinden zamansal ve uzamsal özellikleri otomatik olarak çıkarabilir. GKO tanımlama problemlerindeki DÖ yöntemleri, süreçleri basitleştirebilir, sınıflandırma doğruluğunu artırabilir ve insan müdahalesine olan ihtiyacı ortadan kaldırabilir. Referans [105]'te karmaşık GKO'ları sınıflandırmak için curvelet dönüşümü ve derin sinir ağı (DSA)-temelli yeni bir hibrit yaklaşım kullanılmıştır. Başka bir çalışmada [23], GKO'ların sınıflandırılması için ham verilere dayalı yeni bir DÖ-Tabanlı yöntem önerilmiştir. Kompleks olayları da içeren 16 farklı GKO sınıfı için, gürültü içeren koşullardaki tespit doğruluğu %98,13'tür. YÖK ile SA kullanan hibrit yöntemin önerildiği çalışmada [105], SA ile öznitelik çıkarımı yapmak otomatik süreçleri engellemekte olup hesaplama yükünü artırır. Referans [106]'da önerilen çalışmada ise, 1-D zaman serisi GKO verileri, WVD kullanılarak 2-D görüntü verilerine dönüştürülmüş, ardından 2-D ESA ile olayların

sınıflandırılması gerçekleştirilmiştir. SA ve ESA-temelli bir derin ağı önerildiği çalışmada [107] ise matematiksel veriler için yüksek sınıflandırma doğruluğu sağlanırken, deneysel sistem üzerinden alınan gerçek olay sinyallerinde tespit doğruluk oranı %81'e kadar düşmektedir. GKO sınıflandırmasının UKSB, ESA ve ESA-UKSB yöntemleri kullanılarak yapıldığı çalışmada [108], karşılaştırmalı analizler de sunulmaktadır. ESA-UKSB hibrit yöntemi ile yapılan sınıflandırmada doğruluk oranı %84,76 olarak bulunmuştur ve en yüksek başarı bu modele aittir. Ancak, karmaşık bir model kullanılmasına rağmen bu yöntemde sınıflandırma doğruluk oranının oldukça düşük kaldığı görülmektedir.

1.2 Tezin Amacı, Özgün Değer ve Çalışmanın Literatüre Katkısı

Tez çalışması kapsamında, şebeke koduna ve belirli standartlara uygun AMOD çalışma ve GKO tespit/sınıflandırması için akıllı yöntemler önerilmiştir. Aynı zamanda önerilen yöntemi kullanan izleme-tespit-koruma sistemi için prototip ürün geliştirilmesi sağlanmıştır. Bu kapsamda, yenilenebilir enerji kaynakları (YEK) ve EA şarj istasyonları içeren bir mikroşebeke test sistemi oluşturulmuştur. Ayrıca literatürde önemli bir eksik olan ortak kullanılabilir ve yöntem performanslarını değerlendirebilecek veri seti eksikliği giderilmeye çalışılmıştır. Olay sinyalleri için matematiksel, simülatif ve test sistemi gerçek verilerinden oluşan veri setleri alandaki araştırmacılar için kolaylık sağlayacaktır.

Mikroşebekelerde meydana gelen GK sorunları, geleneksel güç sistemindeki olaylara benzemekle beraber bazı işletim operasyonları nedeniyle çok daha zor tanımlanabilir. Mikroşebekelerde, rüzgar hızı ve güneş ışınım değerlerindeki değişim gibi çevresel faktörler hem şebeke hem de yük tarafında dengesizliklere neden olabilir. Bununla birlikte, DG'lerin devreye girmesi/çıkması, YEK-Tabanlı DG'lerin şebekeye entegrasyonunda kullanılan dönüştürücü ve inverter gibi güç elektroniği cihazlarındaki artış ve son yıllardaki gelişmelerle birlikte sayıları hızla artan EA şarj istasyonları gibi lineer olmayan yüklerdeki çoğalma geleneksel sistemlerdekinden farklı GKO'lara sebep olmaktadır. Tez çalışması kapsamında geliştirilen YEK-destekli test sistemi ile bu olaylar gerçekleştirilmiştir. Literatürdeki matematiksel ve simülatif veri testleriyle sınırlı olan yaklaşımlara göre büyük katkı sağlanmıştır.

AMOD çalışma tespiti için ÖİDD-Tabanlı yaklaşım önerilmiş olup ulusal/uluslararası standartlara uygun olarak minimum ADB ile tespit gerçekleştirilmiştir. Tespit

gerçekleştirildikten sonra çok kısa sürede gerekli koruma sistemi aktif edilerek DG şebekeden ayrılmıştır. ÖİDD-Tabanlı piramidal algoritma yaklaşımıyla, elde edilen sinyaldeki salınımlar azaltılmakta ve eşik değerler kolaylıkla seçilebilmektedir. ÖİDD, gürültülü koşullar altında SDD ve ADD yöntemlerine göre yüksek doğruluk performansı sağlamaktadır. Minimum ADB ile kısa sürede AMOD tespit edilebilmektedir. Bu avantajlarıyla, önerilen yöntem, farklı DG'ler için güvenilir ve kolaylıkla kullanılabilir bir koruma sağlar. Önerilen yöntemin avantajları aynı zamanda şu şekilde maddelenebilir [67]:

- Minimum ADB ile YEK-Tabanlı DG'ler için yeni sinyal analiz-Tabanlı AMOD çalışma tespit sistemi önerilmektedir.
- Geliştirilen piramidal algoritma yaklaşımına sahip ÖİDD-Tabanlı yöntem gerçek zamanlı olarak oluşturulan deneysel sistem ile test edilmiştir.
- OBN'den alınan sinyalde, salınımlar azaltılmıştır, eşik değerleri kolaylıkla seçilebilmektedir ve gürültü hassasiyeti diğer DD yöntemlerine göre daha düşüktür.
- Önerilen yöntem yalnızca OBN gerilim sinyalini kullanmaktadır. Bu durum, işlem yükünü en aza indirmektedir.
- ÖİDD-Tabanlı yöntem diğer DD-Tabanlı yöntemlerle karşılaştırılmış ve performansı farklı şebeke koşulları için değerlendirilmiştir.
- Önerilen yöntemle, DG uygulamaları için hem minimum ADB sağlanmıştır ve ortalama algılama süresi IEEE 929-2000 standartlarına uygun ve 75 ms'dir.

Literatürdeki sinyal analiz-Tabanlı olay tespit yöntemlerinde öncelikle olay sinyaline alan dönüşümü yapılarak katsayıları/özellikleri çıkarılmaktadır. Daha sonra ampirik testlerle eşik değerleri belirlenmekte ve özellik parametrelerine göre AMOD veya GKO tespit edilmektedir. Ancak, eşik değerlerine sahip uygulamalar, değerlerin seçilmesindeki zorluklar ve gürültülü koşulların neden olduğu belirsiz durumlar nedeniyle yanlış algılama ve kaçırılan algılama eğilimlerini gösterir. Bu durum özellikle nominal olay ile arıza durumunun birbirine çok yakın olduğu yüksek gürültü koşullarına sahip sinyaller için sorunlara neden olur. Ayrıca EA şarj cihazları gibi doğrusal olmayan yüklerde kompleks GKO'lar oluşabilir. Bununla birlikte, sabit bir eşik değeri seçmek, yoğun çentik oluşumu ve harmonik sorunlarla birlikte gerilim

profili bozulmalarının tespitinde sorunlara neden olacaktır. Önerilen ÖİDD-BKV-Tabanlı yöntemle bu dezavantajlar ortadan kaldırılmıştır. BKV algoritmaları, değişen ortamlara çok duyarlı olmadıkları için genellikle sağlamdır. Akıl yürütme süreci, makine öğrenimi tabanlı sınıflandırıcılarla karşılaştırıldığında genellikle basittir. Ayrıca bir optimizasyon algoritmasının kullanılmasını gerektirmez. Önerilen yöntemin literatüre katkısı şu şekilde sıralanabilir [109]:

- ÖİDD ile elde edilen detay katsayılarına bulanık mantık tabanlı eşik değer seçim mekanizması uygulanarak geleneksel sinyal işleme tabanlı yöntemlerin dezavantajları ortadan kaldırılmıştır.
- Önerilen basit ve güvenilir yöntem, sinyaldeki gürültüyü azaltmak için yoğun işlem gerektiren filtreleme işlemine olan ihtiyacı ortadan kaldırmıştır.
- Oluşturulan adaptif yapıyla, eşik değerlerin seçimindeki zorluklar, gürültülü ölçümler ve çalışma koşullarından kaynaklanan belirsiz durumlardan dolayı hatalı tespit ve kaçırılmış algılama eğilimi sorununun üstesinden gelinmiştir.
- Eşik değer yöntemlerinde sınır koşullarındaki tespit hatalarının önüne geçilmekte, aynı zamanda sadece gerilim sinyali kullanılarak maliyet ve hesaplama yükü en aza indirilmektedir.

Tez çalışması kapsamında, GKO tespiti ve sınıflandırması için sinyal analizi ve sınıflandırıcı kullanan hibrit bir yöntem önerilmiş ve performans testleri matematiksel, simülatif ve gerçek veri setleriyle gerçekleştirilmiştir. Önerilen ÖİDD ve çekirdek DVM-Tabanlı hibrit yöntemde olay genel tanıma doğruluğu %99,85 olarak belirlenmiştir. Düşük seviyede gürültü ve yüksek seviyede gürültü koşullarında, olay sınıflandırma doğruluğu ise aynı yöntemle sırasıyla %99,66 ve %99,32'dir. Önerilen yöntemin literatüre katkısı şu şekilde maddelenebilir [65]:

- Zaman-frekans analizinin çözünürlüğünü iyileştirmek için, mevcut DD-Tabanlı yöntemler arasında GKO sınıflandırılmasında "á trous" algoritmasına sahip ÖİDD-Tabanlı bir ayırıştırma yöntemi kullanılmıştır. ÖİDD yöntemi gürültü azaltma, tepe veya çukur algılama gibi avantajlara sahiptir ve yüksek frekanslarda yüksek çözünürlük elde eder.
- Beş farklı sınıflandırıcının (kNN, DVM, KA, RO, GAKA) en çok kullanılan ADD ve önerilen ÖİDD yöntemleri için performansları detaylı olarak incelenmiştir.

ADD-Tabanlı olarak geliştirilen ancak gürültü altında performansı oldukça düşük olan sınıflandırıcıların performansı, ÖİDD ile önemli ölçüde iyileştirilmiştir.

- ÖİDD ve DVM-Tabanlı hibrit yöntem, 25 ila 40 dB gürültü altında bile yüksek doğruluk ve güvenilirlikle GKO sınıflandırması yapabilmektedir.

Sinyal analizi ile sınıflandırıcı kullanan ÖİDD-GAKA-Tabanlı GKO sınıflandırma yöntemi de tez çalışması kapsamında geliştirilmiştir. Referans [110]'da, hem geleneksel sınıflandırıcılar hem de daha yeni önerilen DÖ-Tabanlı yaklaşımlar olmak üzere 11 farklı sınıflandırıcı için UCI ve KEEL veri depolarındaki farklı alanlarda kullanılan 71 veri seti çeşitli performans kriterlerine göre test edilmiştir. Sonuçlar, GAKA'nın diğer makine öğrenmesi algoritmaları arasında test için en hızlı algoritma olduğunu göstermektedir. Bu üstünlüklerinin yanı sıra GAKA'nın bazı dezavantajları da bulunmaktadır. GAKA'nın gürültülü sinyallerde aşırı öğrenme sorunu vardır. Sinyal analiz işlemi ile gürültülü ortamlarda dahi elde edilecek özellikler ile bu dezavantaj ortadan kaldırılabilmektedir. GKO'ların öznelik çıkarımı için piramidal ÖİDD tekniği kullanılmış ve öznelik vektörü elde edilmiştir. Ayrıca geleneksel DD-Tabanlı yöntemlerin gürültüye duyarlı olduğu bilinmektedir. Önerilen piramidal ÖİDD ve GAKA-Tabanlı yöntemle bu dezavantajlar ortadan kaldırılmıştır. Önerilen yöntemin literatüre katkısı şu şekilde maddelenebilir [66]:

- FV tabanlı bir mikroşebekede GKO'ları sınıflandırmak için piramidal ÖİDD-GAKA-Tabanlı yöntem önerilmiştir.
- Piramidal ÖİDD, DG işlemleriyle ilişkili GKO bağlamında öznelik çıkarımı için kullanılmıştır.
- Önerilen piramidal ÖİDD, hızlı bir yöntem olan GAKA'nın aşırı öğrenme sorununu çözmek için kullanılmıştır.
- Önerilen yöntem yüksek frekans çözünürlüğüne sahip olup GAKA performansı piramidal ÖİDD ile önemli ölçüde iyileştirilmiştir.

Sahada kaydedilen GKO'lar kompleks yapıda olabilir. Kompleks GKO'lar, birbirine bindirilen ve/veya aynı dönemde meydana gelen birden fazla olayın birleşimini ifade eder. Literatürdeki çalışmalar, genellikle tek veya ikili GKO kombinasyonlarını ele alsa da, kompleks GKO'lar aynı anda meydana gelen sadece iki olayla sınırlı değildir [111]. Sürdürülebilir ve güvenilir bir DG-Tabanlı mikroşebeke sistemi kurmak için

çevrimdışı karmaşık GKO sınıflandırma teknolojilerine de ihtiyaç vardır. Ayrıca, kompanzasyon cihazlarının planlanması ve tüketim tarafı ekipmanlarının daha uzun süreli ve tutarlı çalışması için GKO'ların ayrıntılı bir şekilde tespiti ve sınıflandırması gerekmektedir. Tez çalışması kapsamında tekli ve kompleks GKO olaylarının sınıflandırmasını gerçekleştirmek için ağırlıklı çoğunluk oylaması (Weighted Majority Voting - AÇO) ve çoklu DÖ sınıflandırıcıları kullanan bir yöntem de geliştirilmiştir. Yöntemin literatüre genel katkısı şu şekilde sunulabilir [112]:

- YEK-Tabanlı mikroşebeke için AÇO-Tabanlı çoklu derin sınıflandırıcı modelleri içeren bir yöntem önerilmektedir.
- Oylama sisteminde, çoklu derin sınıflandırıcıların kullanılmasındaki zorluklar ele alınmıştır.
- Geleneksel üç aşamalı süreçten (sinyal analizi ve öznitelik çıkarımı – öznitelik seçimi – çoklu sınıflandırıcı ile sınıflandırma) farklı olarak otomatik öznitelik çıkarma ve sınıflandırma için kapalı döngü derin ESA, UKSB ve hibrit (ESA-UKSB) modelleri birlikte kullanılmıştır.
- YEK-Tabanlı DG'ler içeren ve farklı lineer olmayan yükler barındıran bir sistemdeki iki olayla sınırlı olmayan daha kompleks GKO'ların sınıflandırılması gerçekleştirilmiştir.

1.3 Metnin Organizasyonu

Tez çalışması 9 bölümden oluşmaktadır. 2. bölümde AMOD ve GKO tanımları, nedenleri ve bunların ulusal/uluslararası standartlarındaki yeri ayrıntılandırılmıştır. 3. bölümde, önerilen yöntemlerde kullanılan metot ve algoritmaların teorik arka planı verilmiştir. Bölüm 4, GKO veri üretimi, kurulumu yapılan test sistemi ve geliştirilen güç analizörü hakkında bilgi vermektedir. Bölüm 5 ve Bölüm 6, sırasıyla önerilen AMOD çalışma ve GKO sınıflandırma yöntemlerini ele almaktadır. Aynı zamanda bu bölümlerde, tespit/sınıflandırmaya ilişkin matematiksel, simülasyon ve gerçek veri sonuçları verilmiştir. 7. bölümde önerilen yöntemler literatürdeki yöntemlerle karşılaştırılmıştır. Bölüm 8, önerilen yöntemin kullanıldığı kesici prototipini göstermektedir. Son bölümde ise çalışma sonuçlandırılmış ve gelecek çalışmalardan bahsedilmiştir.

2. GÜÇ KALİTESİ OLAYLARI VE ADA MOD ÇALIŞMA

Bu bölümde, öncelikle AMOD çalışma ve GKO'ların tanımları, nedenleri ve etkileri ele alınmıştır. Ayrıca, DG sistemlerin ve EA şarj cihazları gibi lineer olmayan yüklerin sisteme entegrasyonundaki uluslararası standartlar da detaylandırılmıştır.

2.1 Ada Mod Çalışma Tanımı ve İlgili Standartlar

Bir dağıtım sistemi güç sisteminin kalan kısmından elektriksel olarak izole edildiğinde, enerji akışının halen kendisine bağlı bulunan dağıtık üretim kaynağı tarafından devam ettirilme durumudur. Bu durum, AMOD çalışabilme özelliği taşımayan DG sistemin belirlenen gerilim ve frekans değerlerinin dışında kalmasına neden olur. Sonuçta, elektriksel cihazlar ve sistemler zarar görebilir, işletme personeline yaralanmalar, can kayıpları meydana gelebilir. Güç üretim tesislerinde zararlar oluşabilir. Senkronize olmayan açma/kapama işlemleri nedeniyle büyük boyutta bir kesinti (blackout) meydana gelebilir. Tam tersi durumda ise, sisteme güç sağlana DG'lerin yanlış AMOD çalışma tespitinde bulunup kendini korumaya alması büyük ekonomik kayıplara neden olacaktır. Genel olarak, doğru AMOD koşullarının tespiti ve tanımlanması, kararlı ve verimli bir mikroşebeke sistemi sürdürmek için hayati önem taşır.

IEEE (Institute of Electrical and Electronics Engineers) ve IEC (International Electrotechnical Commission) gibi çeşitli uluslararası kuruluşlar, DG'lerin entegrasyonu, kontrolü ve işletilmesine ilişkin standartları tanımlamıştır. Bu standartların temel amacı, entegre güç sistemleri ağlarının performansı, güvenliği ve emniyeti, izlenmesi ve bakımı da dahil olmak üzere özel gereksinimleri sağlamaktır. Ayrıca standartlar, yük kalite faktörü, algılama süresi, gerilim çalışma aralıkları, frekans çalışma aralıkları gibi bazı parametreler dikkate alınarak AMOD çalışma tespit yöntemlerinin tasarlanması sırasında uzmanlara kapsamlı bir rehber sağlamaktadır. Adalanma tespitinin performansını değerlendirmek için kullanılan en yaygın standartlar Çizelge 2.1'de sunulmuştur [27,44]. IEEE 929-2000 [4], IEE 1547-2018 [8] ve IEC 62116 [113] standartlarında AMOD çalışma durumu, maksimum 2

saniyede tespit edilmeli ve gerekli koruma tedbirleri alınmalıdır. Daha önce tartışılan AMOD çalışma tespit yöntemlerinin çoğunluğu, bazı sinyal işleme ve makine öğrenmesi-Tabanlı yöntemler hariç, AMOD durumunun 2 saniyeden daha kısa sürede tespit edilmesini gerektiren IEEE ve IEC standartlarını karşılayabilmektedir. Ancak bu yöntemlerde de GK'ye etki ve geniş bir ADB bulunduğu unutulmamalıdır.

Çizelge 2.1 : AMOD çalışma ile ilgili standartlar.

Parametreler	IEEE Std. 929-2000	IEEE Std. 1547-2018	IEC 62116
Frekans aralığı	$59,3 \leq f \leq 60,5$ Hz	$59,3 \leq f \leq 60,5$ Hz	$f_0 - 1,5$ Hz $\leq f$, $f_0 + 1,5$ Hz $\leq f$
Gerilim aralığı	$0,88 \leq V \leq 1,10$	$0,88 \leq V \leq 1,10$	$0,85 \leq V \leq 1,15$
Kalite faktörü	2,5	1	1
Tespit süresi	$t < 2$ s	$t < 2$ s	$t < 2$ s

IEEE 1547-2108 standardına göre, OBN'deki küçük gerilim değişiklikleri 2 saniyeden kısa sürede algılanmalıdır. Ancak, nominal gerilime göre 0.5 pu'dan düşük veya 1.2 pu'dan büyük gerilim değişiklikleri durumunda bu algılama süresi 0.16 saniyenin altına inmelidir. Ayrıca, bu standartlardaki DG entegrasyonunda yer alan düzenlemeler şu şekilde özetlenebilir [44]:

- Bir DG'de, AMOD çalışma meydana gelmesinden sonraki tedbirler,
- GK, frekans ve gerilimin uygun bir şekilde yönetimi ve kontrolü,
- Güç akışının düzenlenmesi,
- DG'lerin izlenmesi,
- Sisteme katkı sağlayan ve sağlamayan DG'lerin belirlenmesi
- DG'lerin bağlı olduğu transformatörlerle ilgili düzenlemeler.

DG Sistemin şebeke bağlantısının sorunsuz çalışması için IEC 62116 standardının tüm hususlarının dikkate alınması gerekmektedir. IEC 62116 standardına göre DG sisteminin işletilmesi için bazı temel gereksinimler şunlardır [28]:

- Eğer nominal gerilim (V_{nom}) belirtilen sınırları aşıyorsa, ($\%88$ of $V_{nom} < V_{nom} < \%110$ V_{nom}) DG, şebekeden 2 saniyeden daha kısa bir süre içinde izole edilmelidir.

- Eğer nominal frekans (f_{nom}) belirtilen sınırları aşıyorsa, (f_{nom} 'un 48,5 Hz altında veya f_{nom} 'un 51,5 Hz üstünde) DG, şebekeden 0.2 saniyeden daha kısa bir süre içinde izole edilmelidir.
- Eğer V_{dc} , 1 A'den fazla bir değeri aşıyorsa, DG'lerin şebekeden izole edilmesi 2 saniyeden daha kısa bir süre içinde gerçekleştirilmelidir.
- Yüksek talebi yönetmek için DG'lerle talep tarafı yönetimi sağlanmalıdır.
- DG çıkış gücünün güvenilirliği korunmalıdır.
- Özellikle arıza sırasında aktif ve reaktif güç arasındaki dengeyi korumak için reaktif güç kontrolü sağlanmalıdır.
- GK, harmonikleri sınırlayarak, kırpışma etkilerini en aza indirgeyerek ve güç faktörünü koruyarak sağlanmalıdır.

FV-Tabanlı DG sistemlerde kullanılan şebeke etkileşimli inverterler için önemli gereksinimler ise IEEE 929-2000 (Recommended Practice for Utility Interface of Photovoltaic Systems) standardında tanımlanmaktadır. Bu çalışma gereksinimleri aynı zamanda UL-1741 [114] standardı ile uyumludur. IEEE 929, bir dizi konuyu ele alsa da, en dikkat çekici bölümü, güvenlik ve koruma işlevlerini içermektedir ve FV inverterin anormal şebeke koşullarına tepkisini ele alır [4]. Gerilim ve frekans dalgalanmasının üzerinde durmakla beraber bir dizi parametre sınır değer seti sunar. Ayrıca, bu standartta AMOD çalışma yöntemlerinin incelenebileceği bir test sistemi de tanımlanmıştır. Tez çalışmasında, önerilen AMOD tespit yönteminin veri seti ve performans değerlendirmesi bu standarda göre yapılmış olup Bölüm 4'te test sistemi ayrıntılandırılmıştır. IEEE 929 standardına göre gerilim ve frekans sınır değerleri Çizelge 2.2'de verilmiştir.

Çizelge 2.2 : Şebeke etkileşimi için gerilim ve frekans sınırları.

Durum	Gerilim	Frekans	Açma Süresi
A	$0,5 V_{nom}$	f_{nom}	6 periyot
B	$0,5 V_{nom} < V < 0,88 V_{nom}$	f_{nom}	2 saniye
C	$0,88 V_{nom} \leq V \leq 1,10 V_{nom}$	f_{nom}	-
D	$1,10 V_{nom} < V < 0,37 V_{nom}$	f_{nom}	2 saniye
E	$1,37 V_{nom} \leq V$	f_{nom}	2 periyot
F	V_{nom}	$f < f_{nom} - 0,7 \text{ Hz}$	6 periyot
G	V_{nom}	$f > f_{nom} + 0,5 \text{ Hz}$	6 periyot

2.2 GK / GKO Tanımları ve İlgili Standartlar

Kaynaklarda GKO'nun çeşitli tanımları önerilmiş olup tanımlar aşağıda maddelenmiştir [115,116]:

- GK, hassas ekipmanın çalışmasına uygun bir konuda güç sağlanması ve topraklanması kavramıdır [117].
- Bir elektrik sisteminde belirli bir noktadaki elektriğin özelliklerinin, belirli bir referans teknik parametre setine karşı değerlendirilmesidir [118].
- GK gerilim kalitesi ve akım kalitesinin birleşimidir [18].
- Güç sistemlerinin gerilim, akım ve frekans sinyallerini bozulmadan iletme yeteneği, güç kaynağının kalitesi olarak adlandırılır [119].
- Bir ekipmanın önemli bir performans veya yaşam beklentisi kaybı olmadan amaçlandığı şekilde çalışmasına olanak tanıyan bir dizi elektriksel sınırdır.

Özet olarak GK, gerilim ve akım karakteristiği ile doğrudan ilgilidir ve ideal dalga formundan sapmaya yol açan bir problem GKO olarak isimlendirilir [120]. GK standartları ise GKO'ların güvenilir sınırlarını tanımlamaktadır. Standartlarda, sistemdeki generatör ve yüklerin ihmal edilebilir çalışma koşulları için gerilim, akım ve bunların değişim limitleri tanımlanmaktadır. Ayrıca, bu standartlarda uygun izleme cihazlarının seçimi, bu cihazların sınırları, uygulama yöntemleri ve sonuçların açıklaması da gösterilir. GKO sınıflandırılması, IEEE 1159-2019 standardı [121] ve Avrupa EN 50160 standardı [122] tarafından belirlenen gerilim ve akım sinyali değişimleri için nominal işletme koşullarına göre belirlenen eşik limit setlerine dayanmaktadır. Ayrıca, IEC 61000-4-30 standardı [118], 50/60 Hz elektrik güç sistemlerinde elektronik parametrelerin ölçümü ve yorumlanması için tutarlı teknikleri içermekte olup geliştirilen güç analizöründe bu standartlar dikkate alınmıştır.

Tez çalışmasında, GKO sınır parametrelerinin belirlenmesi amacıyla IEEE 1159-2019 standardı dikkate alınmıştır. Bu standart, GK izleme, GK ile ilgili terimler ve GK'nin elektrik dağıtım şirketi ve tüketici üzerindeki etkisi hakkında önerilen bir uygulama standardını içermektedir. Bu standart aynı zamanda çeşitli GKO'ların gerilim büyüklüğü, süre ve spektral içerik değişimi açısından farklılıklarını belirlemektedir. Çizelge 2.3'te, gerilim büyüklüğü, süre ve spektral içerik değişimine dayalı çeşitli GKO'ların sınır değerleri vurgulamaktadır.

Çizelge 2.3 : GKO kategorizasyonu [115].

GKO	Spektral İçerik	Zaman Aralığı	Gerilim Değişimi
Kesinti	-	0,5 periyot -3 sn (kısa), 3 sn - 60 sn (geçici)	< 0,1 pu
Çökme	-	0,5 periyot - 30 periyot (anlık), 30 periyot - 3 sn (kısa süreli) 3 sn - 60 sn (geçici)	0,1 pu – 0,9 pu
Sıçrama	-	0,5 periyot - 30 periyot (anlık) 30 periyot - 3 sn (kısa süreli) 3 sn - 60 sn (geçici)	1,1 pu – 1,8 pu 1,1 pu – 1,2 pu 1,1 pu – 1,2 pu
Harmonikler	0 - 9 kHz	Durağan durum	%0 - %20
Ara Harmonikler	0 - 9 kHz	Durağan durum	%0 - %2
Çentik	-	Durağan durum	-
Gürültü	Geniş bant	Durağan durum	%0 - %1
	5 ns	< 50 ns	-
Darbeli Geçici Durum	1 μ s	50 ns - 1ms	-
	0,1 ms	>1 ms	-
Osilasyonlu Geçici Durum (Düşük frekans)	< 5 kHz	0,3 – 50 ms	0 – 4 pu
Osilasyonlu Geçici Durum (Orta frekans)	5 – 500 kHz	20 μ s	0 – 8 pu
Osilasyonlu Geçici Durum (Yüksek frekans)	0,5 – 5 MHz	5 μ s	0 – 4 pu

DG için devreye girip çıkarken, gerilim düşümü veya yükselmesi sınır değerleri EN 50160 standardına göre \pm %3,3 V olarak belirlenmiştir. Frekanstaki değişim, sistemindeki frekans değerinin nominal değerinden sapmasıdır. Özellikle sistemdeki yük miktarı ile üretilen güç miktarının uyuşmamasından kaynaklanır. EN 50160 standartlarında çalışma süresine göre frekans değer aralıkları belirtilmiştir.

IEEE 519-2022 standardında [123] için gerilimdeki toplam harmonik bozulma (THB) miktarının kabul edilebilir sınırları güç sisteminin gerilim seviyesine göre değişiklik gösterir. Tüm değerler, OBN'deki nominal frekanstaki gerilimin yüzdesi olarak ifade edilmelidir. Çizelge 2.4, nominal frekansın tam sayı katları olan ve 50. harmonik dahil olmak üzere ara harmoniklere sahip olan gerilim harmonikleri için geçerlidir.

Çizelge 2.4 : Gerilim THB sınır değerleri.

Bara Gerilimi (V)	Ara Harmonik Değeri (%) $h \leq 50$	(THB) (%)
$V \leq 1$ kV	5,0	8,0
1 kV < V \leq 69 kV	3,0	5,0
69 kV < V \leq 161 kV	1,5	2,5
161 kV < V	1,0	1,5

Gerilimdeki THB sınırlarıyla beraber ara harmonikler için de maksimum izin verilen değerler IEEE 519-2022 ve EN 50160 standartlarında yer almaktadır. OBN'den alınan ölçüme dayalı bu değerler Çizelge 2.5'te verilmiştir.

Çizelge 2.5 : Ara harmonikler için sınır değerler.

Parametreler	IEEE 519-2022	EN 50160
Gerilim THB değeri	8,0	8,0
3. gerilim harmoniği	5,0	5,0
5. gerilim harmoniği	5,0	6,0
7. gerilim harmoniği	5,0	5,0
9. gerilim harmoniği	5,0	1,5
11. gerilim harmoniği	5,0	3,5

Çentik olayı, bir sistemde şebeke frekansında çalışan bir dönüştürücünün darbe sayısı kadar tekrar eden yarım periyottan kısa süreli gerilim dalga şekli bozulması olarak tanımlanır. Bu olay, dönüştürücünün çalışması sırasında kısa süreli gerilim dalga bozulmalarının meydana gelmesiyle karakterize edilir. IEEE 519-2022 standardına göre çentik alan ve derinliğine bağlı sınır değerleri belirlenmiştir. OBN'deki gerilim dalga biçimlerinde fazlar arası çentik derinliği sınırları, Çizelge 2.6'daki gösterilmiştir.

Çizelge 2.6 : Anahtarlama elemanlarında kaynaklı çentiklerinde önerilen sınırlar.

	Özel Uygulamalar	Genel Sistem	Dönüştürücülü Sistemler
Çentik Derinliği	%10	%20	%50
Çentik Alanı	16400	22800	36500

Kırpışma aydınlatma sistemleri üzerinde olumsuz etkilere neden olan gerilim dalgalanmaları sonucu ortaya çıkar. Kırpışma, ışık kaynaklarının parlaklık seviyelerindeki ani ve tekrarlayan değişimler olarak tanımlanır. IEEE 1453-2022 standardı [124], gerilim dalgalanmaları ve bu dalgalanmaların neden olduğu ışık kırpışması ölçümlerini/sınırlarını belirlemek için değerler belirtmektedir.

GKO'ların nedenleri, sisteme etkileri ve dalga biçimleri Çizelge 2.7'te verilmiştir. Arıza konumuna ve DG çalışma modu koşullarına bağlı olarak, bir arıza veya işletme sorunu gerilim çökmesine, kesintiye veya sıçramaya neden olabilir. Gerilim çökmesi olayı, şebeke frekansında çalışan bir sistemde 10 ms ile 60 s zaman aralığında sınırlı olmak kaydıyla, gerilimdeki %10 ile %90 arasında meydana gelen azalma olarak tanımlanır. Aşırı güçlü motorların devreye alınması, büyük güçte yüklerin anahtarlanması, büyük kapasite gruplarının devreden çıkarılması, tek faz-toprak

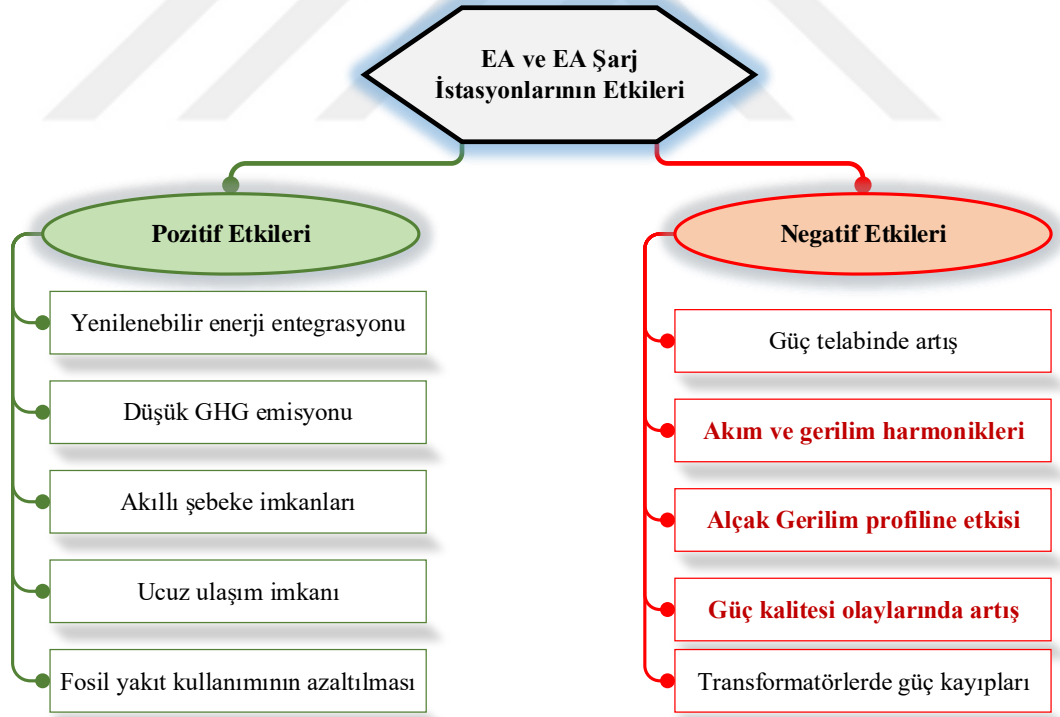
arızaları, EA şarj sistemlerinin devreye alınması ve YEK-Tabanlı DG'lerin aniden sisteme entegrasyonu, mikroşebekelerde gerilim çökmelerine neden olabilir.

Çizelge 2.7 : GKO'ların nedenleri, etkileri ve dalga biçimleri.

GKO sınıfının nedenleri ve etkileri	Gerilim dalga şekli
<p>C2-Gerilim çökmesi</p> <p>Nedenleri: Kısa devre arızaları, büyük güçteki yüklerin anahtarlaması, mikro-şebekede dağıtık genatörlerin aniden başlatılması</p> <p>Etkileri: Veri kaybı, sistem arızaları, çökme</p>	
<p>C3-Gerilim sıçraması</p> <p>Nedenleri: Kısa devre arızaları, büyük güçteki kapasitelerin anahtarlaması, mikro-şebekedeki büyük güçteki yüklerin devreden alınması</p> <p>Etkileri: Ekipman hasarı ve ömürde azalma, açma</p>	
<p>C4-Gerilim kesintisi</p> <p>Nedenleri: Kısa devre arızaları, büyük güçteki yüklerin AMODda anahtarlanması, bileşen arızaları, CB açma</p> <p>Etkileri: Hasarlı çökme, veri kaybı</p>	
<p>C5-Harmonikler</p> <p>Nedenleri: Doğrusal olmayan güç elektroniği tabanlı sürücüler (araç şarj istasyonları), ark fırınları, aydınlatma dimmerleri</p> <p>Etkileri: Sistem durması, transformatörlerin ısınma sorunu</p>	
<p>C6-Kırpışma</p> <p>Nedenleri: Yük ekipmanlarının, ark fırınlarının, indüksiyon makinelerinin aralıklı çalışması</p> <p>Etkileri: Sistem durması, veri kaybı, ışık kırpışması</p>	
<p>C7-Osilasyonlu geçici durum olayları</p> <p>Nedenleri: Büyük kapasite banklarının ve indüktif yüklerin anahtarlanması</p> <p>Etkileri: Veri kaybı, olası hasar</p>	
<p>C8-Darbeli geçici durum olayları</p> <p>Nedenleri: Yıldırım düşmesi, mikro-şebekeler için ada değiştirme, şebeke hatası temizleme</p> <p>Etkileri: Veri kaybı, sistem durması</p>	
<p>C9-Çentik</p> <p>Nedenleri: Doğrusal olmayan güç elektroniği tabanlı sürücüler (araç şarj istasyonları), ark fırınları</p> <p>Etkileri: Veri kaybı, sistem durması</p>	

Gerilim sıçraması olayı, şebeke frekansında çalışan bir sistemde 10 ms ile 60 s zaman aralığında sınırlı olmak kaydıyla, gerilimdeki %110-%180 arasında meydana gelen artış olarak tanımlanır. Faz-faz arızaları, yüklerin anahtarlanması ve büyük kapasite bankalarının açılması, güç sisteminde gerilimin yükselmesine neden olabilir. Ayrıca, YEK-Tabanlı DG'lerdeki çevresel koşullara bağlı aktarılan güçteki dalgalanmalar da DG'lerde gerilim sıçramasına neden olabilir. Kısa süreli gerilim kesintisi ise 1 ile 9 döngü için gerilim genliğinin %90'ından fazla bir düşüş olarak tanımlar. Güç sistemlerinde kısa devre direncine bağlı olarak iki faz-toprak arızaları ve üç faz simetrik arızalar gerilim kesintisine neden olur. Ayrıca DG yapısında AMODunda büyük yüklerin açılması, kesici açma ve bileşen arızaları da kesintiye neden olabilir.

YEK-Tabanlı DG'lerle beraber sayısı hızla artan EA şarj cihazlarının doğrusal olmayan özellikleri, GK için önemli bir sorundur. Sayısı artan EA şarj sistemlerinin şebekeye entegrasyonu harmoniklere neden olur, gerilim profilini etkiler ve nihayetinde GK önemli ölçüde etkilenir. EA ve EA şarj istasyonlarının sisteme olumlu ve olumsuz etkileri Şekil 2.1'de gösterilmiştir.



Şekil 2.1 : EA ve EA şarj istasyonlarının etkileri.

3. TEORİK ARKA PLAN

Bu bölümde, çalışmada kullanılan yöntemlerin teorik alt yapısı verilmektedir. Sırasıyla dalgacık dönüşümü (DD) çeşitleri (sürekli dalgacık dönüşümü (SDD), ayrık dalgacık dönüşümü (ADD), örnek indirgenmemiş dalgacık dönüşümü (ÖİDD)), bulanık mantık karar vericiler (BKV-Tip-1), sınıflandırıcılar (destek vektör makineleri (DVM), karar ağaçları (KA), rastgele orman (RO), gradyan artırıcı karar ağaçları (GAKA), k-en yakın komşu (kNN)) ve derin ağ yöntemleri (evrişimli sinir ağları (ESA), uzun kısa süreli bellek (UKSB) ve hibrit yaklaşımlar (ESA-UKSB)) ayrıntılandırılmıştır.

3.1 Dalgacık Dönüşümü

Eldeki sinyallerin zaman-frekans uzayında analizi, günümüzde birçok uygulama alanında oldukça önemli bir role sahiptir. Bu doğrultuda, DD yöntemi bir sinyalin zaman-frekans uzayında ayrıştırılmasına olanak sağlayarak, sinyaldeki farklı frekans bileşenlerinin ve zaman aralıklarının ayrıntılı bir şekilde incelenmesine olanak tanır. Ayrıca çeşitli üstünlükleri ile DD, sinyal işleme, veri analizi, görüntü işleme ve nesne tanıma gibi pek çok alanda da önemli bir yere sahiptir.

3.1.1 Sürekli dalgacık dönüşümü (SDD)

DD yöntemi, KZFD’de kullanılan sabit pencereleme kavramından farklı olarak, ana dalgacık ($\psi(x)$) adı verilen ölçeklenebilir bir pencere kavramı kullanır. $\psi_{s,b}$ fonksiyonu şu şekilde ifade edilebilir [125]:

$$\psi_{s,b} = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-b}{s}\right) \quad (3.1)$$

Denklem 3.1’de, b, kaydırma faktörünü ve s, ölçeklendirme faktörünü temsil etmektedir. Kaydırma parametresi (b), sıfırdan büyükse sağa doğru kaydırır ve sıfırdan küçükse sola doğru kaydırır. Ana dalgacık, FD yöntemindeki sinüs işaretinin aksine sonlu, asimetrik ve düzensizdir.

Ana dalgacık fonksiyonu koşulları Denklem 3.2 ve Denklem 3.3'te belirtilmiştir. Bir fonksiyona, dalgacık fonksiyonu denilebilmesi için işaretin integralinin sıfır, aynı fonksiyonun karesinin integralinin de bir olması gerekir.

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (3.2)$$

$$\int_{-\infty}^{\infty} \psi^2(t) dt = 1 \quad (3.3)$$

SDD, kaydırılan dalgacık fonksiyonunun tüm zaman için ölçekleme miktarı ile çarpılmasıyla elde edilir [126]. Çarpma, çok sayıda dalgacık katsayısıyla sonuçlanır. SDD, $\psi_{s,b}$ dalgacık fonksiyonu yardımıyla Denklem 3.4'teki gibi belirlenir Burada $f(t)$, SDD uygulanacak sürekli zamanlı sinyali ve $\psi_{s,b}^*$, $\psi_{s,b}$ 'nin kompleks eşleniğidir.

$$SDD(s, b) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} f(t) \psi^* \left(\frac{t-b}{s} \right) dt \quad (3.4)$$

Karşılaştığımız gerçek dünya sinyallerinin çoğu, ayrık zamanlı örnekler olarak mevcuttur ve Denklem 3.4 entegrasyonunun kapalı formda bir çözümü yoktur. Bu nedenle çalışmada, sürekli dalgacıkların ölçekleri ve kaymaları için bir dizi ayrık değer seçilmiş ve ardından SDD uygulanmıştır [60]. SDD'yi bir sinyale uygularken, ana dalgacık ofset değerine bağlı olarak zaman eksenini boyunca kaydırılır. Her kayma için, ana dalgacık ile sinyal arasındaki benzerlik katsayısı hesaplanır. Katsayı bulma işlemine sinyalin tamamı kaplanana kadar devam edildikten sonra dalgacık ölçeği değiştirilir ve her ölçek değeri için aynı adımlar tekrarlanır.

3.1.2 Ayrık dalgacık dönüşümü (ADD)

SDD yönteminde hesaplama süresi çok yüksektir, bu nedenle gerçek zamanlı uygulamaların SDD ile ayrıştırılması genellikle tercih edilmez. Aksine, ADD yöntemi genellikle gerçek zamanlı sinyal analizi uygulamalarında kullanılır. Dalgacık fonksiyonu kullanılarak, ADD Denklem 3.5'teki gibi hesaplanabilir.

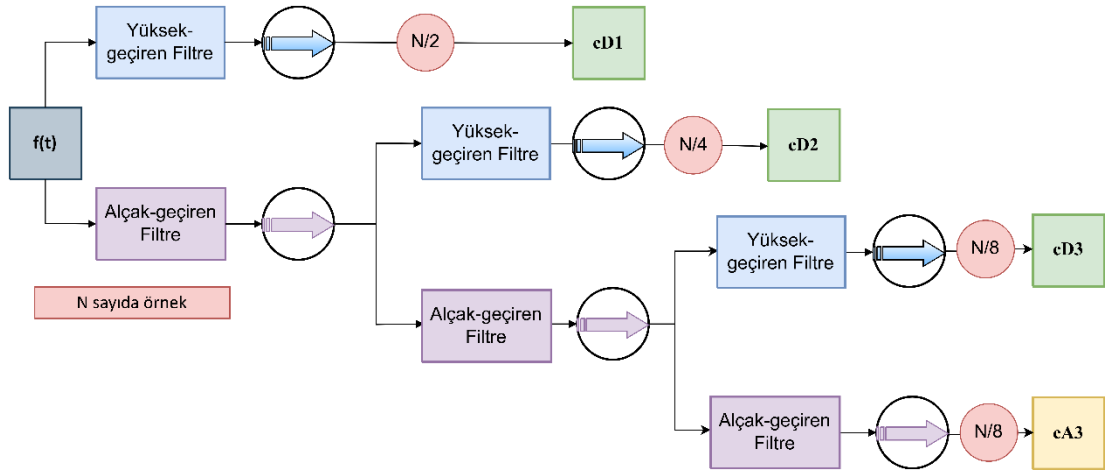
$$ADD(s, b) = 2^{-s/2} \int f(t) \psi(2^{-s}t - b) dt \quad (3.5)$$

Filtre bankları, ADD uygulamalarında çok seviyeli ayrıştırmalarda kullanılabilir. Çoklu çözünürlük analizi (ÇÇA) yöntemi ile, yüksek ve alçak geçiren filtreleri kullanarak bir sinyal iki alt frekans değerinden daha fazla frekans bandına ayrılabilir [127]. ADD katsayıları, giriş sinyalinin alçak ve yüksek geçiren filtrelerle ÇÇA yöntemi kullanılarak evrilmesinin sonucudur. Denklem 3.6'da ÇÇA ile ADD katsayılarının elde edilişi gösterilmiştir:

$$c_j^D[k] = (h_0 * c_{j-1}^D[k]) = \sum_n c_{j-1}^D[n] h_0(n - 2k);$$

$$w_j^D[k] = (h_1 * c_{j-1}^D[k]) = \sum_n c_{j-1}^D[n] h_1(n - 2k)$$
(3.6)

Denklem 3.6'da, h_0 ve h_1 sırasıyla yüksek geçiren ve alçak geçiren filtre banklarını tanımlanmaktadır. c_0 ise Denklem 3.6'daki 1-D giriş sinyalidir. $W = \{w_1, \dots, w_j \text{ and } c_j\}$ ise 1-D sinyal için ÇÇA yönteminin sonucu olan ADD katsayılarıdır. Filtre bankası modeline dayanan gerçekleştirilen ÇÇA algoritmasında, yaklaşım katsayıları (cA_n) yüksek ölçekli ve düşük frekanslı sinyalleri gösterirken, detay katsayıları (cD_n) düşük ölçekli ve yüksek frekanslı sinyallerde baskındır. Üç seviyeli ayrıştırma sonucunda elde edilen detay ve yaklaşım katsayıları Şekil 3.1'de gösterilmiştir. Filtre çıkışlarında örnek sayısının yarıya düşürülmesi, analiz edilen sinyalde özellikle düşük frekanslı bileşenlerin bilgilerinin kaybolmasına neden olabilir.



Şekil 3.1 : Üç seviyeli ÇÇA ile ADD ayrıştırmasında detay ve yaklaşım katsayıları.

3.1.3 Örnek indirgenmemiş dalgacık dönüşümü (ÖİDD)

Aşağı örnekleme, ADD yöntemlerinde orijinal sinyaldeki bazı bilgilerin kaybolmasına neden olur. SDD yönteminin uygulama sorunları ve performans sınırlamaları vardır. Bu dezavantajlar, ÖİDD ile önemli ölçüde iyileştirilebilir. Bu yöntem, öteleme değişmez (translation-invariant) olduğundan ve her ölçekte aynı sayıda katsayıya sahip bir zaman serisini temsil ettiğinden, durağan veya durağan olmayan sinyallerde zaman/frekans konumu gibi gizli bilgilerin oluşumunu tespit etmek için idealdir [65-67]. Kilit nokta, ÖİDD'nin öteleme değişmez olması ve SDD'ye ortonormal ADD tarafından sağlanan yaklaşımdan daha yoğun bir yaklaşım vermesidir. Ayrıca, farklı gürültü seviyeleri altında ve gürültüsüz koşullar altında ÖİDD tekniğinin algılama doğruluğu, diğer DD-Tabanlı yöntemlerden daha yüksektir. ÖİDD analizinde kullanılan farklı algoritmalar bu bölümde ele alınmıştır.

3.1.3.1 à trous algoritması ile ÖİDD ayrıştırması

ADD, aynı zamanda filtre bankları kullanılarak Denklem 3.7'deki gibi ifade edilebilir.

$$ADD(j, k) = \sum_{n \in \mathbb{Z}} \sum_{k \in \mathbb{Z}} S(n) g_{j,k}(n), \quad g_{j,k} \in \mathbb{Z}, j \in \mathbb{N}, k \in \mathbb{Z} \quad (3.7)$$

burada, $S(n)$ ayrıştırılacak sinyal ve $g_{j,k}(n)$ sonlu enerjili ana dalgacık fonksiyonudur. Denklem 3.8'de $g_{j,k}(n)$ tanımlanmıştır:

$$g_{j,k}(n) = a_0^{-\frac{j}{2}} g(a_0^j n - k b_0) \quad (3.8)$$

Uygun a_0 ve b_0 kullanılarak, ölçeklendirilmiş ve kaydırılmış ana dalgacık ailesi, $l^2_{(\mathbb{Z})}$ 'nin ortonormal tabanını oluşturur. Basitçe $x = 2$ ve $y = 1$ seçilerek ikili-ortonormal bir dalgacık dönüşümü elde edilir ve ayrıştırma işlemini kolaylaştıran ÇÇA yöntemi artık sinyale uygulanabilir. $S(n)$ ve $g_{j,k}(n)$ arasında Denklem 3.9'daki ilişki bulunmaktadır:

$$S(n) = \sum_{n \in \mathbb{Z}} \sum_{k \in \mathbb{Z}} d_{j,k} g_{j,k}(n) \quad (3.9)$$

burada, $d_{j,k}$ katsayılarına, ayrıştırılacak sinyal ile ana dalgacık işlevi arasındaki 'benzerlik indeksleri' denir. Sinyalin ADD'si, yüksek frekansları analiz etmek için bir

dizi yüksek geçiren filtreden ve düşük frekansları analiz etmek için bir dizi alçak geçiren filtreden geçirilerek hesaplanır. Detay katsayıları (düşük frekanslı sinyaller (cD_n)) ve yaklaşım katsayıları (yüksek frekanslı sinyaller (cA_n)), ÇÇA ayrışımının bir sonucu olarak elde edilir. cD_n ve cA_n katsayıları şu şekilde elde edilir:

$$cA[n] = \sum_k S(k)g[2n - k]; \quad cD[n] = \sum_k S(k)h[2n - k] \quad (3.10)$$

Denklem 3.10'da $h(n)$ ve $g(n)$ ilgili filtre katsayılarıdır. ÖİDD, à trous algoritması yöntemi ile uygulanırsa ADD gibi filtre bankalarını kullanır, ancak katsayıların uzunluğu ana sinyal ile aynıdır [67]. Detay ve yaklaşım katsayıları, ÖİDD yönteminde "à trous" algoritması tarafından ÇÇA kullanılarak yukarı örneklenir [125]. ÖİDD, sinyaldeki gürültü ve salınımları azaltabilir. Ayrıca ÖİDD'de eşik değerleri seçmek ADD'ye göre daha kolaydır [97]. ÖİDD detay ve yaklaşım katsayıları şu şekilde ifade edilebilir:

$$c_j^U[k] = (h_0^{(j)} * c_{j-1}^U[k]) = \sum_n c_{j-1}^U[k + 2^j n] h_0(k); \quad (3.11)$$

$$w_j^U[k] = (h_0^{(j)} * c_{j-1}^U[k]) = \sum_n c_{j-1}^U[k + 2^j n] h_1(k)$$

Denklem 3.11'de, h_0 düşük geçiren ve h_1 yüksek geçiren filtrelerdir. Ayrıca, $w^U = \{w_1^U \dots w_j^U \text{ and } c_j^U\}$, j ölçeğindeki ÖİDD katsayılarıdır.

3.1.3.2 Piramidal algoritma ile ÖİDD ayrıştırması

ÖİDD yöntemi zaman kaymasından bağımsızdır. $X = [X_0, X_1, \dots, X_{n-1}]$ bir sinyalin zaman serisi olmak üzere, tek seviyeli ÖİDD filtreleme ($j = 1$) sonucunda elde edilen katsayılar aşağıdaki gibi hesaplanır:

$$\tilde{W}_{1,t} = \sum_{k=0}^{K-1} \tilde{h}_k X_{t-k \bmod n} \quad (3.12)$$

$$\tilde{V}_{1,t} = \sum_{k=0}^{K-1} \tilde{g}_k X_{t-k \bmod n}, \quad t = 0, 1, 2, \dots, n-1$$

Denklem 3.12'de $\tilde{W}_j = \{\tilde{W}_1, \tilde{W}_2, \dots, \tilde{W}_j\}$ ÖİDD dalgacık katsayıları vektörüdür ve X değeri 2^{j-1} ölçeğinde değişir. $\tilde{V}_j = \{\tilde{V}_1, \tilde{V}_2, \dots, \tilde{V}_j\}$ ise ÖİDD ölçekleme katsayıları vektörüdür ve $2^j, j = 1, 2, \dots, J$ ölçeğindeki varyasyonlarla ilişkilidir. Dalgacık filtresi ve ölçekleme filtresi sırasıyla h_k ve g_k olarak tanımlanır. h_k birim enerjiye sahiptir, toplamı sıfır olmalıdır ve ortogonal olmalıdır. g_k ise şu özellikleri karşılamalıdır [128]:

$$g_k = (-1)^{k+1} h_{K-1-k} \quad (3.13)$$

$$\sum_{k=0}^{K-1} g_k = \sqrt{2} \quad (3.14)$$

$$\sum_{k=0}^{K-1} g_k^2 = 1 \quad (3.15)$$

$$\sum_{k=0}^{K-1} g_k g_{k+2n} = \sum_{n=-\infty}^{+\infty} h_k h_{k+2n} = 0 \quad (3.16)$$

g_k ve h_k filtreleri, Denklem 3.12'deki \tilde{g}_k ve \tilde{h}_k elde etmek için yeniden ölçeklendirilir:

$$\tilde{h}_k = h_k / \sqrt{2} \quad (3.17)$$

$$\tilde{g}_k = g_k / \sqrt{2} \quad (3.18)$$

Şimdiye kadar tek seviyeli ($j = 1$) ayrıştırma için ÖİDD katsayıları hesaplanmıştır. j . seviyedeki katsayılar aşağıdaki gibi tanımlanır:

$$\tilde{W}_{j,t} = \sum_{k=0}^{K_j-1} \tilde{h}_{j,k} X_{t-k \bmod n} \quad (3.19)$$

$$\tilde{V}_{j,t} = \sum_{k=0}^{K_j-1} \tilde{g}_{j,k} X_{t-k \bmod n}, t = 0, 1, \dots, n-1, K_j \equiv (2^{j-1})(K-1) + 1$$

Denklem 3.19’da, $\{\tilde{h}_{j,k}: k = 0, \dots, K_j - 1\}$, ÖİDD dalgacık filtresi ve $\{\tilde{g}_{j,k}: k = 0, \dots, K_j - 1\}$, ÖİDD ölçekleme filtresidir. Bu filtreler, $K_j \equiv (2^{j-1})(K - 1) + 1$ genişliğinin K değerlerinin dalgacık $\{h_{j,k}\}$ ve ölçekleme $\{g_{j,k}\}$ filtrelerinden $\tilde{h}_{j,k} \equiv h_{j,k}/2^{j/2}$ ve $\tilde{g}_{j,k} \equiv g_{j,k}/2^{j/2}$ ile tanımlanır.

ÖİDD filtreleri, her K değeri arasına 2^{j-1} sıfır eklenerek her ayrıştırma ölçeğinde değiştirilir. Bu, ADD’de karşımıza çıkan aşağı örnekleme sürecini ortadan kaldırır. ÖİDD ayrıştırması, $j - 1$ seviyesinin ölçekleme katsayısına (\tilde{V}_{j-1}) dayanan piramidal algoritma adı verilen verimli bir algoritma kullanılarak gerçekleştirilebilir [66]. Bu yöntemde ÖİDD filtreleri, her ayrıştırma aşamasında K_j genişliğine göre yukarı örneklenir. Piramidal algoritmadan yararlanarak ÖİDD katsayılarını Denklem 3.20’deki gibi hesaplanabilir:

$$\tilde{W}_{j,t} = \sum_{k=0}^{K-1} \tilde{h}_k \tilde{V}_{j-1,t-2^{j-1}k \bmod N} \quad (3.20)$$

$$\tilde{V}_{j,t} = \sum_{k=0}^{K-1} \tilde{g}_k \tilde{V}_{j-1,t-2^{j-1}k \bmod N}, \quad t = 0, 1, 2, \dots, N - 1$$

3.2 Sınıflandırıcılar

Sınıflandırma süreci, güç kalitesi olaylarını farklı kategorilere ayırmak için kullanılan bir dizi algoritma ve tekniklerin uygulanmasıyla gerçekleştirilir. Bu bölümde sırasıyla, kNN, DVM, KA, RO ve GAKA yapılarının matematiksel alt yapısı verilecektir. Bu sınıflandırıcılar, farklı özellikleri kullanarak güç kalitesi olaylarını sınıflandırmak için öğrenme modelleri oluşturur. Sınıflandırıcıların doğruluğu, kullanılan özneliklerin seçimi, veri örnekleme, veri boyutu ve sınıf dengesizliği gibi faktörlere bağlı olarak değişebilir.

3.2.1 k-en yakın komşu (kNN) algoritması

kNN yöntemi, yeni bir veri örneğinin hangi sınıfa ait olduğunu belirlemek için örnekleme veri setindeki k en yakın örneği bulur ve bu örneklerin çoğunluğuna dayanarak sınıflandırma yapar. Bir aday örnek başka bir örneğin komşusuysa, bu aday aynı sınıfta olabilir. k parametresi sonucu önemli ölçüde etkiler. k parametresi daha

küçük seçilirse, öğrenme performansı artabilir ancak aşırı uyum riski olabilir. Aksi takdirde k parametresi büyük seçilirse öğrenme performansı düşebilir. Ayrıca parametre seçimi eğitim süresini de etkiler. En yakın komşu mesafesi farklı metriklerle hesaplanabilmektedir: Uzaklık (benzerlik) ölçüsü, Euclidean uzaklığı, Manhattan uzaklığı ve Minkowski uzaklığı.

kNN algoritmasının işlem adımlarını aşağıdaki gibi sıralanabilir [129]:

- Test örneği ve örneklem veri seti verilir.
- Uzaklık hesaplama yöntemi belirlenir.
- Test örneği ile örneklem veri setindeki her örnek arasındaki uzaklık (benzerlik) hesaplanır.
- Elde edilen uzaklıklar küçükten büyüğe sıralanır.
- En yakın k komşu seçilir.
- Komşuların sınıf etiketleri dikkate alınarak test örneğinin sınıfı tahmin edilir.
- Tahmin edilen sınıf etiketi sonuç olarak rapor edilir.

Bu çalışmada, Euclidean uzaklık metriği kullanılmıştır. N boyutlu bir uzayda, bu mesafe, iki nokta dikkate alındığında $P1 = (x1, x2, x3, \dots, xN)$ ve $P2 = (y1, y2, y3, \dots, yN)$ için Denklem 3.21'deki gibi hesaplanır.

$$d(p1, p2) = \sqrt{(x1 - y1)^2 + (x2 - y2)^2 + \dots + (xN - yN)^2} \quad (3.21)$$

3.2.2 Destek vektör makinesi (DVM)

DVM yöntemi, n -boyutlu özellik uzayının sınıflarında bir ayırma hiperdüzlemi bulmayı amaçlar. Hiperdüzlemler, az sayıda destek vektörü ile elde edilebilir. Bu sayede veri sayısı az olan eğitim setlerinde başarılı sonuçlar alınabilir. En iyi hiperdüzlem, sınıf üyelerine en uzak olan belirlenerek elde edilir. Doğrusal problemlerin çözümünde oldukça başarılı sonuçlar elde eden DVM, doğrusal olmayan problem çözümlerinde çekirdek (kernel) fonksiyonları üzerinden doğrusal olmayan haritalama yaparak verileri yeni bir boyuta taşımaktadır. Sınıflandırma, yeni uzayda optimum ayırma hiper düzlemi belirlenerek gerçekleştirilir. Çalışmada, Scikit ML kütüphanesindeki SVC fonksiyonundan yararlanılmıştır. SVC fonksiyonu (sınıflandırıcı), birçok hiperparametreye sahiptir. Bu parametreler arasında, çekirdek

fonksiyonu tipi, çekirdek işlevi parametreleri, C parametresi ve karar fonksiyonu bulunur. Bu parametreler, modelin performansını etkiler ve optimal parametre değerlerinin bulunması modelin doğruluğunu artırabilir. Verilen eğitim vektörleri $x_i \in R^p, i = 1, 2, \dots, n$ olmak üzere $y \in \{1, -1\}^n$ vektörü SVC fonksiyonu $y \in \{1, -1\}^n$ verilen ana problemin Denklem 3.22'deki şekilde çözülmesini sağlar [130].

$$\min_{w,b,\zeta} \frac{1}{2} w^T w + C \sum_{i=1}^n \zeta_i \quad (A2) \quad (3.22)$$

$$\text{subject to } y_i(w^T \phi(x_i) + b) \geq 1 - \zeta_i, \quad \zeta_i \geq 0, \quad i = 1, 2, \dots, n$$

İkili formu ise Denklem 3.23'teki gibi ifade edilebilir.

$$\min_{\alpha} \frac{1}{2} \alpha^T Q \alpha - e^T \quad (3.23)$$

$$\text{subject to } y^T \alpha = 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, n$$

Denklem 3.23'te e tüm birlerin vektörüdür, Q pozitif yarı tanımlı bir matristir. Çekirdek fonksiyonu kullanıldığında, Q matrisi $Q_{ij} \equiv y_i y_j K(x_i, x_j)$ olarak tanımlanabilir. Burada çekirdek fonksiyonu $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ ile gösterilmektedir. Eğitim vektörleri için, ϕ fonksiyonu daha yüksek (belki sonsuz) boyutlu bir uzaya eşleme sağlar. Karar fonksiyonu şu şekilde ifade edilebilir:

$$\text{sgn} \left(\sum_{i=1}^n y_i \alpha_i K(x_i, x) + \rho \right) \quad (3.24)$$

3.2.3 Karar ağaçları (KA)

KA yöntemi, sınıflandırma için bir dizi kural kullanır. Kural modeli, karar vermeye yardımcı olan bir ağaç gibidir. Bu yöntem üç aşama ile özetlenebilir [131]: 1) Öznitelik seçimi, 2) Ağaç üretimi, 3) Eleminasyon. Eleme aşaması, alakasız ve gereksiz özellikleri otomatik olarak hariç tutabilir. Verilen eğitim vektörleri $x_i \in R^n, i = 1, 2, \dots, l$ ve bir etiket vektörü $y \in R^l$ için KA, uzayı bölümleyerek aynı sınıfları gruplandırır. Burada, m düğümündeki veriler Q ile ifade ediliyorsa, karar ağacı verileri

$Q_{left}(\theta(j, t_m))$ ve $Q_{right}(\theta)$, $\theta = (j, t_m)$ olarak iki alt kümeye ayırır; burada j bir özelliktir ve t_m Denklem 3.25 ve Denklem 3.26'ya göre verilen eşik değeridir.

$$Q_{left}(\theta) = (x, y) | x_j \leq t_m \quad (3.25)$$

$$Q_{right}(\theta) = Q \setminus Q_{left}(\theta) \quad (3.26)$$

Safsızlık (Impurity) fonksiyonu H , m düğümündeki safsızlığı hesaplar ve Denklem 3.27 ve Denklem 3.28 ile minimize edilmiş safsızlık parametre seçimi uygulanır. Bu çalışmada Gini (H) safsızlık kriteri kullanılmıştır.

$$G(Q, \theta) = \frac{n_{left}}{N_m} H(Q_{left}(\theta)) + \frac{n_{right}}{N_m} H(Q_{right}(\theta)) \quad (3.27)$$

$$\theta^* = \underset{\theta}{\operatorname{argmin}} G(Q, \theta) \quad (3.28)$$

En büyük izin verilen derinliğe $Q_{left}(\theta^*)$ ve $Q_{right}(\theta^*)$ alt kümelerine ulaşıncaya kadar, $N_m < \min_{\text{samples}}$ veya $N_m = 1$ koşullarından herhangi biri sağlandığında durulur.

3.2.4 Rastgele orman (RO) algoritması

RO algoritması, birbirinden bağımsız birçok karar ağacının oluşturulması ve bu ağaçların sonuçlarının bir araya getirilmesiyle oluşan bir toplu öğrenme (ensemble learning) algoritmasıdır. RO algoritması, veri kümesi içindeki özellikleri rastgele alt kümelerine ayırarak ve bu alt kümelerdeki özellikler üzerinde karar ağaçları oluşturarak çalışır. Her bir ağacın oluşturulması sırasında, veri kümesindeki örneklerin bir kısmı rastgele seçilir ve ağacın büyümesi bu örnekler üzerinde gerçekleştirilir. Test verisi sınıflandırıldığında, her ağaç için ayrı ayrı bir tahmin yapılır ve sonuçlar birleştirilerek nihai sınıflandırma sonucu elde edilir. Bu sayede, tek bir ağaçta oluşabilecek hataların ortalaması alınarak genel bir doğruluk artırılır ve aynı zamanda aşırı öğrenme riski de azaltılmış olur. RO sınıflandırıcısı teorisi, KA'ya dayanmaktadır ve sınıflandırıcı denklemleri, Denklem 3.29 ile verilmiştir [132].

$$\{f(x, \delta_k), k = 1, 2, \dots\} \quad (3.29)$$

burada x giriş vektörüdür, $f(x, \delta_k)$ bir ağaç yapı sınıflandırıcısıdır ve δ_k , k tek bir karar ağacının büyümesini belirleyen rastgele vektörlerdir.

3.2.5 Gradyan artırıcı karar ağaçları (GAKA) algoritması

GAKA, RO gibi bir tür topluluk karar ağacı yöntemidir. GAKA yönteminde ana fikir, zayıf bir öğrenimi daha güçlü hale getirmek için değiştirmektir. Bu yöntem, seri şekilde karar ağaçları ekleyerek bir model oluşturur ve ağaçlar arasındaki hatayı minimuma indirmek için çalışır. Her ağaç, önceki ağaçların kalan hatasını tahmin etmeye çalışarak eğitilir. Bu sayede, son ağaç, tüm ağaçların tahminlerinin toplamına eklenerek elde edilen hatayı minimize eder. İşlem sonunda GAKA tüm KA tahminlerini toplayarak sonucu verir. RO algoritmasındaki gibi oylama yapılmamakta olup GAKA, Denklem 3.30'da $h_m(x)$ ile tanımlanan zayıf öğreniciler olarak sabit boyuttaki karar ağaçlarını kullanır [133].

$$F(x) = \sum_{m=1}^M \gamma_m h_m(x) \quad (3.30)$$

GAKA, h_m 'in eklenen ağaç olduğu, L 'nin kayıp fonksiyonunu ifade ettiği ve (F_{m-1}) 'in önceki ağaç topluluğu olduğu durumda kaybı en aza indirmek için fonksiyonel gradyan iniş prosedürünü içeren bir toplama modeli kullanır. Denklem 3.31 ve Denklem 3.32 'de $F_m(x)$ ve h_m için bu formülasyonlar verilmiştir [133].

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x) \quad (3.31)$$

$$h_m = \arg \min_h \sum_{i=1}^n L(y_i, F_{m-1}(x_i) + h(x_i)) \quad (3.32)$$

GAKA, ilk model F_0 minimizasyon problemini çözmek için kayıp fonksiyonunun negatif gradyanı olan yönde en dik iniş algoritmasını kullanır. Yeni ek model, Denklem 3.33 ile hesaplanabilir ve adım uzunluğu γ_m , satır arama (line search) ile seçilen Denklem 3.34 ile bulunur. Bu çalışmada, sınıflandırma için multinomial sapma kaybı fonksiyonu kullanılmıştır.

$$F_m(x) = F_{m-1}(x) - \gamma_m \sum_{i=1}^n \nabla_F L(y_i, F_{m-1}(x_i)) \quad (3.33)$$

$$\gamma_m = \arg \min_{\gamma} \sum_{i=1}^n L \left(y_i, F_{m-1}(x_i) - \gamma \frac{\partial L(y_i, F_{m-1}(x_i))}{\partial F_{m-1}(x_i)} \right) \quad (3.34)$$

GAKA, aynı zamanda birden fazla karar ağacı kullanır, ancak her ağaç, önceki ağacın tahmin hatalarını düzeltmek için eğitilir. GAKA, RO'dan farklı olarak, bir sonraki ağacın, önceki ağaçların yaptığı hataları azaltma eğiliminde olduğu bir öğrenme işlemi gerçekleştirir. Bu sayede, RO'dan daha az ağaç kullanmasına rağmen daha yüksek doğruluk sağlanabilir. RO ise, aşırı uydurmayı azaltmak için rastgele örnekler ve özellikler kullanır ve sonuçları bir araya getirerek tahminlerde bulunur. Bu özelliği ile yüksek boyutlu verilerle çalışırken ve özellik sayısı çok fazla olduğunda oldukça etkili bir sınıflandırma yöntemi haline gelir. Sonuçta, her iki algoritma da farklı veri setleri için farklı sonuçlar verebilir ve hangi algoritmanın kullanılacağı, veri setine ve amaca bağlıdır.

3.3 Derin Öğrenme Yaklaşımı

Derin öğrenme teknikleri, özellik çıkarımını otomatikleştirme yeteneğine sahiptir ve insan müdahalesine ihtiyaç duymadan çalışabilirler. Bu yaklaşımda kullanılan modeller, sinyal analizi adımına ihtiyaç duymadan otomatik olarak optimal özellikleri çıkarabilirler. Geleneksel YSA yapılarından farklı olarak, DÖ algoritmaları çok katmanlı yapılar kullanarak karmaşık verilerde özelliklerin çıkarılmasını sağlarlar. Sonuçta, GKO ve AMOD tespiti/sınıflandırılması gibi zorlu problemlerde derin öğrenme kullanılması, prosedürleri kolaylaştırabilir, doğruluğu artırabilir ve insana ihtiyacı azaltabilir.

Geleneksel makine öğrenmesi algoritmalarıyla derin ağ mimarileri arasındaki farklar şunlardır [134]:

- DÖ algoritmaları, makine öğrenmesi-Tabanlı geleneksel sınıflandırıcılara göre daha fazla veri gerektirirler.
- Geleneksel olay sınıflandırma yöntemleri sinyal analizi, öznitelik çıkarımı ve öznitelik seçimi gibi aşamalar barındırır. DÖ yaklaşımı ile bu süreç otomatik olarak işler.
- DÖ algoritmaları, verilerin eğitilmesi sırasında yeni özelliklerin ortaya çıkmasını sağlarlar; ancak makine öğrenmesi-Tabanlı sınıflandırıcılar, özellikleri doğru bir şekilde tanımlamak için kullanıcıya ihtiyaç duyarlar.
- Klasik makine öğrenmesi yöntemleri, problemleri küçük parçalara ayırır ve sonuçları tek bir sonuçta birleştirirler. DÖ'de ise adım adım problem çözümüne

yaklaşır ve her adımda daha yüksek bir doğruluk elde edilir. Ayrıca, DÖ algoritmalarının daha yüksek doğruluk oranlarına ve daha fazla sınıfta veriyi sınıflandırma özelliğine sahip olmalarının nedeni, daha fazla matematiksel işlemin kullanılmasıdır.

- DÖ teknikleri, kapalı döngü geri besleme mekanizmasına sahiptirler. Bu mekanizma sayesinde, eğitim verilerini sürekli olarak işleyebilir ve sonuçları geri bildirimlerle iyileştirebilirler. Sonuç olarak, makine öğrenmesi yöntemlerinde olduğu gibi, ayrı bir geri bildirim aşamasına ihtiyaç duyulmamasını sağlar.

DÖ mimarileri, kullanılan eğitim algoritmalarına göre altı farklı grupta incelenebilir: Derin sinir ağları, ESA, Derin inanç ağı, YÖK ve UKSB, Çekişmeli Üretici Ağlar [135]. Tez çalışmasında ESA, UKSB ve hibrit model (ESA-UKSB) üzerinde durulmuş olup bu modellerin teorisi aktarılmıştır.

3.3.1 Evrimsel sinir ağları (ESA)

İlk olarak 1980 yılında Fukushima tarafından önerilen ESA modeli, eğitim prosedürlerindeki zorluklar ve yüksek donanım maliyetleri nedeniyle yaygın olarak kullanılmamıştır [136]. İlerleyen yıllarda ESA mimarilerindeki gelişmeler ve artan teknolojik yeterlilikler nedeniyle çeşitli uygulamalarda kullanılmaya başlanmıştır [137]. Tez çalışmasında, ESA ağlarının dinamik yapısı ve derinlik kavramı vurgulanarak yaşanan gelişmeler ışığında bundan sonraki süreçte derin evrimsel sinir ağları (DESA) olarak adlandırılması tercih edilmiştir. DESA mimarileri, evrim katmanları, havuzlama (pooling) katmanları ve tam bağlantılı (fully connected) katman yapılarının kademeli bir şekilde birleştirilmesiyle oluşur. Bunların yanı sıra, aşırı öğrenmeyi önlemek için sıklıkla düğüm seyreltme (dropout) ve yığın normalleştirme kullanılır.

Giriş katmanında kullanılacak veri ham veri olarak ilgili ağa verilir. Verinin boyutu doğrudan ağın doğruluğunu etkiler. Veri kapasitesi arttıkça daha yüksek bellek ve eğitim süresine ihtiyaç duyulur. Girdi verilerindeki dönüşüm filtrelerle sağlanır. Aktivasyon fonksiyonu ile evrim katmanındaki lineer yapı, lineer olmayan bir yapıya dönüştürülerek etkinleştirilir. Aktivasyon fonksiyonundan sonra havuzlama katmanı kullanılır ve girdi boyutu bir sonraki evrim katmanı için azaltılır. Bu şekilde veri hafızası azaltılır ve hesaplama maliyeti düşürülür. Tam bağlantılı katman ise bu katmanlardan önceki evrim katmanlarının tüm bölgelerine bağlıdır. Düğüm

seyreltme katmanı ise bazı durumlarda aşırı öğrenmeyi önlemek için bu mimarilerde kullanılabilir. Son olarak, sınıflandırma çıktı katmanında yapılı ve genellikle başarısı nedeniyle eşiksiz en büyük işlevi (softmax) aktivasyon fonksiyonu tercih edilir. Ağın sınıflandırma tipine göre belirli bir çıktı üretir.

19 farklı sınıf içeren (Nominal sinyal, 8 adet tekli olay, 10 adet kompleks olay) GKO olaylarını sınıflandırmak için önerilen DESA model yapısı, Şekil 3.2'de gösterilmiştir. Bu modelde, veri seti girişleri doğrudan giriş katmanından ağa dahi olur. Girdi veri boyutu, sınıflandırma sonucunu, donanımınızın bellek kullanımını, eğitim ve test süresini ve ağ performansını doğrudan etkilediğinden, veri girişi seçimi çok önemlidir. Evrişim katmanı, görüntüler üzerinde evrişim işlemlerinin yapıldığı katmandır. Evrişim işleminde giriş katmanından elde edilen büyük veri matrisi üzerinde soldan sağa ve yukarıdan aşağıya adım adım kaydırılarak $2 \times 2, 3 \times 3, 5 \times 5$ gibi filtre katsayı matrislerinin çarpılmasıyla aktivasyon haritası veya öznitelik haritası elde edilir. Aktivasyon katmanı, doğrusallaştırılmış ağı, evrişim katmanlarının girdilerini etkilemeden doğrusal olmayan bir yapıya dönüştürmek için kullanılan katmandır. Genel olarak GKO sınıflandırmasında ReLU (rectified linear unit) tercih edilirse ağ eğitiminin en hızlı sonucu verdiği görülmektedir. Tanh, Scaled Exponential Linear Units, softsign, Leaky ReLU, softtanh, Randomized Leaky ReLU, hardtanh, Parameterized ReLU, softmax, softplus gibi diğer fonksiyonlar da tercih edilebilir. ReLU aktivasyon fonksiyonu Denklem 3.35'te gösterilmiştir.

$$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases} \quad (3.35)$$

Havuzlama katmanı, evrişim katmanlarının aktivasyon haritalarına doğrusal olmayan aşağı örnekleme yönteminin uygulandığı katmandır. Derinlik ölçüsüne müdahale edilmeden genişlik ve yüksekliğin azaltılması hedeflenmiştir. Eğer giriş görüntüsü genişliği (W_i), giriş görüntüsü yüksekliği (H_i), giriş görüntüsü derinliği (D_i), alt örnekleme yöntemi filtre boyutu (K), kaydırma penceresi adım boyutu (S), şeklinde tanımlarsak, giriş görüntüsü boyut parametreleri ile çıktı görüntüsü mekânsal boyutu (Y) arasındaki ilişki şu şekilde ifade edilebilir:

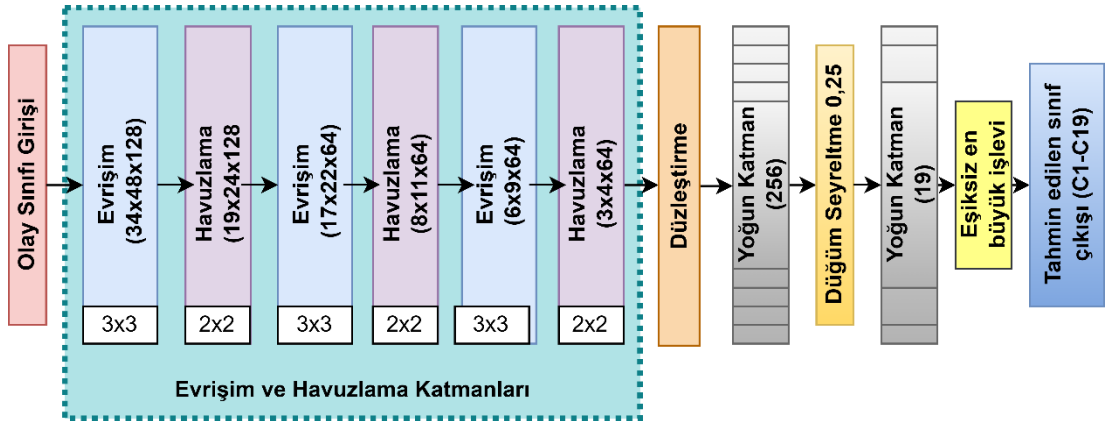
$$Y = [(W_i - K)/S + 1] \times [(H_i - K)/S + 1] \times D_i \quad (3.36)$$

Ayrıca, fazla uydurma sorunlarını önlemek için katmanlar arasında bir veya birkaç kez kullanılabilen bir seyreltme katmanı da vardır. Son olarak, sınıflandırma için bir aktivasyon fonksiyonu içeren geleneksel bir sinir ağı katmanı vardır. Tam bağlı olan bu katman önceki katmanlardan çıkarılan özellikleri kullanır. Bunun sonucunda DESA modellerinin kendi içerisinde özellik çıkarımı içerdiğini söylemek mümkündür. Son katmanda ise eşiksiz en büyük işlevi katmanı bulunmaktadır.

Bir eşiksiz en büyük işlevi katmanı, eşiksiz en büyük işlevi aktivasyon fonksiyonuna sahip bir tam bağlı katmandır. Eşiksiz en büyük işlevi girdi örneğinin olasılığı anlamına gelir. Yani en yüksek olasılığa sahip sınıf çıktı olarak belirlenecektir. Bu fonksiyonda, tam bağlı katmandan gelen verilerin çıkış sınıflarına yakınsaması olasılık hesaplama yöntemi ile belirlenir. GKO sınıflandırma sistemlerinde, N olası olaydan bir sınıf tahmin edilmeye çalışılır. Model, her sınıf için sıfır ile bir arasındaki olasılık puanlarını temsil eden N boyutlu bir vektör hesaplar. Fonksiyonunun matematiksel tanımı Denklem 3.37'de verilmiştir.

$$P(y = j | x) = \frac{e^{x^T w_j}}{\sum_{k=1}^K e^{x^T w_k}} \quad (3.37)$$

burada, x giriş vektörünü temsil eder ve w ağırlık matrisidir.



Şekil 3.2 : Önerilen DESA Modeli.

DESA modelindeki katman sayısı, katman sırası ve parametre seçimi, model tasarımcısına göre değişiklik gösterebilir. DESA modelleri için veriler ağ katmanlarından geçirilir ve ağırlıklar güncellenerek bir sonraki katmana aktarılır. Genel hata değeri, hedeflenen sonuç ile DESA yanıtı arasındaki farktır. Elde edilen hatayı ağdaki tüm ağırlıklara dağıtmak için bir geri yayılım tekniği kullanılır. Her

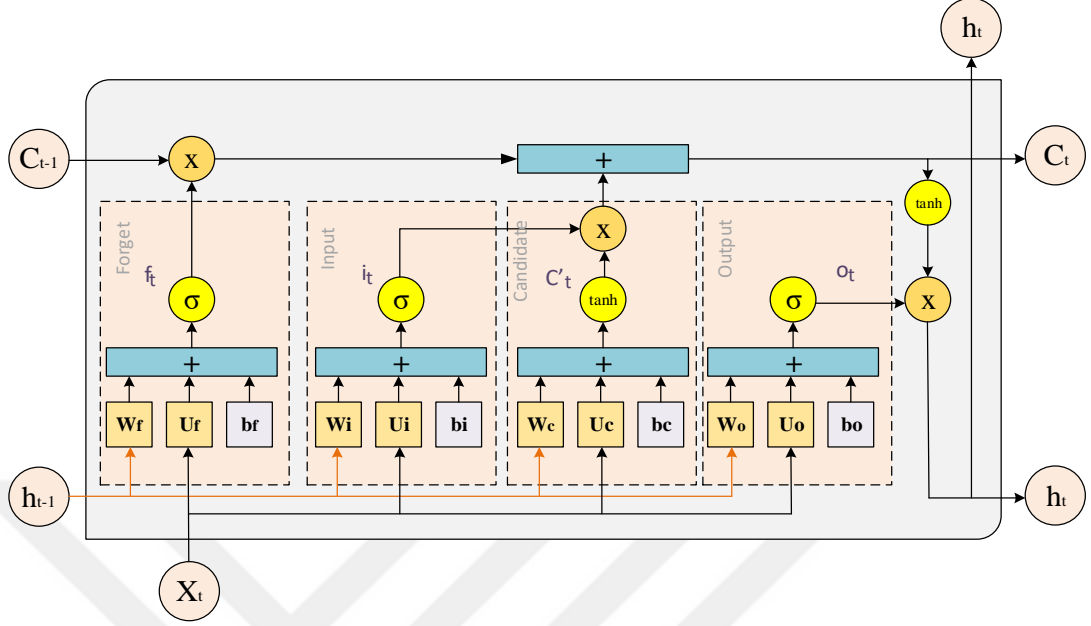
ağırlığın toplam hata üzerindeki etkisi, stokastik inişe dayalı optimizasyon yaklaşımları kullanılarak belirlenir. En iyi ağ performansını elde etmek için her yineleme genel hatayı azaltmayı amaçlar. Bu çalışmada DESA yapılarındaki sıralama katmanları, çekirdek boyutları, aktivasyon fonksiyonları ve optimize edici fonksiyonları, filtre boyutları gibi çeşitli parametreler değiştirilerek çeşitli modeller oluşturulmuştur. Şekil 3.2’de önerilen DESA modeli için en yüksek doğruluğu sağlayan parametreleri göstermektedir. ReLU, DESA algoritmasında aktivasyon fonksiyonu olarak bulunmaktadır. Tam bağlı katmanlarda sigmoid aktivasyon fonksiyonu kullanılmıştır. Bu modelde, düğüm seyreltme ve toplu normelleştirme, girdileri standart hale getirmek ve fazla uydurmayı önlemek için kullanılmıştır.

3.3.2 Uzun kısa süreli bellek (UKSB)

Tekrarlayan sinir ağları, YSA türlerinden biridir ve yönlü döngülerden oluşan birkaç birimin birbirine bağlanması sonucu oluşur. Ağın yapısı, giriş seviyesi sinir ağı planının önceki verileri kullanarak bir sonraki verileri tahmin etme potansiyeline sahiptir. Bellek hücreleri ve kapılardan oluşan UKSB, kaybolan gradyan problemine çözüm olarak ve karmaşık zaman serilerinin üstesinden gelmek için üretilmiştir.

Şekil 3.3’te gösterilen UKSB birimi, üç ana kapıya sahiptir: giriş kapısı (input gate), çıkış kapısı (output gate) ve unutma kapısı (forget gate) [138]. Giriş kapısı, yeni bilgi girişini yönetir ve hafıza birimine ne kadar ekleneceğini kontrol eder. Unutma kapısı, gereksiz bilgileri silmek için hafıza biriminden ne kadar veri silineceğini belirler. Aday katman, hafızaya ve bilginin güncellenmesine yardımcı olmak için bir sonraki hafıza durumu için aday bilgileri oluşturur. Bu aday bilgileri, önceki hafıza durumundan gelen bilgilerle birleştirilir ve ardından filtrelenir, böylece sadece önemli bilgiler saklanır. Çıkış kapısı, hafıza biriminden çıkışı kontrol eder. UKSB mimarisinde, aday katman (candidate layer), giriş kapısı ve unutma kapısı tarafından oluşturulan vektörün işlendiği katmandır. Ayrıca, girdilerin daha önceki zaman adımlarında kullanılmak üzere hatırlanmasını sağlamak için hücre durumu (cell state) olarak adlandırılan bir bellek birimi kullanır. UKSB birimleri ayrıca, katmanların ardışık sırasında birbirlerine bağlanabilmesi için dışarıya bir çıkış ve bir de gizli durum vektörü sağlar. Bu gizli durum vektörü, modelin öğrenilen özelliklerini içerir ve daha sonra başka katmanlarla paylaşılabilir. Genel olarak, UKSB birimi, veri dizilerini daha iyi

modellemesine izin vererek, bilgileri zaman içinde seçici olarak tutmak veya atmak için tasarlanmıştır.



Şekil 3.3 : UKSB birim yapısı.

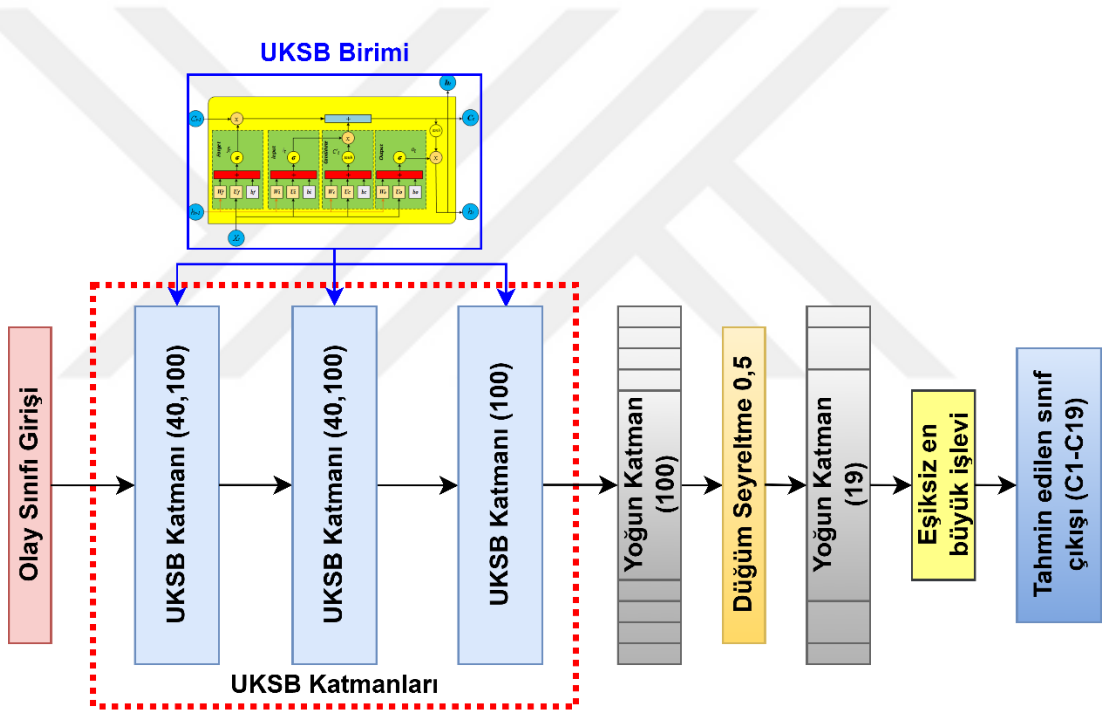
UKSB birimlerinde, temel olarak zaman adımı (t) için bir unutmaya kapısı (f_t), bir giriş kapısı (i_t), bir aday katman ve bir çıkış kapısı (O_t) blokları bulunur. Şekil 3.3'te gösterildiği gibi bu bloklar, hücrelerin sigmoid (σ) ve hiperbolik tanjant (\tanh) aktivasyon fonksiyonları ile veri depolamasına ve erişimine uzun bir süre izin verir. Gizli durum (hidden state- (h_{t-1})), önceki hücre durumu (c_{t-1}), giriş (x_t), unutmaya kapısı ağırlık matrisleri (W_f), giriş kapısı ağırlık matrisleri (W_i), aday katman ağırlık matrisleri (W_c), çıkış kapısı ağırlık matrisleri (W_o), unutmaya kapısı tekrarlayan ağırlık matrisleri (U_f), giriş kapısı tekrarlayan ağırlık matrisleri (U_c), aday katman tekrarlayan ağırlık matrisleri (U_f), çıkış kapısı tekrarlayan ağırlık matrisleri (U_o), unutmaya kapısı bias'ı (b_f), giriş kapısı ek girdisi (bias- (b_i)), aday katman ek girdisi (b_c) ve çıkış kapısı ek girdisi (b_o) kullanılarak, mevcut gizli durum (h_t) ve mevcut hücre durumu (c_t) Denklem 3.38'deki şekilde hesaplanabilir [139]:

$$\begin{aligned}
 i_t &= \text{sigm}(W_i x_t + U_i h_{t-1} + b_i) \\
 f_t &= \text{sigm}(W_f x_t + U_f h_{t-1} + b_f) \\
 o_t &= \text{sigm}(W_o x_t + U_o h_{t-1} + b_o) \\
 \tilde{c}_t &= \text{tanh}(W_c x_t + U_c h_{t-1} + b_c)
 \end{aligned} \tag{3.38}$$

$$c_t = i_t \odot \tilde{c}_t + f_t \odot c_{t-1}$$

$$h_t = o_t \odot \tanh(c_t)$$

Bu çalışmada, UKSB kullanılarak oluşturulan derin sinir ağı DUKSB olarak isimlendirilmiştir. Şekil 3.4'te, 19 farklı sınıf içeren (Nominal sinyal, 8 adet tekli olay, 10 adet kompleks olay) GKO olaylarını sınıflandırmak için önerilen DUKSB modeli yapısı gösterilmiştir. Önerilen DUKSB algoritması için en yüksek doğruluğu sağlayan en uygun modelin oluşturulduğu durumdaki model parametreleri şekil üzerinde gösterilmektedir. DUKSB modeli belirlendikten sonra, bu modeli kullanarak optimal girdi parametrelerini ve daha hızlı bir olay sınıflandırması sağlanması için eğitim test oranlarını değiştirerek modelin doğruluğu üzerindeki etkileri araştırılmıştır.



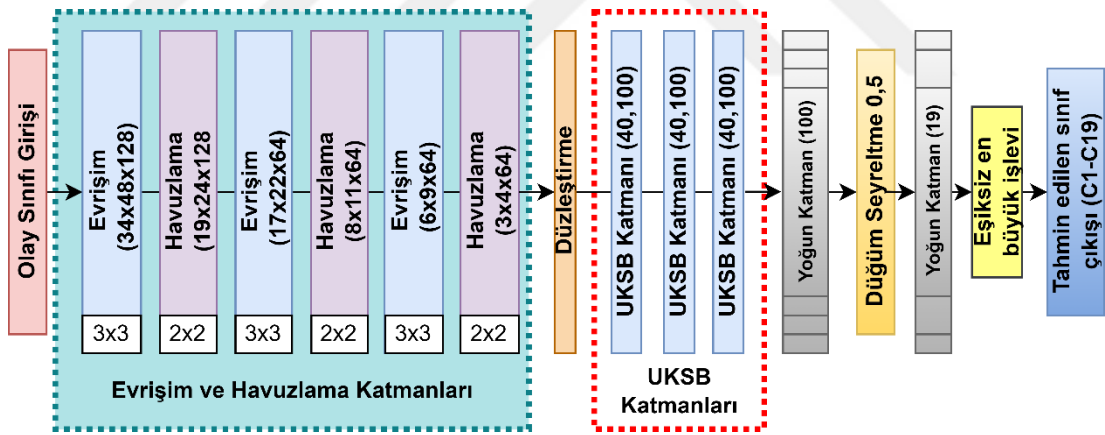
Şekil 3.4 : Önerilen DUKSB Modeli.

3.3.3 Hibrit yaklaşımlar (DESA-DUKSB)

GKO sınıflandırılmasında ESA ile UKSB'nin birlikte kullanılması birçok avantaj sağlayabilir. Örneğin, ESA veri özelliklerinin yerel yapısını tanımak için etkilidir ve bu nedenle, GKO sınıflandırması için veri özelliklerini öğrenmek ve öznelik çıkarmak için kullanılabilir. Bununla birlikte GKO zaman serisi verileri içerir. UKSB'ler ise, özellikle zaman serisi verileri işlemek için tasarlanmıştır ve uzun süreli bağımlılıkları ve zaman içindeki değişiklikleri modellemek için kullanılırlar. Bu iki

modelin birleştirildiğinde, ESA veri özellikleri çıkarmak için kullanılırken, UKSB'ler zaman içindeki değişimleri modellemek için kullanılır. Bu nedenle, DESA-DUKSB birleşimi, zaman içindeki değişiklikleri tanımlayabilen daha doğru bir sınıflandırma modeli sağlayabilir.

İki farklı derin sinir ağı mimarisi taşıyan modeller hibrit yöntemler olarak adlandırılır. Şekil 3.5'te gösterilen, 19 farklı sınıf GKO olayını sınıflandırmak için önerilen DESA-DUKSB hibrit modeli en başarılı doğruluk oranına sahiptir. Önerilen yöntemde, DESA modelinden elde edilen özellikler DUKSB modeli girdisi olarak kullanılmıştır. Modelin sonunda sınıflandırma için tamamen bağlı katmanlar ve eşiksiz en büyük işlevi bulunmaktadır. Geleneksel DESA veya DUKSB modelleri ile karşılaştırıldığında, önerilen bu hibrit model GKO gibi zaman serisi verileriyle birlikte yerleştirilmiş bozulmalara karşı daha dayanıklıdır. ESA'nın özellik çıkarımı uyarlanabilir olduğundan, önerilen hibrit model, geleneksel üç aşamalı süreçte insan katılımına dayanan özellik çıkarımına olan güvensizliğin üstesinden gelebilir. Bu modelde UKSB'lerin kullanılmasının motivasyonu, ESA ağından her özellik sırası arasındaki bağımlılıkları çıkarmaktır.



Şekil 3.5 : Önerilen hibrit model.

3.4 Bulanık Mantık Karar Verici (BKV)

BKV, birçok durumda kullanılan ve belirsizliği olan verilerin analizinde yararlı olan bir yapay zeka yaklaşımıdır. Temel prensip, verilerin kesin bir doğru ya da yanlış olduğu yerine, bir dereceye kadar doğru ya da yanlış olduğu gerçeğidir. BKV, bir veya daha fazla girdi değişkenine dayanır ve bu değişkenlerin bir veya daha fazla çıktı değişkenine nasıl etki ettiğini belirler. Bu etkiyi belirlemek için, belirli bir veri kümesi üzerinde eğitilir ve sonunda, girdiye bağlı olarak doğru bir çıktı üretebilir. Sonuçta

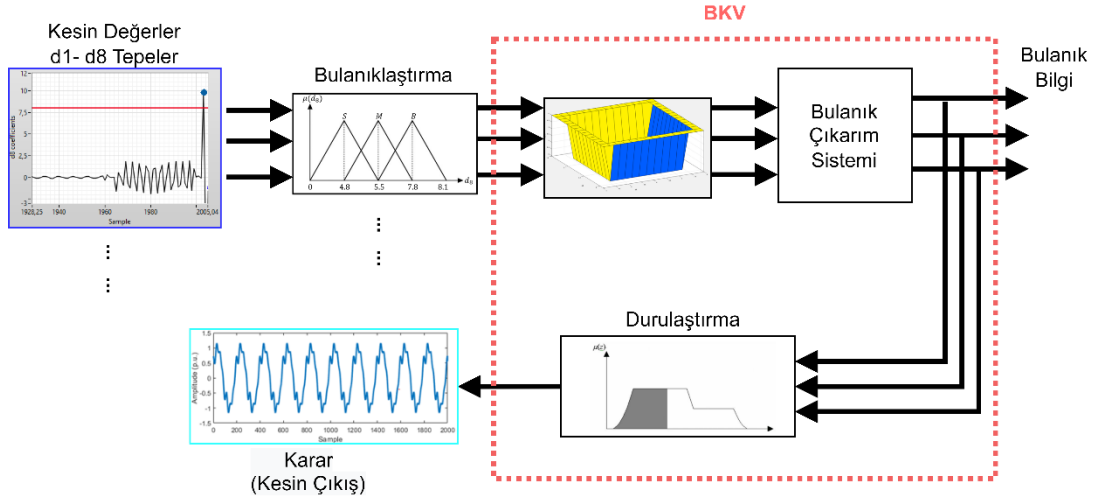
geleneksel yöntemlerde ABD'ye neden olan eşik değer belirleme problemi BKV ile giderilebilir.

Bu yaklaşımda iki farklı karar verici yapısı bulunmaktadır: BKV-Tip1 ve BKV-Tip2. BKV-Tip1, bulanık girdi verilerine bulanık kurallar uygulayarak bulanık çıktılar üreten basit yapıda karar vericilerdir. Burada bulanık kurallar, önceden belirlenmiş bulanık setlerin ve bu setler arasındaki ilişkilerin kullanımını içerir. BKV-Tip2 ise belirli bir bulanıklık derecesine sahip olan belirsizlikleri de dikkate alır. Bu tip karar vericiler, bulanık girdi verilerini hassas bir şekilde işlemek için, dinamik olarak değişen belirsizlik dereceleri kullanır. BKV-Tip2 daha karmaşık bir yapıya sahiptir.

BKV-Tip2 belirsizlik seviyesini daha iyi ele alabilen ve bu nedenle daha yüksek bir esneklik derecesi sunabilen bir yapıya sahiptir. Bu sistemler, daha geniş bir bilgi alanına dayanarak karar verebilirler. Özellikle GKO gibi yüksek boyutlu ve çoklu girdili sistemlerde faydalıdır. Ayrıca, BKV-Tip2 belirsizlikle başa çıkmanın yanı sıra, girdilerdeki gürültüyü de daha iyi ele alabilirler. Bununla birlikte, BKV-Tip2 sistemleri dezavantajlar da barındırır. Öncelikle daha karmaşıktır ve daha fazla hesaplama gücü gerektirir. Ayrıca, BKV-Tip2 performansı, bulanıklaştırma fonksiyonunun seçimine ve parametrelerinin ayarlanmasına bağlıdır. Bu nedenle, optimum parametrelerin belirlenmesi zorlu olabilir.

3.4.1 BKV-Tip1

BKV-Tip1, kararları vermek için kuralları sağlayan operatörün bilgisine dayalı olarak bazı eylemler gerçekleştirir. Şekil 3.6'da gösterildiği gibi bir BKV-Tip1 genellikle dört bölümden oluşur: bulanıklaştırma birimi, kural tabanı birimi, bulanık çıkarım sistemi ve durulaştırma birimi. Bulanıklaştırma birimi, kesin girdilerini bulanık sayılara dönüştürür. Böylece, kesin girdi verileri üçgen, Gauss vb. bulanık üyelik fonksiyonları ile temsil edilir. Daha sonra bulanık girdi ve önceden belirlenmiş kurallar, bulanık çıkarım sistemi aracılığıyla işlenir. Bulanık çıkarım sisteminin çıktısı olan bulanık bilgi elde edildikten sonra durulaştırma birimi kullanılarak kesin değerlere dönüştürülür.



Şekil 3.6 : BKV-Tıp1 blok diyagramı.

Bir üyelik fonksiyonu, 0 ile 1 arasında kesin veri olan bir üyelik değerini tanımlar. Üyelik fonksiyonları herhangi bir tipte olabilir, ancak en sık kullanılan üyelik fonksiyonlarının üçgen, yamuk, Gauss veya sigmoid fonksiyonlarıdır. Basitlik ve hesaplama verimliliği nedeniyle tez çalışmasında üçgen üyelik fonksiyonu tercih edilmiştir. Bulanık kurallar, tasarımcının deneyimi veya girdi ve çıktılarının gözlemlenmesi yoluyla oluşturulur. Bu çalışmada ise, daha önce elde edilen ÖİDD katsayıları ve bu katsayılarla karşılık GKO'lar gözlemlenmiş, daha sonra bunların işlenip analiz edilmesiyle kurallar oluşturulmuştur. Bulanık çıkarım birimleri genellikle Sugeno veya Mamdani yaklaşımlarıdır [140]. Tez çalışmasında, Mamdani yaklaşımı kullanılmıştır. BKV'nin durulaştırma biriminde bisektör durulaştırma yöntemi uygulanmıştır. Ancak ağırlık merkezi, maksimumun ortalaması, maksimumun küçüğü vb. gibi başka yöntemler de vardır [141]. Bu çalışmada önerilen BKV, ÖİDD ile elde edilen katsayıların tepe değerlerinin oluşturduğu sekiz girdiye sahipken BKV'nin çıktısı ise GKO sınıfıdır.

4. VERİ ÜRETİMİ

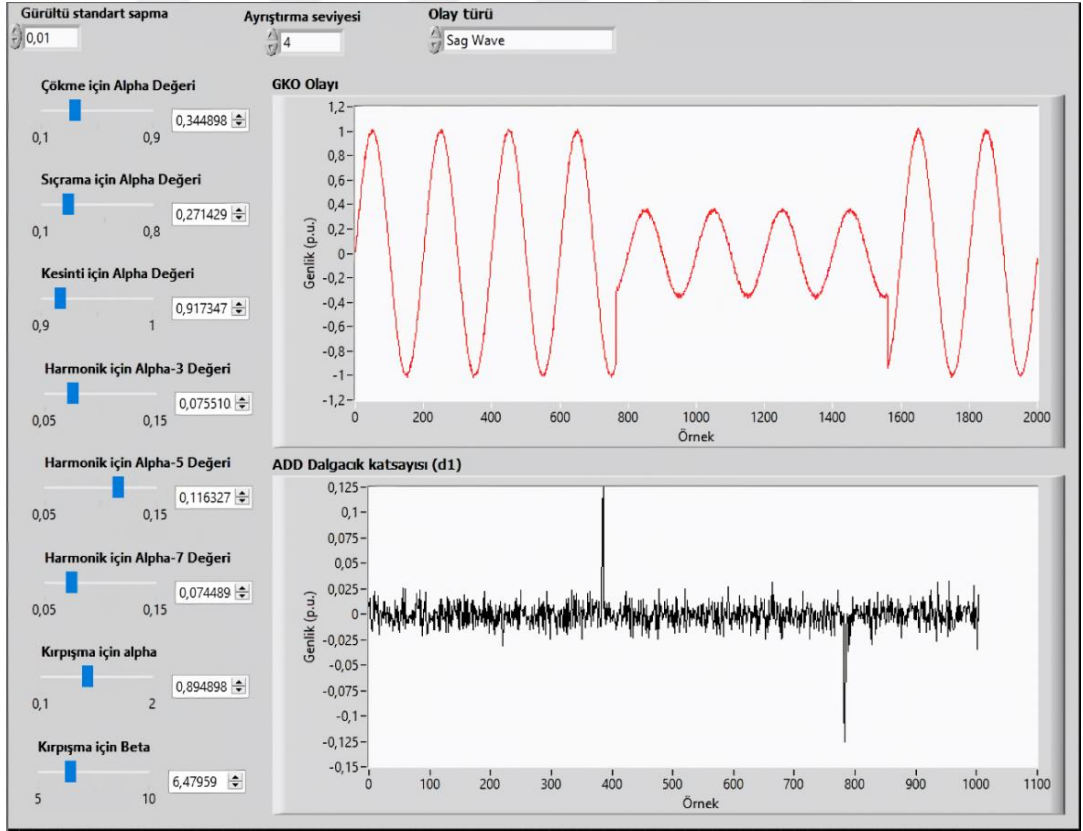
GKO ve AMOD olayları, gerçek hayatta nadir görülen olaylardır ve özellikle laboratuvar ortamında üretilmeleri oldukça zor olabilir. Ayrıca, bu olayların gerçek dünya verileri sınırlıdır ve mevcut veriler belirli bir örüntü içermeyebilir. Bu nedenle literatürde yapay zeka uygulamalarında kullanılmak üzere farklı şekilde verilerin de üretildiği görülmektedir [142]. Bu çalışmada 5 farklı şekilde veriler üretilmiş veya toplanmıştır:

- Matematiksel yöntemlerle veri üretimi: GK olaylarına ilişkin yapay veri setleri oluşturmak için kullanılmıştır. Bu yöntem, veri setinde özellikle nadir olan olaylar incelenmek istendiğinde oldukça kullanışlıdır. Kısa sürede milyonlarca veri üretilebilir.
- Benzetim program yardımıyla veri üretimi: GKO ve AMOD olayları simülasyonlar kullanılarak da oluşturabilir. Ayrıca simülasyonlar, AMOD tespiti için farklı senaryoların test edilmesi için de kullanılabilir.
- Laboratuvar deneyleri ile veri üretimi: Yapay veri setlerinin laboratuvar ortamında elde edilen gerçek verilerle desteklenmesi gerekir. Bu çalışmada, FV sistem ve ideal olmayan yüklerin bulunduğu bir mikroşebekede çeşitli olay üretimi için manevra gerçekleştirme, arıza oluşturma ve devreye alma/devreden çıkarma gibi yöntemlerle veriler üretilmiş ve kaydedilmiştir.
- GKO üretme özelliğine sahip bir kaynak ile veri oluşturma: Deneysel yöntemlerle elde edilen verilerin yetersizliği ve her olayın gerçekleştirilememesi gibi nedenlerle GKO üretme özelliğine sahip generatörler ile ayrıca veriler üretilebilir.
- Gerçek dünya verilerini kullanma: Tüm bu yöntemlerden farklı olarak GKO verileri, enerji şirketlerinin veya araştırmacıların arşivlerinden toplanabilir. Bu verilerin kullanımı oldukça değerli olup paylaşımı yapılan veri setlerinin sınırlı olduğu görülmektedir.

4.1 İntegral-Tabanlı Matematiksel Modelle Veri Üretimi

Mevcut literatürün çoğu, GKO ile ilgili gerçek sinyalleri elde etmenin zorluğu nedeniyle veri üretimi için bir matematiksel model veya simülasyon modeli de kullanmıştır [87,121,143-146]. Tez çalışmasında, gerçek verilere en yakın karakteristiği göstermesi nedeniyle GKO sinyallerini üretmede integral-Tabanlı matematiksel model kullanılmıştır [143]. Özellikle mikroşebeke uygulamalarında en yaygın görülen hem tekli hem de kompleks (aynı anda iki veya daha çok olayın gerçekleştiği sinyaller) yapıda GKO sinyalleri, IEEE standartlarına göre LabVIEW ortamında otomatik olarak üretilmiştir [121].

Şekil 4.1'de oluşturulan veri üretim programının ara-yüzü gösterilmektedir. Araştırmacılar, örnek sayısı, örnekleme frekansı, temel frekans ve sinyallerin normal genliği gibi yapılandırma seçeneğine sahiptir. İntegral-Tabanlı yöntem kullanılarak kısıtlama parametreleri rastgele değiştirilerek sonsuz sayıda veri üretilebilir. Ayrıca, program ara-yüzü aracılığıyla üretilen GKO sinyallerine farklı seviyede gürültü uygulanabilir.



Şekil 4.1 : İntegral-Tabanlı yöntemle GKO üretim yazılımının arayüzü.

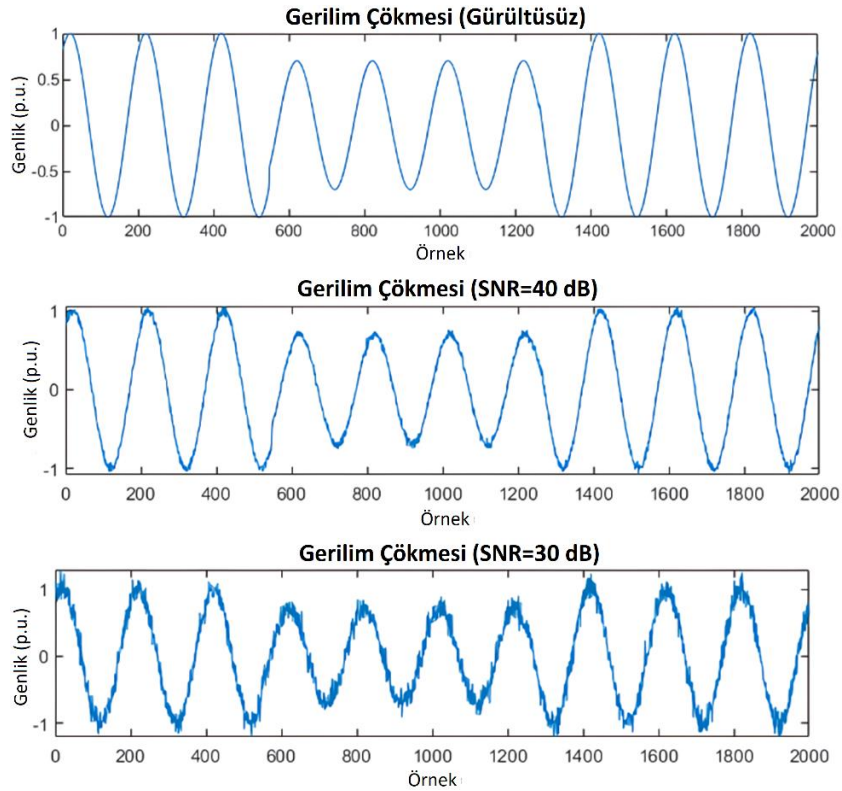
Çalışmada kullanılmak için seçilen GKO parametreleri şu şekildedir:

- Temel frekans değeri 50 Hz'dir.
- Örnekleme frekansı 10 kHz'dir.
- Temel frekansın döngü sayısı on döngüdür (0,2 saniye-2000 nokta).
- Her sınıf için oluşturulan örnek sayısı uygulamadan uygulamaya değişmektedir.
- GKO sinyallerinin gerilim genlik değeri birim değer dönüşümü (ρ_u) ile belirlenir.

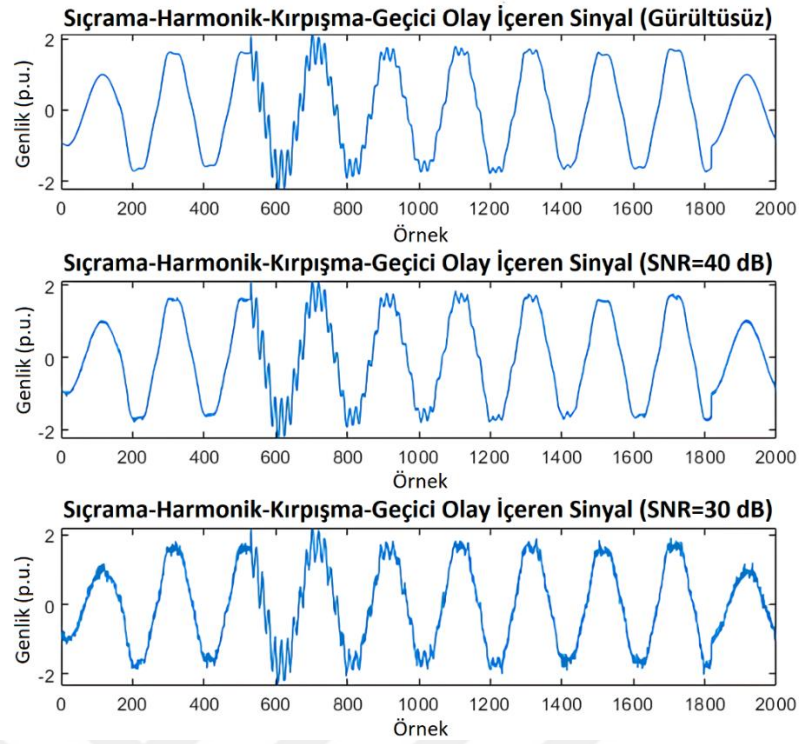
Gürültülü bir ortamda GKO'ları simüle etmek için, Beyaz-Gauss gürültüsü, ideal GKO dalga biçimlerine eklenmiştir. Sinyal-gürültü-oranının (SNR) tanımı şu şekilde ifade edilebilir:

$$SNR = 10 \log_{10} \left(\frac{P_s}{P_n} \right) \text{ dB} \quad (4.1)$$

Denklem 4.1'de, P_s ve P_n sırasıyla ideal sinyal ortalama gücünü ve gürültü ortalama gücünü ifade eder. Önerilen yöntemlerin eğitimi ve doğrulanması için $SNR=\infty$, $SNR=40$ dB, $SNR=30$ dB ve $SNR=25$ dB için GKO verileri üretilmiştir. Gerilim çökmesi (C2) ve sıçrama, kırpışma, geçici olay, harmonik içeren kompleks olay (C19) sınıfları için farklı SNR değerlerinde üretilen sinyaller Şekil 4.2'de gösterilmektedir.



(a)



(b)

Şekil 4.2 : Matematiksel model ile üretilen (a) C2 ve (b) C19 sınıfları.

Çizelge 4.1'de, yazılım tarafından integral tabanlı model ile oluşturulan nominal sinyalle beraber 8 tekli ve 10 kompleks GKO sınıflarının denklemleri ve parametreleri ayrıntılı olarak verilmiştir. Ayrıca literatürde kullanılan GKO veri setlerinden farklı olarak çalışma şartlarında kabul edilen sınırlar içindeki sinyaller geliştirilen yazılım ile nominal sınıfa (C1) dahil edilmektedir. Örneğin, %5 genlik düşüşüne sahip bir olay sinyali, IEEE 1159 standardında ayarlanan eşikten daha düşük harmonikler içeren bir sinyal veya bunların kompleks durumları C1 sınıfında olabilir. Nominal sinyal verilerindeki çeşitlilik, sistem esnekliğini ve güvenilirliğini artırmıştır.

Çizelge 4.1 : GKO üretiminin matematiksel modeli.

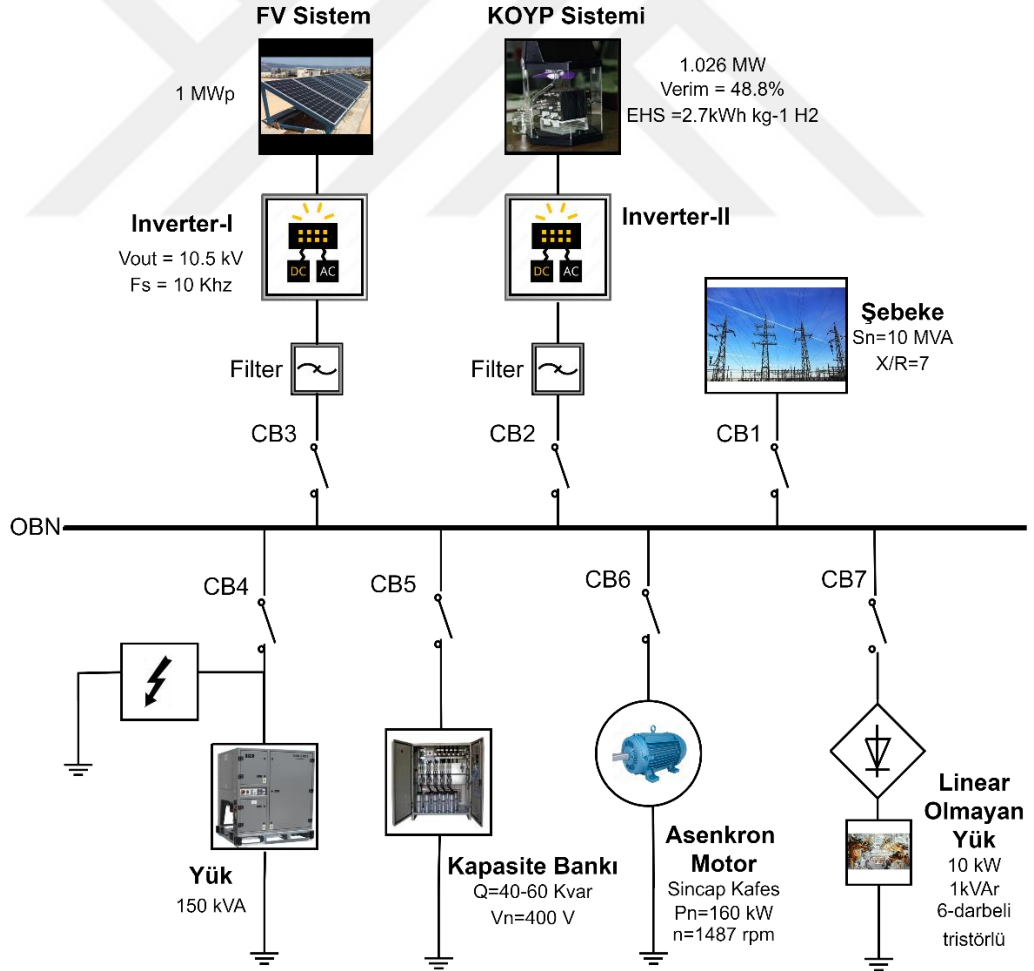
GKO Sınıfları	Denklemler	Eşik Değer Parametreleri
C1	$x(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi)$	$49,8 \leq f \leq 50,2$, $-\pi \leq \varphi \leq \pi$
Nominal	$x(t) = [1 + \beta(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi)$	$0 \leq \alpha < 0,1$, $0 \leq \beta < 0,1$
C2	$x(t) = \sin(2\pi ft - \varphi) + \sum_{n=3}^7 \alpha_n \sin(2\pi f_n t - \varphi_n)$	$u(t) = \begin{cases} 0, & t < 0 \\ 1, & t \geq 0 \end{cases}$ $\alpha_n < 0,03$
Gerilim Çökmesi	$x(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi)$	$T \leq t_2 - t_1 \leq 9T$; $0,1 \leq \alpha < 0,9$
C3	$x(t) = [1 + \beta(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi)$	$T \leq t_2 - t_1 \leq 9T$; $0,1 \leq \beta < 0,8$
Gerilim Sıçraması	$x(t) = [1 - \gamma(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi)$	$T \leq t_2 - t_1 \leq 9T$; $0,9 \leq \gamma < 1$
C4	$x(t) = [1 - \gamma(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi)$	
Gerilim Kesintisi		

Çizelge 4.1 (devam) : GKO üretiminin matematiksel modeli.

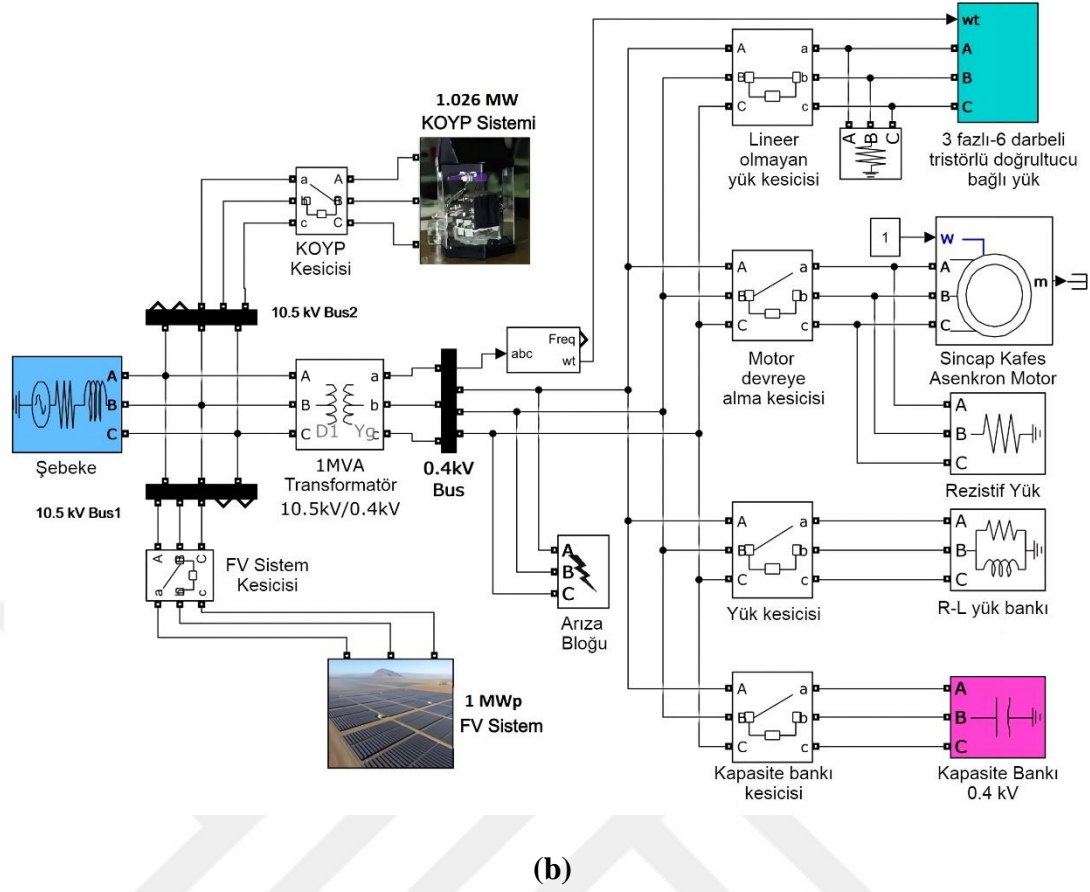
GKO Sınıfları	Denklemler	Eşik Değer Parametreleri
C5 Harmonikler	$x(t) = \sin(2\pi ft - \varphi) + \sum_{n=3}^7 \alpha_n \sin(n\pi ft - \vartheta_n)$	$n = \{3,5,7\}; 0,05 \leq \alpha_n \leq 0,15$ $-\pi \leq \vartheta_n \leq \pi$
C6 Kırpışma	$x(t) = [1 + \delta \sin(2\pi f_i t)] \sin(2\pi ft - \varphi)$	$0,05 \leq \delta < 0,1; 8 \leq f_i < 25$
C7 Osilasyonlu Geçici Durum	$x(t) = \sin(2\pi ft - \varphi) + \beta \exp(-(t - t_1)/\tau) \sin(2\pi f_n(t - t_1) - \vartheta) ((u(t - t_2) - (u(t - t_1))))$	$300 \text{ Hz} \leq f_n \leq 900 \text{ Hz};$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms};$ $0,5T \leq t_2 - t_1 \leq 3T$
C8 Darbeli Geçici Durum	$x(t) = \sin(2\pi ft - \varphi) + \sigma(\exp(-750(t - t_a) - \exp(-344(t - t_a)))(u(t - t_a) - u(t - t_b)))$	$0,222 \leq \sigma < 1,11; T \leq t_a \leq 9T, t_b = t_a + 1\text{ms}$
C9 Çentik	$x(t) = \sin(2\pi ft - \varphi) - \text{sign}(\sin(2\pi ft - \varphi)) + \sum_{n=0}^{10c-1} \alpha_n \sin(n\pi ft - \vartheta_n) k(u(t - (t_c + s.n)) - u(t - (t_d + s.n)))$	$0,01T \leq t_d - t_c \leq 0,05T; t_d \leq s; t_c \geq 0; 0,1 \leq k < 0,4; c = \frac{T}{c}$ $\{1,2,4,6\}; s = \frac{T}{c}$
C10 Harmonik ve Çökme	$x(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi) + \sum_{n=3}^7 \alpha_{n'} \sin(n'\pi ft - \vartheta_{n'})$	$n' = \{3,5,7\}; 0,05 \leq \alpha_{n'} \leq 0,15;$ $-\pi \leq \vartheta_{n'} \leq \pi$
C11 Harmonik ve sıçrama	$x(t) = [1 + \beta(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi) + \sum_{n=3}^7 \alpha_{n'} \sin(n'\pi ft - \vartheta_{n'})$	$n' = \{3,5,7\}; 0,05 \leq \alpha_{n'} \leq 0,15;$ $-\pi \leq \vartheta_{n'} \leq \pi$
C12 Kırpışma ve Çökme	$[1 + \delta \sin(2\pi f_i t) - \alpha(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi)$	$0,05 \leq \delta < 0,1; 8 \leq f_i < 25$ Hz
C13 Kırpışma ve Sıçrama	$[1 + \delta \sin(2\pi f_i t) + \beta(u(t - t_1) - u(t - t_2))] \sin(2\pi ft - \varphi)$	$0,05 \leq \delta < 0,1; 8 \leq f_i < 25$ Hz
C14 Çökme ve Osilasyonlu Geçici Durum	$x(t) = \sin(2\pi ft - \varphi) (1 - \alpha(u(t - t_1) - u(t - t_2))) \beta \exp(-(t - t_{1'})/\tau) \sin(2\pi f_n(t - t_{1'}) - \vartheta) ((u(t - t_{1'}) - (u(t - t_{1'})))$	$300 \text{ Hz} \leq f_n \leq 900 \text{ Hz};$ $\frac{T}{5} \leq t_{1'} - t_{1'} \leq t_2 - t_1; t_{1'} \geq t_1, t_{1'} \leq t_2$
C15 Sıçrama ve Osilasyonlu Geçici Durum	$x(t) = \sin(2\pi ft - \varphi) (1 + \beta(u(t - t_1) - u(t - t_2))) \beta \exp(-(t - t_{1'})/\tau) \sin(2\pi f_n(t - t_{1'}) - \vartheta) ((u(t - t_{1'}) - (u(t - t_{1'})))$	$300 \text{ Hz} \leq f_n \leq 900 \text{ Hz};$ $\frac{T}{5} \leq t_{1'} - t_{1'} \leq t_2 - t_1; t_{1'} \geq t_1, t_{1'} \leq t_2$
C16 Harmonik, sıçrama ve kırpışma	$x(t) = (1 + \delta \sin(2\pi f_i t)) [\sin(2\pi ft - \varphi) + \sum_{n=3}^7 \alpha_{n'} \sin(n'\pi ft - \vartheta_{n'})] (1 - \alpha(u(t - t_1) - u(t - t_2)))$	$n' = \{3,5,7\}; 0,05 \leq \alpha_{n'} \leq 0,15;$ $-\pi \leq \vartheta_{n'} \leq \pi; 0,05 \leq \delta < 0,1$
C17 Harmonik, sıçrama ve kırpışma	$x(t) = (1 + \delta \sin(2\pi f_i t)) [\sin(2\pi ft - \varphi) + \sum_{n=3}^7 \alpha_{n'} \sin(n'\pi ft - \vartheta_{n'})] (1 + \beta(u(t - t_1) - u(t - t_2)))$	$n' = \{3,5,7\}; 0,05 \leq \alpha_{n'} \leq 0,15;$ $-\pi \leq \vartheta_{n'} \leq \pi; 0,05 \leq \delta < 0,1$
C18 Çökme, Harmonik, Osilasyonlu Geçici Durum ve Kırpışma	$x(t) = \sin(2\pi ft - v_1) + (-\alpha(u(t - t_1) - u(t - t_2))) \sum_{n''=1}^7 \alpha_{n''} \sin(n''\pi ft - \vartheta_{n''}) + \beta \exp(-(t - t_{1'})/\tau) \sin(2\pi f_n(t - t_{1'}) - \vartheta) ((u(t - t_{1''}) - (u(t - t_{1'})))$	$n'' = \{1,3,5\}; \alpha_{n''} = 1 n'' = 1; 0,05 \leq \alpha_{n''} \leq 0,15 n'' = \{3,5\};$ $\frac{T}{5} \leq t_{1'} - t_{1'} \leq t_2 - t_1; t_{1'} \geq t_1, t_{1'} \leq t_2$
C19 Sıçrama, Harmonik, Osilasyonlu Geçici Durum ve Kırpışma	$x(t) = \sin(2\pi ft - v_1) + (\beta(u(t - t_1) - u(t - t_2))) \sum_{n''=1}^7 \alpha_{n''} \sin(n''\pi ft - \vartheta_{n''}) + \beta \exp(-(t - t_{1'})/\tau) \sin(2\pi f_n(t - t_{1'}) - \vartheta) ((u(t - t_{1''}) - (u(t - t_{1'})))$	$n'' = \{1,3,5\}; \alpha_{n''} = 1 n'' = 1; 0,05 \leq \alpha_{n''} \leq 0,15 n'' = \{3,5\}$ $\frac{T}{5} \leq t_{1'} - t_{1'} \leq t_2 - t_1; t_{1'} \geq t_1, t_{1'} \leq t_2$

4.2 Mikroşebeke Benzetim Modeliyle Veri Üretimi

Güç sistemlerinde kullanılan benzetim modelleri, bilgisayar ortamında yüzlerce farklı çalışma koşulunu analiz etme imkanı sağlamaktadır. Bu çalışmada, MATLAB/Simulink ortamında modellenen mikroşebekenin şematik görünümü Şekil 4.3'te gösterilmektedir. DG içeren mikroşebeke, bir FV sistem, bir katı oksit yakıt pili (KOYP)-Tabanlı sistem, bir üçgen/yıldız bağlantılı iki sargılı kademeli transformatör, doğrusal ve endüstriyel uygulamalardaki doğrusal olmayan yükler (EA şarj istasyonu, 6-darbeli tistörlü dönüştürücü ile beslenen yükler), kapasite bankası, asenkron motor ve devre kesicilerden (CB) oluşmaktadır. Talep tarafındaki duruma bağlı olarak devre kesicilerle yapılan anahtarlama ile Çizelge 4.1'de verilen olaylar için simülasyonlar oluşturulur. Üretilen verilerde temel frekans 50 Hz, örnekleme frekansı 10 kHz ve pencere süresi 0,2 saniye olarak belirlenmiş olup matematiksel veriler ile benzerdir. Çalışılan sistemin parametreleri Çizelge 4.2'de gösterilmiştir.



(a)



Şekil 4.3 : (a) Modellenen sistemin şematik görünümü, (b) Simulink modeli.

YEK-Tabanlı DG'lerin mikroşebekeye bağlanması, GK sorunlarına, sistem güvenilirliğinde bozulmaya ve diğer ilgili sorunlara neden olabilir. Bu sorunlar, geleneksel sistemlerdeki olaylarla benzer özellikler gösterir. Bununla birlikte, bazı durumlarda, FV ve KOYP sistemlerindeki özel çalışma koşulları spesifik GK sorunlarına neden olabilir. DG'lerin varlığında gerilim düzenlemesi bir zorluk haline gelir. Dağıtım şebekesinde YEK-Tabanlı DG'lerin artan bağlantısı, gerilim profiline etki edebilir. Işınmında meydana gelen değişim gibi çevresel faktörler ile DG'lerin devreye alınması/devreden çıkarılması gibi işlemler arıza yerine bağlı olarak sistemde çökme/kesinti/sıçrama meydana getirebilir. Ayrıca, anahtarlamalı yükler/kapasitör bankaları, doğrusal olmayan yükler, DG'lerin devreye alınması/devreden çıkarılması gibi işlemler ve inverter kontrol stratejileri harmoniklere, kırışıma, salınımlı-darbeleri geçici olaylara ve çentiklere neden olabilir. Ek olarak, DG'ler ve dağıtım ağı arasındaki güç etkileşimi nedeniyle GKO'lar üst üste gelebilir ve daha kompleks olay tipleri oluşabilir.

Çizelge 4.2 : Benzetim modeli oluşturulan sistem parametreleri.

	Parametreler	Değer
FV sistem [33-GBDT]	Maksimum güç	1 MWp
	İnverter çıkış gerilimi	10,5 kV
	Inverter anahtarlama frekansı	10 kHz
	Nominal frekans	50 Hz
KOYP-Tabanlı sistem [29,34-GBDT]	Maksimum güç	1,026 MW
	Verim	%48.8
	EHS	2.7 kWh kg ⁻¹ H ₂
	Inverter anahtarlama frekansı	10 kHz
	Nominal frekans	50 Hz
Şebeke	Görünür güç (S_n)	10 MVA
	3-faz kısa devre gerilimi (VA)	10 MV
	X/R oranı	7
Asenkron motor	Tip	Sincap kafes
	Aktif güç (P_n)	160 kW
	(n_n)	1487 rpm
Lineer olmayan yük-1	Aktif güç (P_n)	10 kW
	İndüktif reaktif güç	1KVAr
	Kontrollü dönüştürücü	6 darbeli-tristörlü
Lineer olmayan yük-2	Aktif güç (P_n)	22 kW
	İndüktif reaktif güç	1 KVAr
	Kontrollü dönüştürücü	EA dönüştürücü
Normal yük	R-L Yük	150 kVA
Transformatör	Gerilim seviyesi	10.5 kV / 0,4 kV
	Sargı bağlantısı	$\Delta - Y$
	Görünür güç (S_n)	1 MVA
	R_{0pu} , L_{0pu}	0.002, 0.08
Kapasitör bankası	Reaktif güç	40 kVAr – 60 kVAr
	V_n	400 V

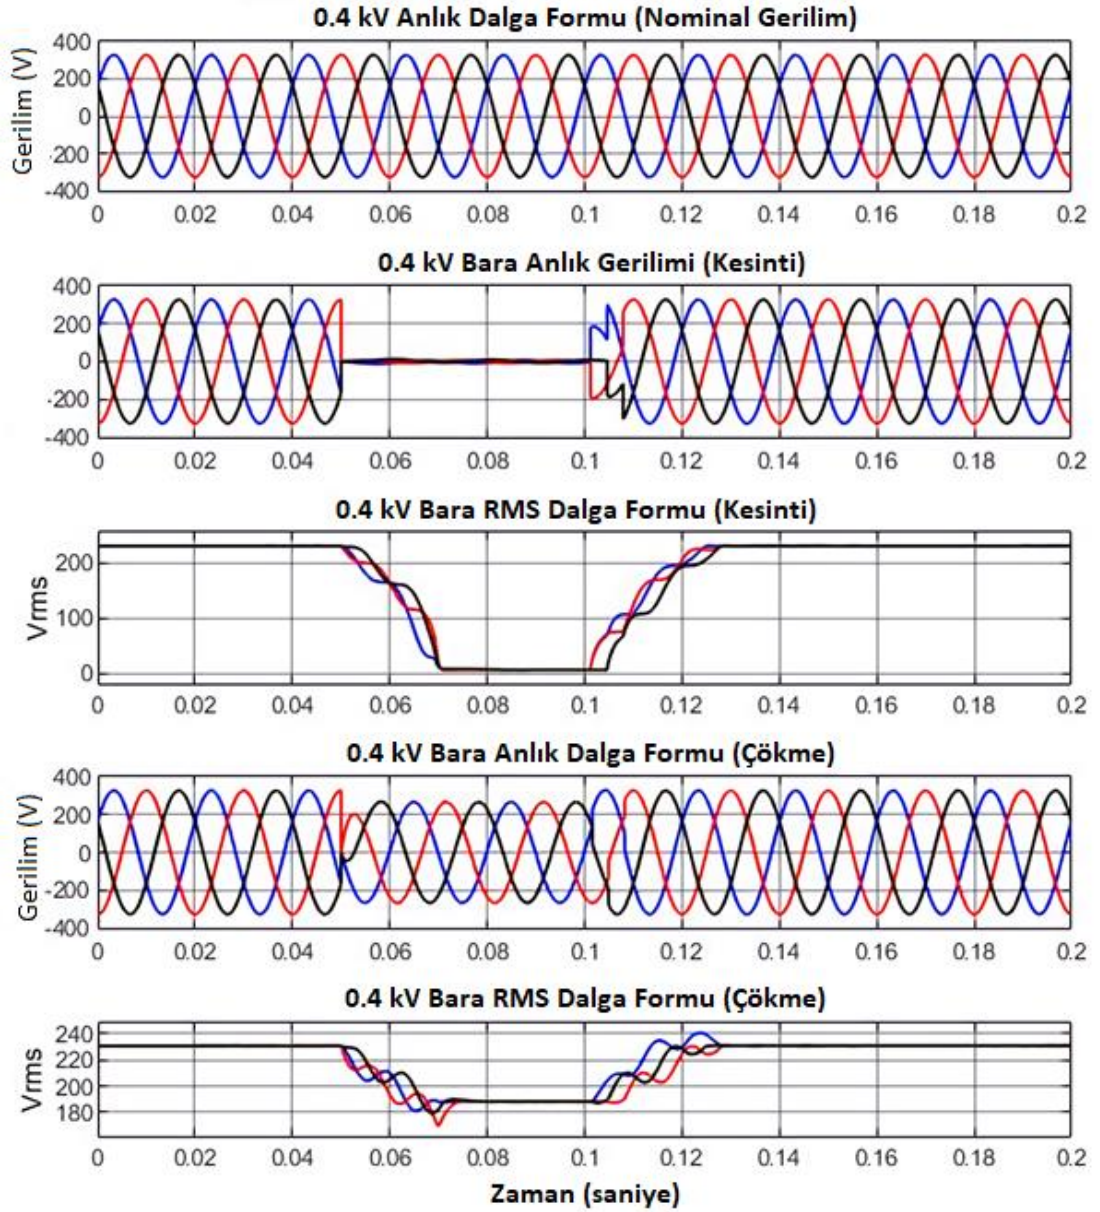
DG'lerin yüksek oranda entegrasyonun, GKO'ları daha karmaşık hale getireceği, ekipmanların hizmet ömrünün kısaltacağı ve işletme güvenilirliğini tehlikeye atacağı açıktır. Test seti oluşturulurken, DG çıkışları / yerel yükler için farklı kombinasyonları ele alınmıştır. Çentik bozukluklarını üretmek için doğrusal olmayan yükler farklı senaryolarda simüle edilmiştir. Ana harmonik kaynaklarının sırası, fazı, konumu, miktarı ve büyüklüğü gibi faktörler dikkate alınarak farklı kombinasyonlarda simüle edilmiş ve farklı harmonik içeren sinyaller elde edilmiştir. Kırpışma olayları, ara harmoniklerin bir kombinasyonu olarak düşünülerek harmonik sınıfı örneklerine benzer şekilde oluşturulmuştur.

DG'deki bazı özel çalışma koşulları, geleneksel güç sistemleriyle aynı olmayan GK sorunlarına neden olur:

- Gerilim çökmesi, gerilim sıçraması ve gerilim kesintisi olayları: Arıza yeri ve DG çalışma modu koşullarına bağlı olarak, bir arıza veya işlevsel problem gerilim çökmesine, kesintisine veya sıçramasına neden olabilir. Gerilim çökmesi, DG çalışma geriliminde 1 ila 9 döngü için nominal gerilim değerinden %10–%90'lık bir düşüş olarak tanımlanır. DG'lerde aşırı yüklenmiş motorlar, büyük yüklerin devreye alınması, tek faz-toprak arızaları ve KOYP sisteminin aniden devreye alınması gerilim çökmesine neden olabilir. Tez çalışmasındaki gerilim çökmesi sinyalleri, OBN'deki (0,4 kV bara) tek faz-toprak arızası veya iletim hattının sonundaki arızalar, çeşitli DG başlatılma kombinasyonları ve OBN'deki büyük yüklerin anahtarlanması ile üretilmiştir.

Gerilim kesinti olayı, 1 ila 9 döngü için işletme gerilim genliğinin %90'ından daha fazla bir düşüş olarak tanımlanır. Güç sistemlerinde kısa devre direncine bağlı olarak iki faz-toprak arızaları ve üç fazlı simetrik arızalar gerilim kesintisine neden olabilir. Ayrıca DG yapısında, AMODunda çalışma bir sistemde büyük yüklerin devreye alınması, komponent arızaları, devre kesicilerinin açması da kesintiye neden olabilir. Modellenen mikroşebekede, OBN'de iki faz-toprak arızaları ve üç faz simetrik arızalar simüle edilerek gerilim kesintisi bozulma sinyalleri üretilmiştir. Test setinde, olay sinyalleri üretilirken çeşitli DG çıkışları ve DG yükleri kombinasyonları kullanılmıştır.


Gerilim sıçraması olayı, belirli bir zaman aralığı ile sınırlı olup nominal gerilim genliğinin %10–%80'lik bir artışını tanımlar. Faz-faz kısa devre arızaları, yüklerin anahtarlanması ve büyük kapasite banklarının devreye alınması güç sisteminde gerilim sıçramalarına neden olabilir. Ayrıca, KOYP veya FV generatör çıkışlarındaki dalgalanmalar da DG içeren sistemlerde gerilim sıçramasına neden olabilir. Benzetim modeli oluşturulan mikroşebekede, OBN'de farklı kısa devre dirençlerinde ve lokasyonlarda faz-faz arızaları simüle edilerek, büyük yükler devre dışı bırakılarak ve büyük kapasitör bankları devreye alınarak gerilim sıçrama sinyalleri üretilmiştir. Kaydedilen test seti için nominal gerilim durumu, gerilim kesintisi ve gerilim çökmesi olayları için dalga formları örneği Şekil 4.4'te gösterilmektedir.



Şekil 4.4 : OBN noktasındaki nominal, gerilim kesintisi ve gerilim çökmesi olayları anındaki anlık ve etkin gerilim dalga formları.

- Kırpışma, harmonikler, çentik ve geçici durum olayları: Güç sistemi uygulamalarında doğrusal olmayan yükler, kısa devre arızaları, büyük kapasitör bankları/yük anahtarlamaları ve DG çalışma modu değişimleri sonucunda darbeli ve osilasyonlu geçici durum olayları, çentikler, kırpışma ve harmonikler oluşabilir. Benzetim modeli oluşturulan mikroşebeke sisteminde, OBN'de büyük yüklerin anahtarlanması ve büyük kapasite bankalarının anahtarlanmasıyla salınımlı geçici durum olayları üretilmiştir. Doğrusal olmayan bir yük, çentik bozulmalarını oluşturmak için altı darbeli tristörlü bir dönüştürücü aracılığıyla beslenmiştir. Ayrıca, MATLAB/Simulink ile geliştirilen yıldırım ve elektrostatik

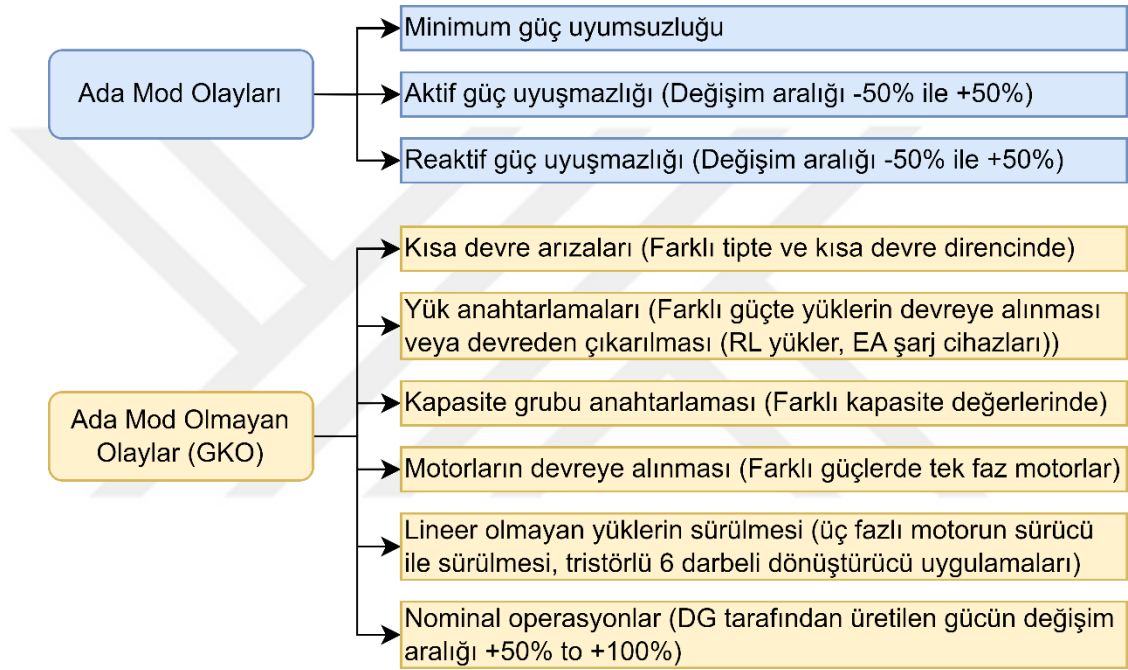
deşarj bloğu ile darbeli geçici durum sinyalleri üretilmiştir. Transformatör enerjilendirmesi simüle edilmiş mikroşebeke sisteminde harmonik içeren sinyaller oluşturulmuştur. Test veri setinde tüm olaylar için farklı DG çıkışları ve DG yükleri içeren senaryo kombinasyonları kullanılmıştır. Benzetim modeli ile üretilen salınımlı geçici olay ve çentik bozulması için dalga formları Şekil 4.5'te gösterilmektedir.



Şekil 4.5 : Salınımlı geçici ve darbeli geçici olaylar ile çentiklerin oluşturduğu OBN'deki gerilim dalga biçimleri.

4.3 Deneysel Kurulum ve Verilerin Toplanması

Deneysel test sistemi üzerinden verilerin toplanma süreci iki başlık altında incelenecektir: 1) AMOD test sistemi ile olay verilerinin elde edilmesi, 2) AMOD olmayan olay verilerinin elde edilmesi. Şekil 4.6'da veri seti oluşturmada kullanılan senaryoların ayrıntıları verilmiştir. GKO üretiminde IEEE 1159-2019, IEEE 519 ve IEEE 1547-2018 standartlarına göre senaryolar oluşturulmuştur. AMOD olay verileri ise IEEE Std. 929-2000 standartlarına uygun şekilde gerçekleştirilen senaryolarla elde edilmiştir.



Şekil 4.6 : Test sistemi üzerinden elde edilen verilerin dağılımı.

4.3.1 AMOD test sistemi ve olay verilerinin toplanması

Güç şebekesindeki herhangi bir gerilim veya frekans değeri kabul edilebilir limitleri aşarsa, DG sistemi fiziksel olarak şebekeden mümkün olan en kısa sürede izole edilmelidir. Ayrıca, mikroşebekelerde yük/kapasite grupları anahtarlama, farklı DG işletme koşulları veya kısa devre arızaları gibi diğer arızalar da GKO olarak adlandırılır ve AMOD olmayan olay grubunu oluşturur. Farklı şebeke koşullarında DG yük talebinin değerlendirilmesi ve tüm olası yük senaryolarında test yapılması, önerilen AMOD tespit yönteminin güvenilirliği ve sürdürülebilirliği için gereklidir. IEEE Std. 929-2000'de tanımlanan kalite faktörü (Q_f), geliştirilen AMOD tespit

yöntemleri için önemli bir performans değerlendirme kriteridir. Kalite faktörünün tanımı aşağıdaki gibidir:

$$Q_f = 2\pi \frac{\text{depolanan maksimum enerji}}{\text{bir dönemde kaybedilen toplam enerji}} \quad (4.2)$$

RLC devresi, yaygın olarak kullanılan performans değerlendirme yöntemlerinden biridir. Q_f hesaplamak için, yerel yük paralel RLC ile temsil edilir. ω_0 , yükün açışal rezonans frekansıdır ve Denklem 4.3'te verilen denklem ile hesaplanır.

$$\omega_0 = \frac{1}{\sqrt{LC}} \quad (4.3)$$

Ardından RLC yükü rezonans frekansında çalışır. RLC'nin Q_f değeri Denklem 4.4'ten hesaplanır. Paralel RLC devresinin Q_f değeri, frekansa bağlı olmayan bir değerdir.

$$Q_f = \frac{2\pi \left(\frac{1}{2} CR^2 I_m^2 \right)}{\frac{\pi R I_m^2}{\omega_0}} = \omega_0 RC = \frac{R}{\omega_0 L} = R \sqrt{\frac{C}{L}} \quad (4.4)$$

ADB, AMOD tespitinde önemli bir kriterdir. Bu alan, AMODun tespit edilemediği bölgedir. ADB genellikle güç uyumsuzluğu uzayı ile karakterize edilir ve özellikle pasif yöntemlerde görülür [34].

$$\left(\frac{V}{V_{max}} \right)^2 - 1 \leq \frac{\Delta P}{P} \leq \left(\frac{V}{V_{min}} \right)^2 - 1 \quad (4.5)$$

$$Q_f \left(1 - \left(\frac{f}{f_{min}} \right)^2 \right) \leq \frac{\Delta Q}{P} \leq Q_f \left(1 - \left(\frac{f}{f_{max}} \right)^2 \right)$$

burada, V sistem gerilimini, f sistem frekansını ifade etmektedir. V_{max} ve V_{min} , DG'lerdeki devre kesiciler için aşırı gerilim/aşırı düşük gerilim eşik sınır değerleridir. Benzer şekilde, f_{max} ve f_{min} aşırı frekans/aşırı düşük frekans eşik sınır değerleridir. Q_f kalite faktörünü ifade ederken, ΔP ve ΔQ güç uyumsuzluklarını temsil eder.

IEEE 929-2000 standartlarına göre, Denklem 4.5 kullanılarak geleneksel pasif yöntemler ve önerilen piramidal ÖİDD-Tabanlı yöntem için ADB hesaplanabilir. OVR/UVR (aşırı gerilim/düşük gerilim koruma yöntemi) ve OFR/UFR (aşırı frekans/düşük frekans koruma yöntemi) algoritmaları için ADB farklı kalite faktörlerinde şu şekilde bulunur:

$$V_{max} = 110\% V_n, V_{min} = 88\% V_n, f_{max} = 50,5 \text{ Hz}, f_{min} = 49,3 \text{ Hz}$$

Burada, V_n nominal gerilimi ifade etmektedir. $Q_f = 2,5$ için ADB,

$$-17,35\% \leq \frac{\Delta P}{P} \leq 29,13\%$$

$$-7,14\% \leq \frac{\Delta Q}{P} \leq 4,92\%$$

$Q_f = 1,5$ için ADB,

$$-17,35\% \leq \frac{\Delta P}{P} \leq 29,13\%$$

$$-4,28\% \leq \frac{\Delta Q}{P} \leq 2,95\%$$

$Q_f = 3$ için ADB,

$$-17,35\% \leq \frac{\Delta P}{P} \leq 29,13\%$$

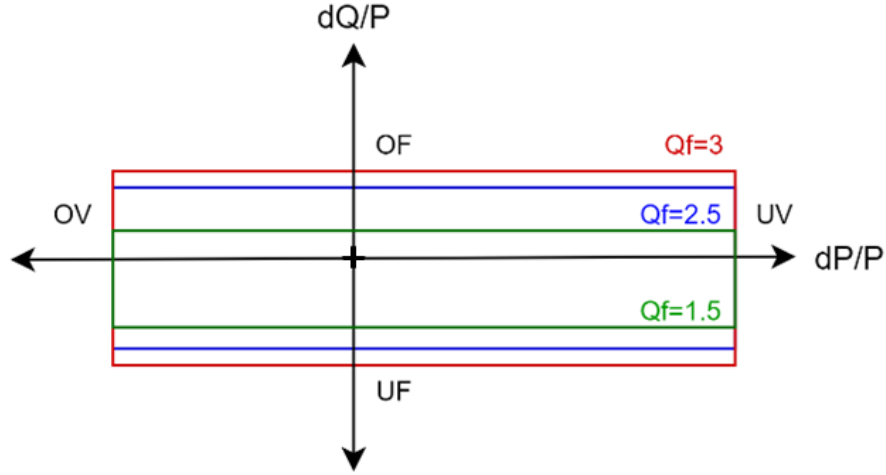
$$-8,57\% \leq \frac{\Delta Q}{P} \leq 5,91\%$$

Q_f ile ADB arasındaki ilişki Şekil 4.7’de gösterilmiştir. Q_f ’in 1,5, 2,5 ve 3 olduğu durumlarda geleneksel pasif yöntemlerle (OVR/UVR ve OFR/UFR) elde edilen sonuçlar geniş bir algılama dışı bölgeyi teşkil etmektedir. Önerilen yöntemde bu alan oldukça küçültülmüştür.

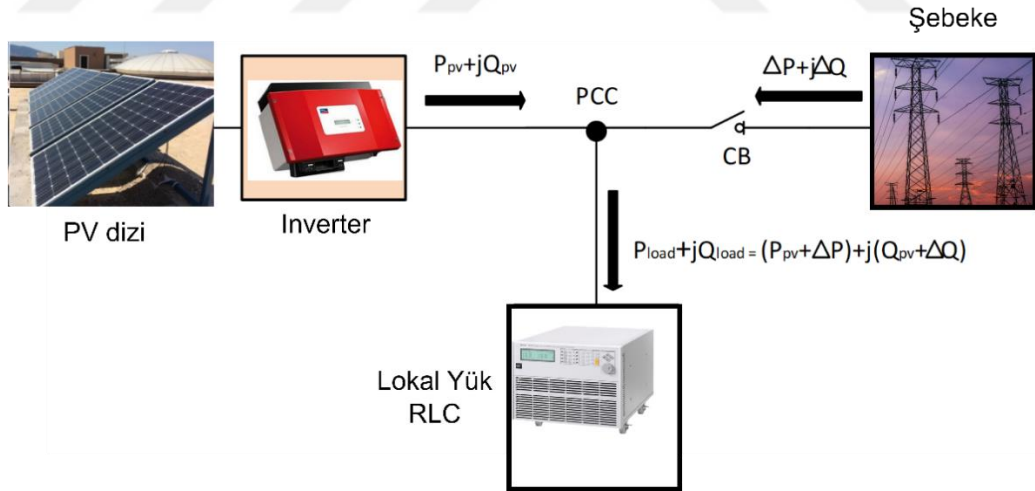
AMOD tespit yöntemlerin performansı farklı güç uyumsuzluğundaki ada koşulları altında test edilmelidir. DG-Tabanlı sistem birim güç faktöründe çalıştığından, 50 Hz’de (rezonans frekansı) paralel RLC yükü en kötü senaryo olarak ada durumu koşullarının tespiti için düşünülebilir. Test sistemi $R = 50 \Omega$, $L = 63 \text{ mH}$ ve $C = 0,16 \text{ mF}$ ’lik bir paralel yük altında çalıştırılır. Sistem rezonans frekansı ve kalite faktörü sırasıyla Denklem 4.3 ve Denklem 4.4 ile hesaplanır. Test sistemi yapılandırması ve güç akışı parametreleri Şekil 4.8’de gösterilmiştir.

$$Q_f = R \sqrt{\frac{C}{L}} = 50 \sqrt{\frac{0,000159}{0,063}} \approx 2,50$$

$$f_{resonance} = \frac{1}{2\pi\sqrt{LC}} = \frac{1}{2\pi\sqrt{0,000159 \times 0,063}} \approx 50 \text{ Hz}$$



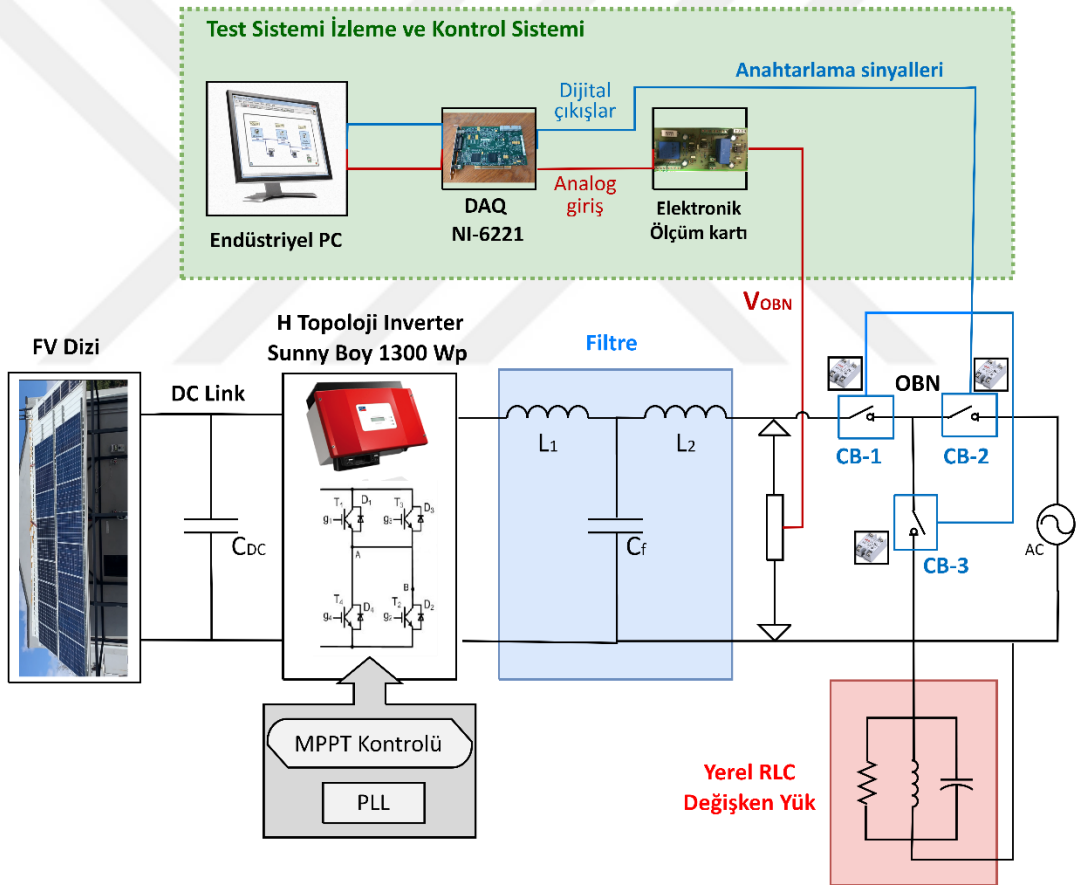
Şekil 4.7 : Farklı Q_f değerleri için geleneksel yöntemlerin ADB yanıtları.



Şekil 4.8 : AMOD test sistemi-IEEE Std. 929-2000.

Şekil 4.9’da, AMOD olay verilerinin toplanmasında kullanılan test sisteminin genel şaması ile izleme ve kontrol sistemi gösterilmiştir. Deneysel sistemde, H5 topolojisine sahip inverter FV dizi çıkışına bağlanmıştır. FV dizisi, 6 adet seri bağlantısı yapılmış 200 Wp gücünde panelden oluşmaktadır. Inverter çıkış sinyali filtreden geçirildikten sonra şebekeye devre kesiciler (CB-1 ve CB-2) üzerinden bağlanmıştır. Ayrıca CB-3


üzerinden değişken yerel yükün anahtarlama yapılabilmektedir. Geliştirilen algoritmada, inverter çıkışındaki gerilim sinyali kullanıldığından test sisteminde sadece OBN gerilimi gösterilmiştir. Devre kesicilerin kontrolü endüstriyel PC’de yüklü yazılım ile sağlanmaktadır. Test sisteminde, inverter, şebeke ve yerel yük tarafında elektronik ölçüm kartları (EÖK) yer almaktadır. EÖK içerisinde ise gerilim ve akım sensörleri bulunmaktadır. EÖK, gerilim ve akım sinyallerini veri toplama kartı (DAQ) analog girişi ile uyumlu hale getirmekte olup gerilim sinyali ± 10 V arasında sınırlandırılmıştır. DAQ tarafından alınan veriler ise LabVIEW yüklü PC’de işlenmektedir. Oluşturulan güç analizörü yardımıyla gerçek zamanlı olarak gerilim ve akım verileri izlenmektedir. Ayrıca yazılımla frekans, güç faktörü, harmonikler, aktif ve reaktif güçler inverter, şebeke ve yük tarafında izlenebilmektedir.



Şekil 4.9 : Test sistemi genel yapısı ve kontrol-izleme sistemi.

Şekil 4.10’da, BTU Yenilenebilir Enerji Sistemleri ve Akıllı Şebekeler Laboratuvarı içerisinde bulunan şebeke bağlantılı FV sistem genel görünümü verilmiştir. FV paneller panoya birer birer sigortalar ile bağlandığından farklı güçlerde ve konfigürasyonlarda diziler elde edilebilmektedir. Bu şekilde üretim tarafı da ada koşullarındaki senaryolar için kontrol edilebilmektedir. Görselde görülen ikili paket

şalter yapısıyla inverter seçimi gerçekleştirilebilmektedir. Ayrıca SMA Data Webbox ile gerçek zamanlı olarak inverter verileri ve laboratuvar sundurmasında bulunan ışınım sensörü verileri kaydedilmektedir. İzleme ve kontrol panosu ise tez çalışması kapsamında gerçekleştirilmiş olup içerisinde DAQ, EÖK, sigortalar, katı hal röleleri (SSR) ve farklı güçlerde çalışabilen güç kaynağı içermektedir.




Şekil 4.10 : Laboratuvar içi test sistemi genel görünüm.

AMOD test sistemi ayrıntılı görünümü Şekil 4.11’de verilmiştir. 1 numara ile 1300Wp'lik şebeke bağlantılı Sunny Boy inverter gösterilmektedir. Bu inverter, H5 topolojiye sahiptir ve anahtarlama frekansı değişken olup 10 kHz'den daha yüksektir. Çalışmada önerilen yöntem, inverterden bağımsızdır; bu nedenle test sistemi işlemi sırasında invertörün şebeke koruma önlemleri devre dışı bırakılmıştır. Yük altında 50A'e kadar anahtarlatabilen SSR numara 2 ile gösterilmiştir. Bu röleler CB-1, CB-2 ve CB-3 için devre kesici görevi üstlenmektedir. CB-2 için kullanılan SSR oluşturulan

yazılım ile anahtarlanarak AMOD durumunun oluşturulmasında kullanılmaktadır. CB-1 inverter çıkışındaki SSR olup, önerilen yöntem AMODu tespit ettiğinde tetiklenmektedir. Yük bankası ise CB-3 ile devreye alınmakta veya çıkarılmaktadır. İzleme ve kontrol panosunda bulunan diğer SSR'ler GKO olaylarının üretilmesinde kullanılmaktadır. Tek fazlı asenkron motor, sürücü üzerinden bağlı 3-fazlı asenkron motor, EA şarj cihazları, kapasite grupları ve diğer yükler bu cihazlarla devreye alınmaktadır veya devreden çıkarılmaktadır.

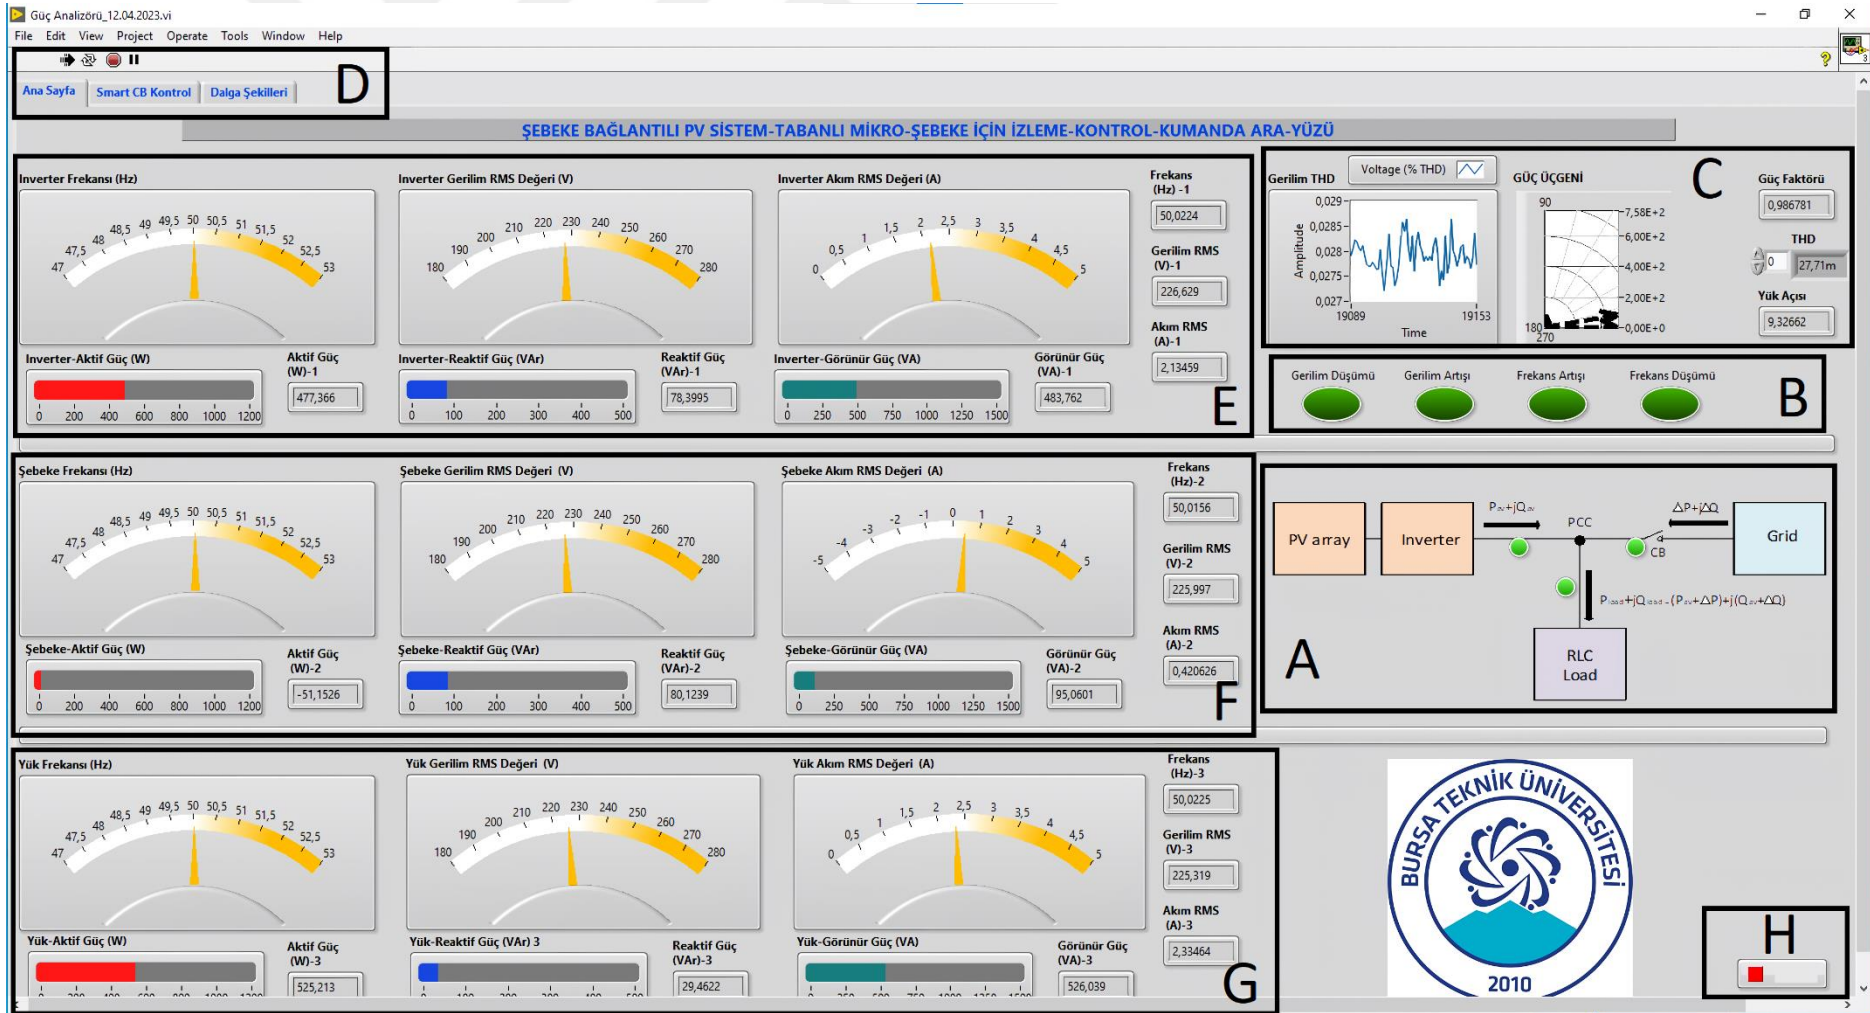
İnverter çıkışındaki frekans, gerilim ve akım verilerini DAQ kartına göndermek için kullanılan EÖK, 3 ile gösterilmiştir. Ölçüm kartında, LEM LV-25-P gerilim transdüseri ve LEM LA-25-P akım transdüseri bulunmaktadır. LV-25-P ile alınan inverter çıkış gerilim verisi, DAQ kartının girişine aktarılmıştır. Bu eleman için birincil nominal RMS akımı (I_{PN}) 10 mA ve birincil nominal RMS gerilimi (V_{PN}) 10-500 V'tur. Ayrıca, V_{PN} 'nin %90'lık son çıkış değerine kadarki gecikme süresi 40 μ s'dir ve bu değer oldukça düşüktür. LA-25-P ile alınan inverter çıkış akım verisi, gerilim sinyali gibi DAQ kartının girişine aktarılmıştır. LA-25-P için birincil nominal RMS akım (I_{PN}) 25 A ve dönüşüm oranı 1: 1000'dir. Ayrıca, I_{PN} 'nin %90'lık son çıktı değeri için gecikme süresi <1 μ s'dir. Her iki sensör tipi için de besleme gerilim aralığı 12-15 V'tur.

Gerilim ve akım verisinden yararlanarak, geliştirilen LabVIEW güç analizör yazılımıyla aktif, reaktif ve görünür güç, frekans, harmonik ölçümleri, güç faktörleri ve yük açısı gerçek zamanlı olarak hesaplanmakta ve izlenebilmektedir. NI MX USB-6221 DAQ veri toplama kartı, numara 4 ile gösterilmektedir. Kullanılan veri toplama cihazının analog veri hızı (data rate) 12kb/s'dir. Kartın analog ve dijital giriş/çıkışları klemenslere aktarılmıştır. NI-DAQ kartları fiziksel olarak veri toplayabilir, işleyebilir ve bu verileri bir bilgisayarın yardımıyla kontrol edebilmektedir. LabVIEW ortamında geliştirilen ara-yüz numara 5 ile belirtilmiştir. Güç analizörü numara 6 ile gösterilmektedir ve Chauvin Arnoux CA 8336 serisine aittir. Güç analizörü ile sistemdeki elektriksel büyüklükler izlenmektedir. Yazılım kalibrasyonu güç analizörü verilerine göre yapılmaktadır. Yük gurubu ise görselde 7 numara ile gösterilmiştir. Farklı yük koşulları rezistif, indüktif ve kapasitif yük bankalardan yararlanarak oluşturulabilmektedir.

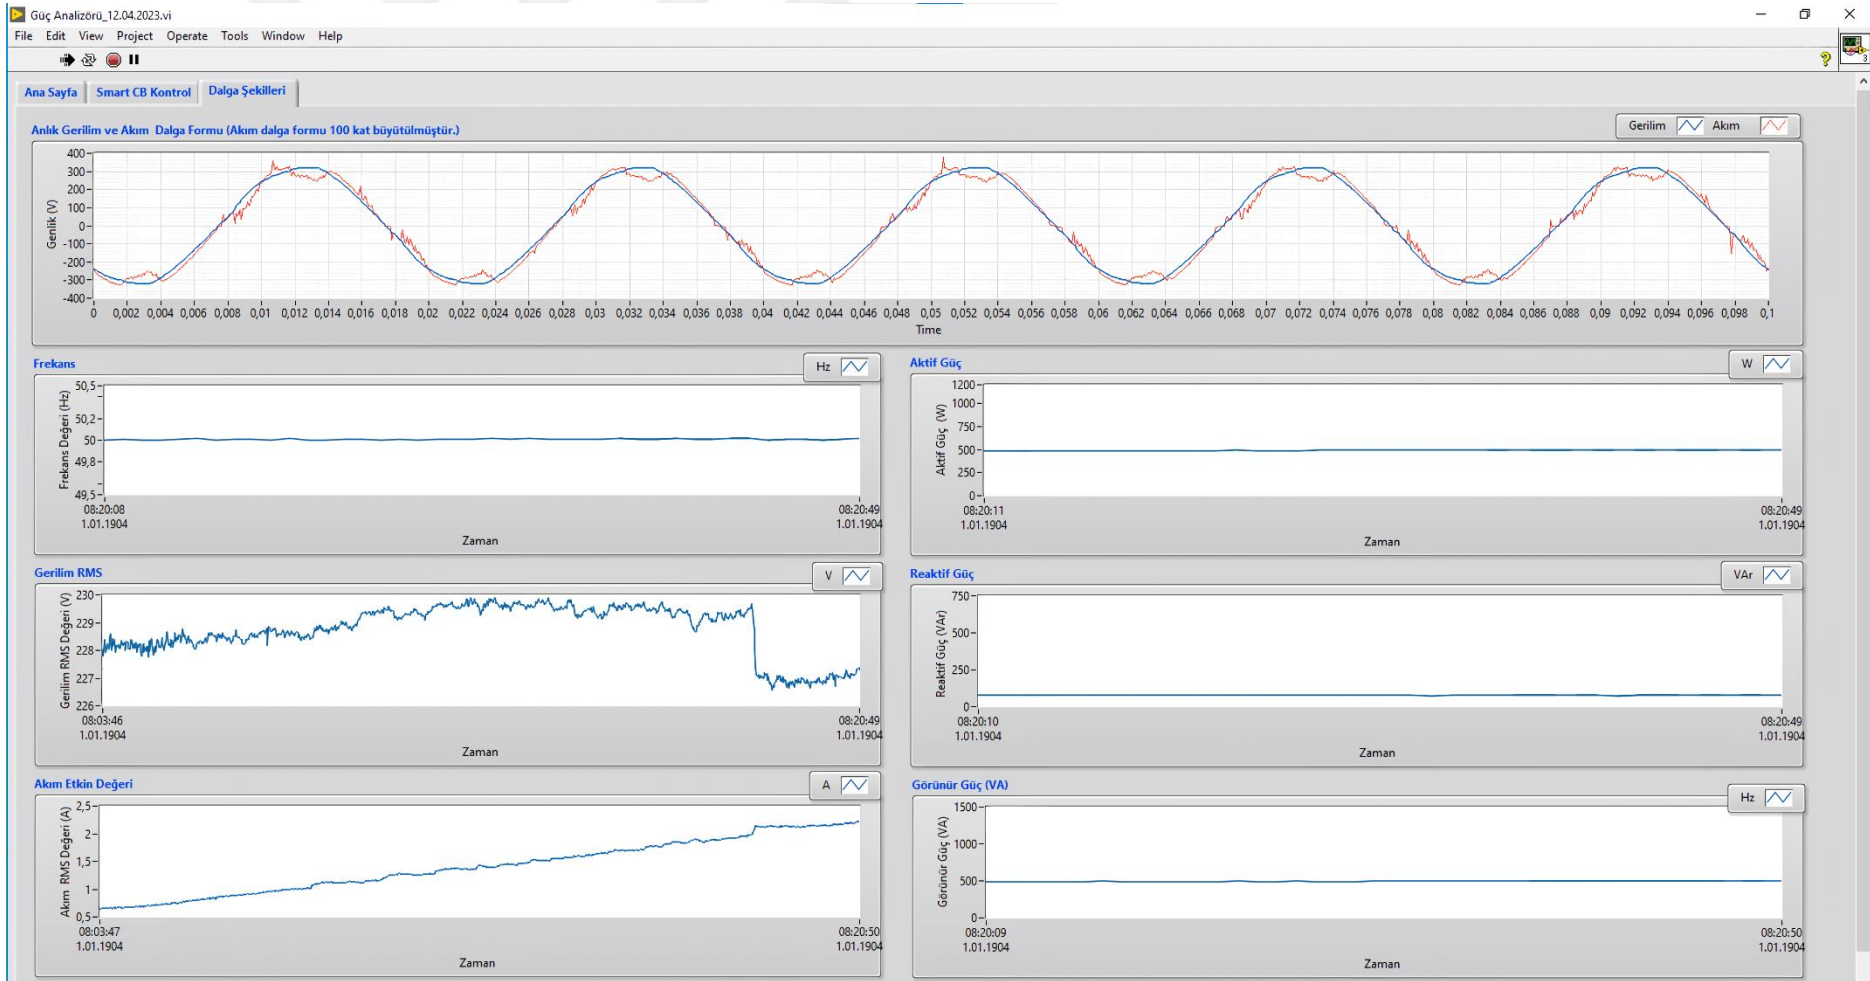


Şekil 4.11 : Deneysel sistem (ayrıntılı görünüm).

Elektriksel verilerin izlendiği ve aynı zamanda kontrol edildiği LabVIEW ortamında oluşturulan yazılımın ara-yüzü Şekil 4.12’de gösterilmiştir. A bloğu, aktif olan devre kesicileri ve güç akışını belirtmektedir. B bloğu, gerilim ve frekans değerlerindeki değişim şebeke kodunda belirlenen eşik değerlerden saptığında alarm vermektedir. C bloğu inverter çıkışındaki gerilime ait THB, güç faktörü ve yük açısı gibi büyüklükleri göstermektedir. D bloğu ile gösterilen kısım ise gezinti sekmelerini göstermektedir. Ana sayfada izleme ile ilgili bloklar yer alırken CB kontrol sekmesinde devre kesicilerin kontrol edildiği ekran bulunmaktadır. Akım, gerilim, frekans ve güç parametreleriyle ilgili dalga formları ve grafikler ise “Dalga Şekilleri” sekmesinde yer almaktadır. E, F ve G blokları ile gösterilen bölümlerde, sırasıyla inverter, şebeke ve yerel yük tarafındaki elektriksel parametreler gözlemlenebilmektedir. H bölümünde bulunan durdurma butonu programın açılıp kapatılmasını sağlamaktadır. Şekil 4.12’de OBN’deki yükün hem şebekeden hem de FV sistemden beslendiği görülmektedir. Şebekeden çekilen güç (-) işaretle gösterilmiştir. Hem aktif hem de reaktif güçteki değişimler gerçek zamanlı olarak izlenebildiğinden AMOD tespitinde önemli bir parametre olan minimum güç uyumsuzluğundaki doğruluk testi de bu deneysel kurulum ile simüle edilebilmektedir. Şekil 4.13’te ise “Dalga Şekilleri” sekmesi içeriği görülmektedir.




Şekil 4.12 : Test sistemi izleme ve kontrol arayüzü (ana sayfa).



Şekil 4.13 : Test sistemi izleme ve kontrol arayüzü (dalga şekilleri sekmesi).

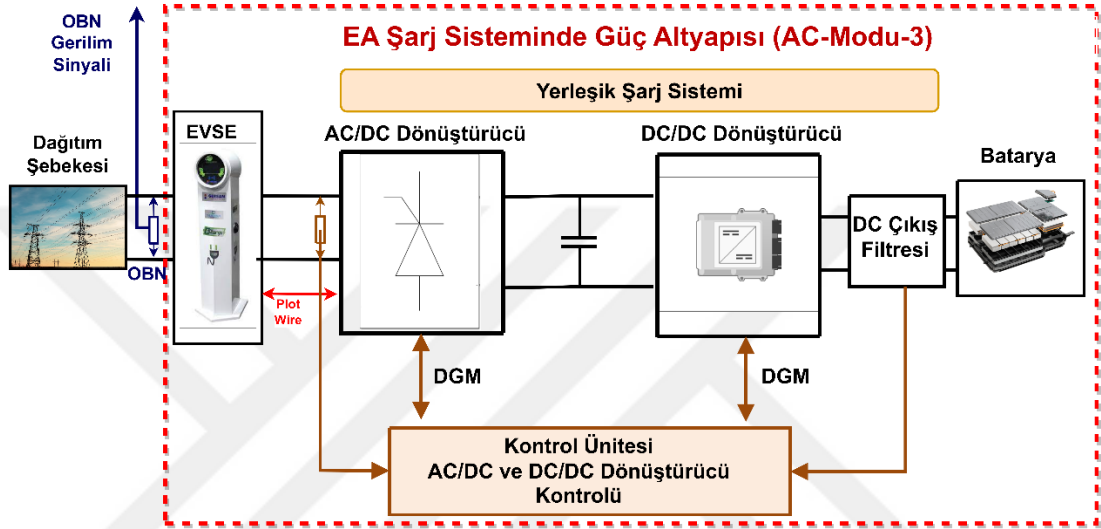
4.3.2 AMOD olmayan (GKO) verilerinin toplanması

İzleme ve kontrol panosunda bulunan diğer SSR'ler GKO olaylarının üretilmesinde kullanılmıştır. Geliştirilen panodan, tek fazlı 1 hp (746 W) asenkron motor, sürücü üzerinden bağlı 1,1 kVA 3-fazlı asenkron motor, 2 adet 3,7 kW (1x16 A) AC Mod-3 EA şarj cihazları, kapasite grupları ve doğrusal/doğrusal olmayan diğer yükler (40 mF kapasite bankası, 50 Ω ve 63 mH RL yükü) Şekil 4.12'de verilen arayüze sahip yazılımla kontrol edilerek GKO senaryoları oluşturulmuştur. EA şarj cihazı, EA'ya Tip 2 konektör ile bağlanmıştır. Tipik endüstriyel yükler devreye alınarak veya devreden çıkarılarak GKO'lar üretilebilir. Bu yüklerle çökme, sıçrama, geçici olaylar, harmonikler, çentikler vb. olayları üretilebilmektedir. Üretilen verilerin parametreleri, integral tabanlı yöntemle matematiksel model tarafından üretilen verilerle örtüşmektedir. OBN'de ölçülen gerilim sinyali EÖK ile DAQ kart girişine uygulanır. Matematiksel ve simülatif verilerle benzer olarak bu sistemde örnekleme frekansı 10 kHz olarak seçilmiştir. Gerilim sinyali 0,2 saniye boyunca ölçülür ve 2000 noktadan oluşmaktadır. GKO verilerinin üretimi için kullanılan test sistemi Şekil 4.14'te verilmiştir.



Şekil 4.14 : Doğrusal/doğrusal olmayan yüklerden oluşan deneysel kurulum.

Yerleşik şarj ünitesine sahip tipik bir EA cihazına bağlantısı yapılan AC Mod-3 şarj sisteminin blok diyagramı Şekil 4.15'te verilmiştir. Yerleşik şarj cihazına sahip EA'lar, araç içindeki dönüştürücüler ile AC enerjiyi doğrultarak batarya şarjını gerçekleştirir. EA besleme ekipmanına (EVSE) sahip AC Mode-3 EA şarj cihazları, şebekedeki AC enerjinin EA'lara aktarılmasından sorumludur. Bu yapıda tasarlanan EA şarj istasyonları, şarj soketi algılama, EA ile haberleşme, şarj hızı kontrolü ve güvenlik gibi işlevleri yerine getirir.



Şekil 4.15 : AC-Mod-3 şarj ünitesi blok diyagramı.

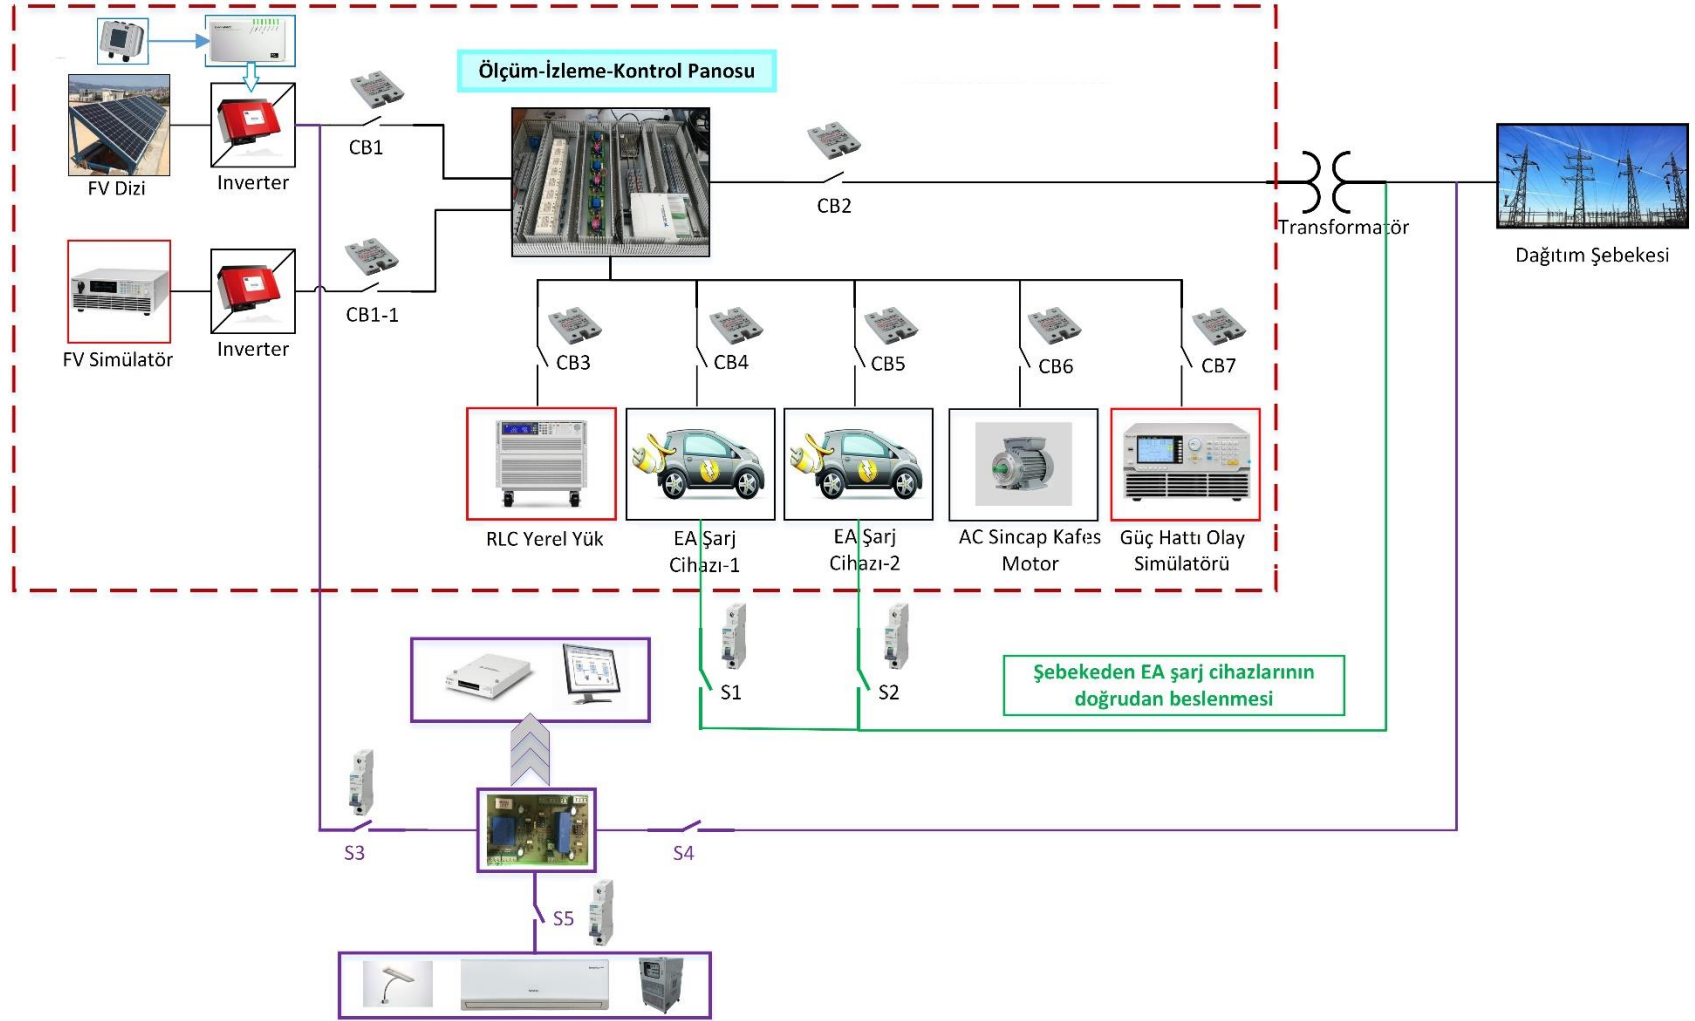
Bir EVSE kontrol sistemi temel olarak bir yardımcı güç kaynağı, kaçak akım algılama, iki yönlü iletişim, röleler/kontaktörler ve bir kullanıcı arabiriminden oluşur. EA şarj cihazlarındaki tüm fiş tiplerinde iki ek sinyal bulunur: kontrol pilotu (control pilot-CP) ve yakınlık pilotu (proximity pilot-PP). Şarj başlamadan önce EVSE, PP aracılığıyla bir AC şarj fişinin varlığını bildirir. Ayrıca PP, şarj düzeneğinde kablo akım derecesini sağlayabilir. Ayrıca kablo, mevcut derecesini PP'de farklı dirençlerle EA ve EVSE'ye de gösterebilir. EVSE ve EA arasındaki haberleşme, CP sinyalleri ile gerçekleşir. Eşleşen fişin tespiti, EVSE'nin güç sağlamaya ve EA'nın şarj gücünü kabul etmeye hazır olup olmadığı ve havalandırma gereksinimleri CP işlevleri tarafından gerçekleştirilir. EVSE, darbe genişlik modülasyonu (DGM) sinyali üretme görevi aracılığıyla EA'nın kullanabileceği mevcut kapasitesini gösterir. AC-Mod 3 sistemi, IEC 62196 [147] ve IEC 61851 [148] standartlarına uygun olmalıdır. Gerilim sinyali OBN'den alınmış ve AC-DC dönüştürücü ile DC gerilime dönüştürülmüştür. Bu gerilim, DC bara kapasitesi aracılığıyla DC-DC dönüştürücüye aktarılır. Filtrelemeden sonra dönüştürücü çıkışındaki gerilim EA bataryasına iletilir. Bu sistem düşük bir

gerçek güç faktörüne sahiptir ve giriş akımında anahtarlama ve harmonik oluşumu nedeniyle çentik oluşumuna neden olur. Veri setinin oluşturulmasında Mod 3 şarj cihazlarının özellikleri de dikkate alınmıştır. Ancak çalışmada kullanılan Mod 3 EA şarj cihazları, CP ve PP protokollerini ve standartları takip eden bir iletişim sistemini içermektedir. Bu nedenle standartlarla belirlenen bir akım değeri için EVSE ile EA arasında güç aktarımı sağlanır. Dışarıdan müdahale mümkün olmadığından, gözlenen GKO olayları sınırlı sayıda elde edilebilir. Yenilenebilir Enerji Sistemleri ve Akıllı Şebekeler (RES&SGs) Laboratuvarı ve sisteminin dıştan görünümü Şekil 4.16’da verilmiştir.



Şekil 4.16 : EA şarj sistemleri.

Yenilenebilir Enerji Sistemleri ve Akıllı Şebekeler (RES&SGs) Laboratuvarında bulunan test sisteminin genel şeması Şekil 4.17’de gösterilmiştir. Senaryolarda, üretim tarafı için sundurma üzerinde kurulu FV dizisiyle beraber Chroma firmasının 62000S-H serisine ait FV dizisi simülatörü DC güç kaynağı da kullanılmaktadır. FV inverter cihazlarında maksimum güç noktası izleme performans değerlendirmesi için de kararlı ve hızlı bir geçici tepki tasarımına sahiptir. Çalışmada, özellikle minimum güç uyuşmazlığının yakalanması ve FV dizinin hava şartlarına bağlı üretim sağlayabilmesi nedeniyle tercih edilmiştir. Pano üzerinden devre kesicilerle kaynaklar arasında geçiş yapılabilmektedir. Bununla birlikte sistem yerel yükleri beslemek için de S3 sigortası yardımıyla kullanılabilir. AMOD test sistemiyle birleşik olan planda güç sisteminde meydana gelen olaylar ve arızalar gerçekleştirilebilmektedir.




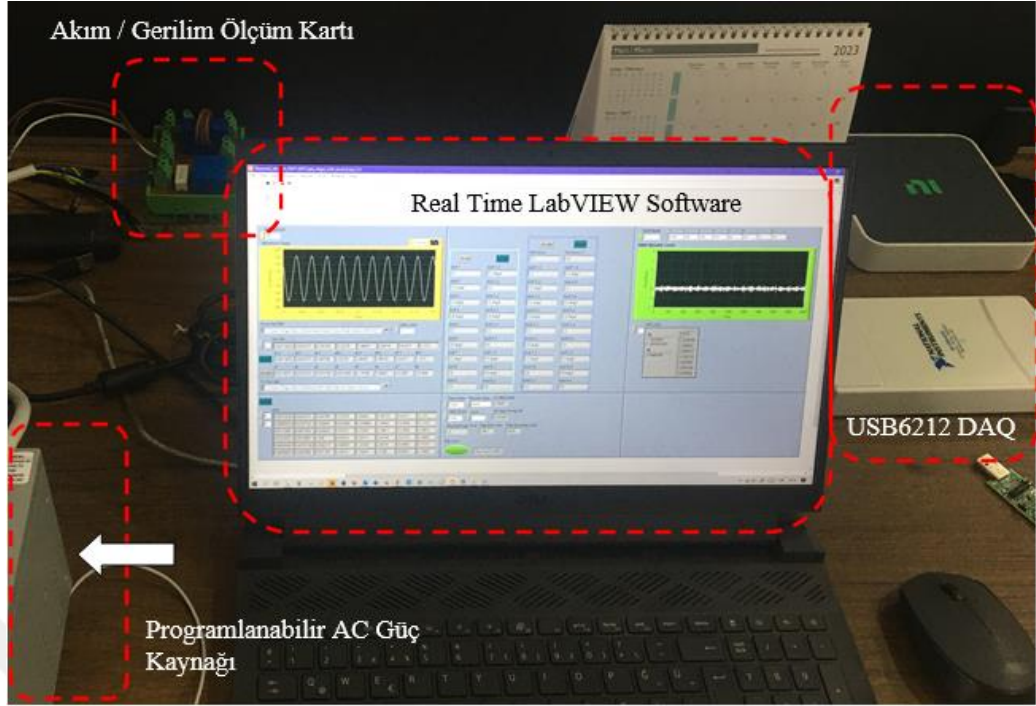
Şekil 4.17 : BTU Yenilenebilir Enerji Sistemleri ve Akıllı Şebekeler Laboratuvarı genel şeması.

4.4 Ayarlanabilir AC Kaynak ile Veri Üretimi

Deneysel test sistemi ile üretilen verilerin sınırlı olması nedeniyle Chroma AC 61501 serisi ayarlanabilir AC kaynak ile de veri üretimi gerçekleştirilmiştir. 61501 serisi bu cihaz, 0-300 V arasında AC dalga formu üretebilir, 15 Hz - 1 kHz arasında sinyal oluşturabilir ve 500 VA maksimum güce sahip tek fazlı bir cihazdır. Benzer şekilde EÖK ile alınan sinyaller DAQ karta aktarılmış ve endüstriyel PC yardımıyla oluşturulan yazılımla kaydedilmiştir. Benzer şekilde, sistemde örnekleme frekansı 10 kHz olarak seçilmiştir. Gerilim sinyali 0,2 s boyunca ölçülür ve 2000 noktadan oluşmaktadır.

Chroma AC 61501 serisi güç kaynağı, gerilim sıçraması/çökmesi/kesintisi, darbeleri geçici durum olayları gibi farklı GKO'ları simüle etmek için gelişmiş özellikler sağlamaktadır. STEP ve PULSE modları ile çıkış değişiklikleri kontrol edilebilir ve tekrarlanabilir bir şekilde gerçekleştirilebilir. Bu modlar, iç zamanlayıcı veya harici bir sinyal tarafından tetiklenebilmesi farklı GKO senaryolarının oluşturulmasını kolaylaştırır. Bu özellikler, güç elektroniği cihazlarının farklı GK koşullarında performansını test etmek ve doğrulamak için de kullanılabilir.

Chroma AC 61501 serisi güç kaynağı ile IEC 61000-4-11 ön uygunluk testleri için tüm gerilim çökmeleri, kesintileri ve sıçrama dalga formları simüle edilebilir. Geleneksel AC kaynaklar, yalnızca temel frekansın tamsayı katlarını birleştirerek periyodik harmonik bozulma dalga biçimleri oluşturabilir. Ancak, standartlar (IEC 61000-4-13, IEE 519) sadece harmonik dalga formlarının değil, aynı zamanda ara harmonik dalga formlarının da simülasyonunu gerektirir. Bu doğrultuda, Chroma AC güç kaynağı 61500 serisi hem harmonik hem de ara harmonik dalga biçimlerini sentezleyebilir, bu da periyodik olmayan harmonik bozulma dalga biçimleri oluşturulmasına imkan tanır.



Şekil 4.18 : Chroma AC 61501 serisi güç kaynağı yardımıyla veri üretimi.

5. ÖNERİLEN AMOD OLAYLARINI TESPİT YÖNTEMİ


Bu bölümde, öncelikle geleneksel DD dönüşüm yöntemi ile AMOD tespit yöntemleri tartışıldıktan sonra önerilen ÖİDD-Tabanlı AMOD tespit yöntemi detaylandırılmıştır. Filtre bankaları ile hızlı bir şekilde uygulanan sinyal-analiz tabanlı yöntemler karşılaştırılmıştır. Elde edilen bulgular, piramidal algoritma ile gerçekleştirilen ÖİDD'nin geleneksel metotların dezavantajlarını ortadan kaldırdığını göstermektedir.

5.1 SDD ile AMOD Tespiti

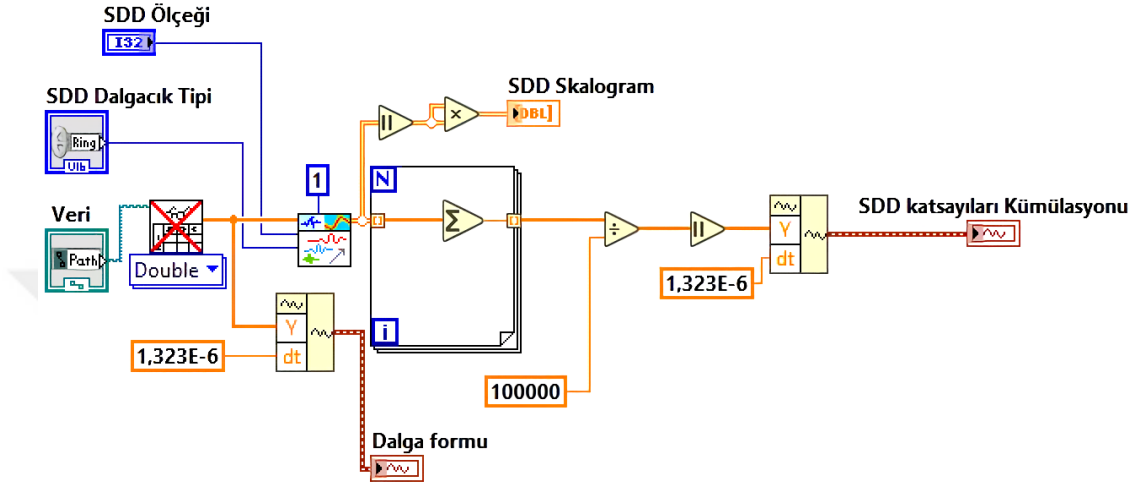
Şekil 5.1 (a), geleneksel SDD-Tabanlı AMOD tespit yönteminin akış şemasını göstermektedir. Bu yöntemde, son aşamada belirlenen eşik değere göre arızanın AMOD mu yoksa başka bir olay mı olduğuna karar verilmektedir. OBN noktasından EÖK ve DAQ kart yardımıyla alınan gerilim sinyaline, db8 ana dalgacığı kullanılarak ayrıştırma işlemi uygulanmaktadır. Daha sonra, ayrıştırma sonucunda elde edilen SDD katsayılarının kareleri hesaplanır ve bir skalogram grafiği elde edilir. Aynı zamanda, katsayılar, arıza zamanını tespit etmek için arıza anındaki tepe değerini belirlemek üzere ölçek ekseninde toplanır. Şekil 5.1 (b), SDD yönteminin LabVIEW blok diyagramını göstermektedir.

5.2 ADD ile AMOD Tespiti

Şekil 5.2, geleneksel ADD-Tabanlı AMOD tespit yönteminin akış şemasını göstermektedir. OBN noktasındaki gerilim sinyali, SDD-Tabanlı yöntemde olduğu gibi DAQ kartı kullanılarak gerçek zamanlı olarak LabVIEW yazılımı yüklü endüstriyel PC'de ayrıştırma işlemine tabi tutulmaktadır. İki seviyeli olarak db8 ana dalgacığı ile gerçekleştirilen ayrıştırma sonucunda her filtre çıkışındaki örnek sayısı yarıya düşmektedir. Son aşamada, belirlenen eşik değere göre arızanın AMODu olup olmadığına karar verilmektedir. Farklı benzetim çalışmaları ve gerçek uygulamalar yapılmış olup AMODu tespiti için kullanılan dalgacık tipi, örnekleme frekansı, ayrıştırma seviyesi ve eşik değerler için optimal parametreler belirlenmiştir. Bölüm 5.4'te parametre seçimi detaylandırılmıştır.




(a)



(b)

Şekil 5.1 : (a) SDD ile eşik değer-Tabanlı yöntem akış diyagramı, (b) SDD yönteminin LabVIEW blok diyagramı.



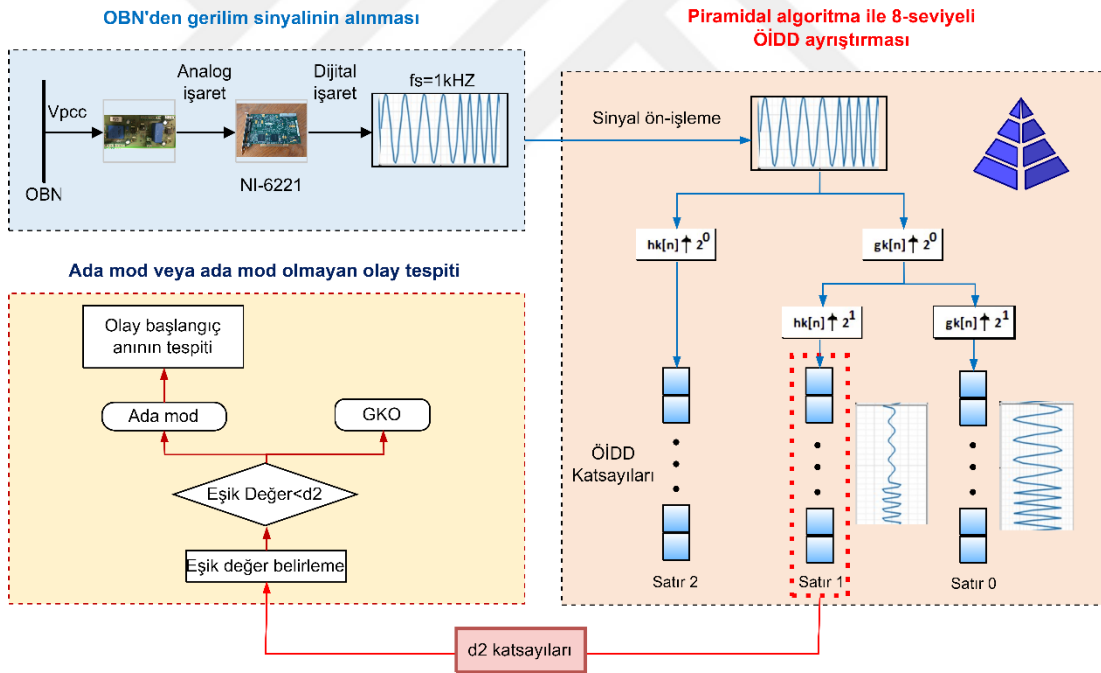
Şekil 5.2 : ADD ile Eşik Değer-Tabanlı yöntem akış diyagramı.

5.3 Önerilen Piramidal ÖİDD-Tabanlı AMOD Tespiti

Önerilen yöntem iki adımdan oluşmaktadır: 1) Olay sinyali piramidal ÖİDD kullanarak iki seviyeye ayrıştırılır, 2) Belirlenen eşik değere göre olayın, AMOD olup olmadığına karar verilir. Önerilen yöntem, sinyaldeki salınımları azaltır, eşik değerleri kolayca seçilebilir hale getirir ve gürültüye karşı hassasiyet diğer DD yöntemlerine göre daha düşüktür. Ayrıca, ÖİDD ayrıştırması ile elde edilen katsayılar, her ölçekte

aynı sayıda katsayıya sahip bir zaman serisini temsil eder. Bu özellikler nedeniyle, sinyallerin gizli bilgileri ve zaman-frekans konumları belirlenebilir.

Piramidal algoritma kullanılarak gerçekleştirilen ÖİDD-Tabanlı AMOD tespit yöntemi için akış şeması Şekil 5.3'te verilmiştir. Süreç, diğer DD yöntemlerine benzer şekilde veri toplama kartı tarafından OBN'de gerilim sinyalinin edinilmesi ile başlar ve bu sinyale 2 seviyeli bir ayrıştırma işlemi uygulanır. İki seviyeli olarak db8 ana dalgacığı ile gerçekleştirilen ayrıştırma sonucunda her filtre çıkışı sabit sayıda katsayıda oluşmaktadır. Son aşamada, belirlenen eşik değere göre hatanın AMODu olup olmadığına karar verilmektedir. Şekilde, 2^{j-1} sıfır eklenerek her dekompozisyon ölçeğinde modifiye edilen ÖİDD filtreleri gösterilmektedir. Bu sayede, piramidal ÖİDD ile örnekleme azaltma işlemi ortadan kalkmaktadır. ÖİDD katsayıları, Denklem 3.20'deki gibi tanımlanabilir ve daha verimli bir hesaplama yapılabilir. Bu algoritma, ölçekleme katsayılarına dayanır ve ÖİDD filtreleri ile her ayrıştırma aşamasında K_j genişliğinde yukarı örnekleme yapılmaktadır.

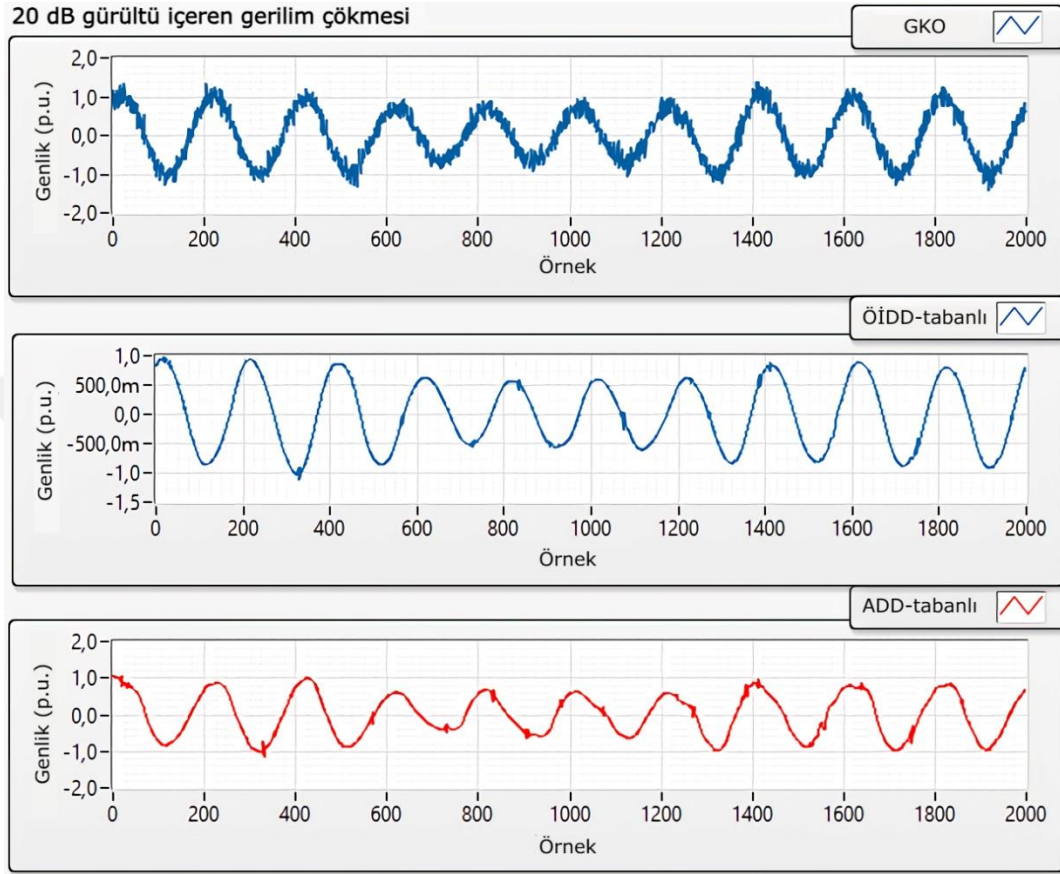


Şekil 5.3 : Önerilen Piramidal ÖİDD-Tabanlı yöntem akış diyagramı.

5.3.1 ÖİDD ayrıştırmasının avantajları


Diğer DD yöntemleriyle karşılaştırıldığında, ÖİDD yönteminin gürültü azaltma, tepe veya çukur tespit etme ve gerçek zamanlı sinyal analizi gibi konularda avantajları vardır [87]. Şekil 5.4, gerilim çökmesi sinyali için ÖİDD ve ADD-Tabanlı gürültü

azaltma yöntemlerinin sonuçlarını göstermektedir. LabVIEW Wavelet Denoise Express VI bloğunu kullanarak yapılan analizde, db4 dalgacığı kullanılarak 8 seviyeli ayrıştırma uygulanmıştır. ÖİDD-Tabanlı gürültü azaltma işlemi sonucunda, ADD-Tabanlı yöntemle kıyasla daha başarılı bir sonuç elde edilmiştir.



Şekil 5.4 : DD-Tabanlı gürültü azaltma yöntemlerinin karşılaştırılması.

Şekil 5.5'te, ÖİDD-Tabanlı ve ADD-Tabanlı tepe/çukur tespit yöntemlerinin doğruluğu geçici durum olay sinyali için incelenmektedir. Tepe için eşik değeri 1 p.u. olarak belirlenmiş ve vadi için ise 0 p.u. olarak ayarlanmıştır. ÖİDD ile yapılan olay tespit işlemi, ADD yöntemine kıyasla daha güvenilir bir şekilde gerçekleşmektedir. Bunun nedeni, ÖİDD ayrıştırmasının ilk aşamada düşük çözünürlüklü sinyallerde sıfır geçiş noktasını bulması ve aynı işlemi daha yüksek çözünürlüklü katsayılara uygulamasıdır. Sıfır geçişlerinin tespiti, düşük çözünürlüklü katsayılara uygulandığında gürültüyü azaltırken, yüksek çözünürlüklü katsayılara uygulandığında en yüksek genlikteki konumların tespit hassasiyetini artırır. Ek olarak, ÖİDD gerçek zamanlı sinyal analizine imkan verir. Bu özellik, gerçek zamanlı uygulamalarda sinyallerin etkili bir şekilde analizini sağlayarak zamanında ve doğru sonuçlar elde edilmesini mümkün kılar.



Şekil 5.5 : DD-Tabanlı tepe/çukur tespit yöntemlerinin karşılaştırılması.

5.4 DD Yöntemlerinde Parametre Seçimi

ÖİDD ayrıştırmasının performansı doğrudan ayrıştırma seviyesi, seçilen dalgacık tipi ve belirlenen eşik değerlerle doğrudan ilgilidir. AMOD tespit süresini minimuma indirmek için veriler 1 kHz ile örneklenmektedir. Ayrıca seçilen parametreler, karmaşıklık, hesaplama yükü ve işlem süresi gibi etkenler göz önüne alınarak gerçekleştirilen çok sayıda test sonucunda belirlenmiştir.

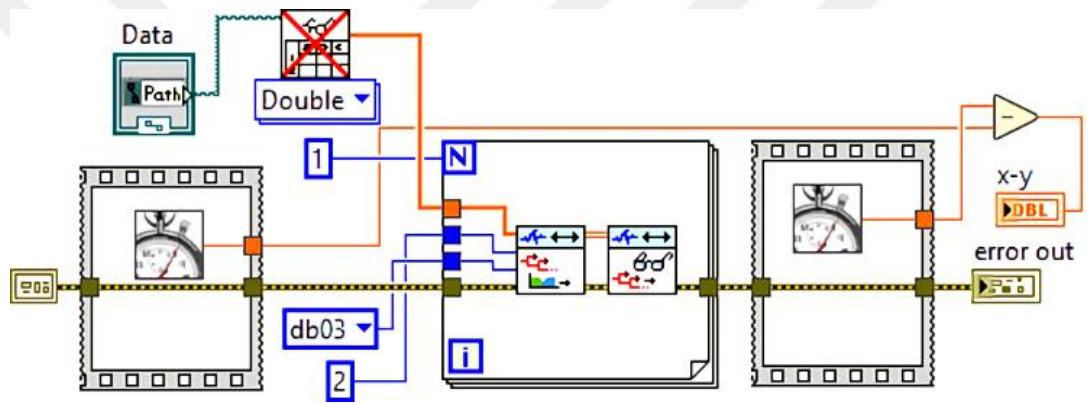
5.4.1 Ana dalgacık seçimi

AMOD sinyalleri kısa süreler için yüksek frekans bileşenlerine sahiptir. Bu özellikleri gösteren en uygun dalgacık türü, literatürde araştırıldığında "dbN" dalgacık ailesidir [9]. Şekil 5.6'da gösterildiği gibi dbN'nin katsayısı arttıkça dalgacık işlevi daha pürüzsüz hale gelir.



Şekil 5.6 : Daubechies dalgacık ailesi örnekleri (db4, db8 ve db12).

AMOD tespitinde, ana dalgacık seçerken düşük ölçeklerde daha iyi zaman konumlandırması sağlamak önemlidir. Bu çalışmada, dalgacık türünü tanımlamak için farklı simülasyon ve deneysel testler yapılmıştır. Kaydedilen veriler üzerinde gerçekleştirilen ÖİDD ayrıştırması ile detay katsayılarının elde edilmesi için hesaplama süreleri, Şekil 5.7'de verilen alt program kullanılarak ölçülmüştür. Farklı dalgacık tipleri için belirlenen hesaplama süreleri Çizelge 5.1'de verilmiştir. Çalışmada, db8 ana dalgacı, AMOD durumunun özelliklerini gösterdiği için seçilmiştir [64, 65]. Aynı zamanda, db8 ana dalga biçimi, az sayıda örneği olan kısa bir dalga biçimini içerdiği için hesaplama süresini de azaltmıştır. db8 için ölçülen hesaplama süresi 0,0134104 s'dir ve gerçek zamanlı sistem performansı için uygun bir süredir.



Şekil 5.7 : Dalgacık türleri için süre hesaplamada kullanılan blok diyagramı.

Çizelge 5.1 : Farklı dalgacık türleri için hesaplama süreleri.

Dalgacık Tipi	Hesaplama Süresi (s)	Dalgacık Tipi	Hesaplama Süresi (s)
db	---	db08	0.0134104
db02	0.0118995	db09	0.0141892
db03	0.0120056	db10	0.0147398
db04	0.0123345	db11	0.0151829
db05	0.0127549	db12	0.0158798
db06	0.0130931	db13	0.0164289
db07	0.0132104	db14	0.0169797
db	---	db08	0.0134104

Deneysel çalışmalar, ADD ve ÖİDD-Tabanlı yöntemler ile AMODu tespiti için iki seviyeli ayrıştırmanın yeterli olduğunu göstermektedir. İki seviyeli dalgacık analizi için katsayı bileşenlerinin (detay ve yaklaşım) frekans aralıkları Çizelge 5.2’de gösterilmektedir.

Çizelge 5.2 : Farklı dalgacık türleri için hesaplama süreleri.

Seviye	Katsayı	Frekans Aralığı
1	Detay 1 (d1)	250-500 Hz
2	Detay 2 (d2)	125-250 kHz
2	Yaklaşım 2 (a2)	0-125 Hz

5.4.2 Eşik değeri seçimi

AMOD tespit yöntemlerinde, özellik seçimi ile elde edilen değeri belirlenen eşik değeriinden daha küçükse, bu durum AMOD olmayan sinyal kategorisine girer; aksi takdirde, bu olay bir ada durumu olarak kabul edilir. Tez çalışmasında, ADD ve ÖİDD için gerilim sinyalinin ayrıştırma işlemi sonucunda elde edilen d2 katsayısı kullanılırken, SDD için dalgacık katsayılarının birikimi olay tespiti için bir kriter olarak kullanılmaktadır. 125-250 kHz arasındaki frekans bandı bilgisini içeren d2 katsayılarındaki değişimler, şebeke bağlantısının kesildiği durumlarda oldukça gözlemlenebilir. Bununla birlikte, AMOD olmayan çalışma koşullarında gerilim sinyallerindeki değişiklikler detay katsayılarında gözlemlenebilir değildir. Eşik değeri belirlenmesi için yapılan testler, farklı güç uyumsuzluklarında ada senaryolarını ve güç kalitesi olaylarını içermektedir. Şebeke bağlantılı FV-Tabanlı sistem, birim güç faktöründe çalışmakta olup, 50 Hz’de (rezonans frekansı) paralel bir RLC yükü, ada koşullarını tespit etmek için en kötü senaryo olarak kabul edilmektedir. Bu senaryo için test yapıldıktan sonra, reaktif güç ve aktif güç değerleri için güç uyumsuzluğu artırılarak testler devam ettirilmiştir. Farklı GKO olayları için de önerilen yöntemin tepkisi gözlemlenmiştir.

DD yöntemlerinde, d2 katsayısı için ÖİDD ve ADD ayrıştırmasıyla deneysel çalışmalar kullanılarak elde edilen en uygun eşik değeri 0.021 olarak belirlenmiştir. Bununla birlikte, SDD için detay katsayılarının kümülatif birikimi için en uygun eşik değeri 0.002 olarak belirlenmiştir.

5.5 Deneysel Sonuçlar

SDD, ADD ve önerilen ÖİDD-Tabanlı yöntem için farklı AMOD senaryolarında performans testleri gerçekleştirilmiştir. Ayrıca, GKO'ların AMOD koşullarıyla karıştırılması durumunda şebeke bağlantılı FV sistemler hizmet dışı kalabilir ve bunun sonucunda hatalı kesici açması ile büyük bir elektrik kesintisi yaşanabilir. Ekonomik kayıpların önüne geçmek ve sistem arz güvenliğinin sağlanabilmesi için AMOD ve AMOD olmayan koşulları doğru bir şekilde tespit etmek ve ayırt etmek son derece önemlidir.

Geleneksel DD-Tabanlı yöntemlerle önerilen piramidal ÖİDD-Tabanlı yöntem, farklı güç uyuşmazlıklarındaki AMOD koşulları için Bölüm 5.5.1'de test edilmiştir. Bununla birlikte, önerilen yöntemin güvenilirliğini kanıtlamak için piramidal ÖİDD'nin GKO sinyallerine karşı tepkisi Bölüm 5.5.2'de incelenmiştir.


5.5.1 AMOD koşullarının tespiti

Senaryo-1-Minimum güç uyuşmazlığı ($\Delta P \approx 0$): Şebeke bağlantılı FV sistem minimum güç uyuşmazlığı ($\Delta P \approx 0$) olduğu durumda, Şekil 4.9'da gösterilen test sistemindeki şebeke tarafındaki kesici (CB2) açılarak şebekeden izole edilmiştir. Bu durumda FV sistem çıkış gücü (inverter çıkış gücü P_{FV}) 1025 W'tır. Paralel RLC yükünün yaklaşık gücü ($P_{yük}$) 1025 W olarak güç analizör yazılımıyla hesaplanmıştır. Şekil 5.8'de gösterilen ada durumu, 120. ms'de başlamaktadır. SDD, ADD ve önerilen ÖİDD tabanlı yöntemlerin bu senaryodaki performansı şekilde gösterilmektedir. DD-Tabanlı yöntemler için eşik değerler grafikteki kırmızı bir çizgiyle gösterilmiştir. Kesicinin aktiflik durumu ise siyah renk ile gösterilmektedir. Durum lojik 0 olduğunda kesici (CB) aktif değilken lojik 1 olarak ayarlandığında CB aktif olur. Önerilen yöntemde, AMOD algılanıp kesici açma yapana kadar geçen toplam süre yaklaşık 75 ms'dir.


Senaryo-2-Gürültü altında minimum güç uyuşmazlığı ($\Delta P \approx 0$, SNR = 20 dB): Bu durumda, şebeke bağlantılı FV sistem minimum güç uyuşmazlığı olduğu durumda oluşturulan AMOD gerilim sinyali gürültü içermektedir. Bu sinyale, herhangi bir gürültü azaltma işlemi gerilim sinyaline uygulanmamıştır. Gürültülü ortamda ada durumu Şekil 5.9'da gösterilmekte ve geliştirilen yazılımda önerilen ÖİDD-Tabanlı ada tespit yönteminin performansı sunulmaktadır. Bu durum, geleneksel yöntemlerde

ADB alanı içinde kalan bir durum iken, önerilen yöntemle güvenilir bir şekilde tespit edilebilmiştir.


Gerilim Grafiği




ADD 2. Seviye Detay Katsayıları (d2)



ÖİDD 2. Seviye Detay Katsayıları (d2)



SDD Katsayıları Kümülasyonu

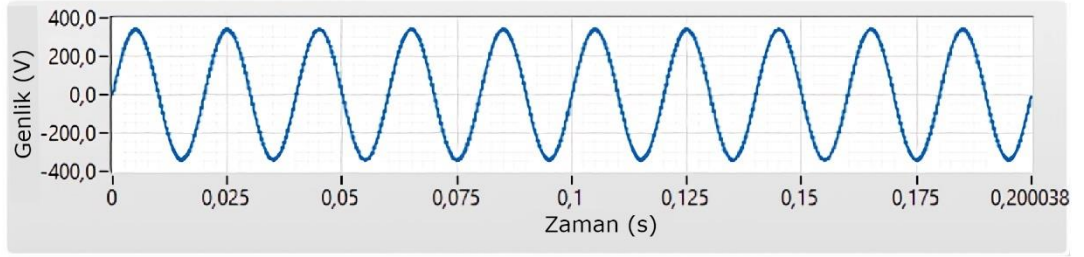


Şekil 5.8 : Senaryo-1 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.


Senaryo-3-Yüksek güç uyuşmazlığı ($\Delta P \ll 0$): Bu senaryoda, şebeke bağlantılı FV sistem yüksek güç uyuşmazlığı ($\Delta P \approx -33\%$) olduğu durumda, Şekil 4.9'da gösterilen test sistemindeki şebeke tarafındaki CB2 açılarak izole edilmiştir. Senaryo gerçekleştirilirken FV sistem çıkış gücü 790 W'tır. Yükün aktif gücü ise $(229 \text{ V})^2 / 50 \Omega = 1048 \text{ W}$ olarak güç analizörü yazılımıyla hesaplanmıştır. Güç uyuşmazlığı (ΔP) /

$(\Delta P) / P_{Load} = \frac{790 W - 1048 W}{1048} W \approx -33\%$ 'tür. AMOD olayı, sistem sürekli durum koşullarını sağladıktan 0,1 saniye sonra meydana gelmektedir. LabVIEW ile gerçekleştirilen ara-yüz programı ile tüm DD yöntemleri aynı anda analiz edilebilmektedir. Şekil 5.10, ÖİDD ve SDD'nin ayrıntı katsayılarını göstermektedir ve ada durumu bu iki yöntemle doğru şekilde tespit edilmiştir. ADD'nin d2 katsayıları incelendiğinde, bunun bir ada durumu olarak kabul edilemeyeceği ($d2 < \text{eşik değeri}$) görülmektedir.


Gerilim Grafiği




ADD 2. Seviye Detay Katsayıları (d2)



ÖİDD 2. Seviye Detay Katsayıları (d2)




SDD Katsayıları Kümülayonu




Şekil 5.9 : Senaryo-2 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.


Gerilim Grafiği




ADD 2. Seviye Detay Katsayıları (d2)



ÖİDD 2. Seviye Detay Katsayıları (d2)



SDD Katsayıları Kümülasyonu




Şekil 5.10 : Senaryo-3 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.

5.5.2 AMOD olmayan koşullarda yöntem performansı


Senaryo-4-Kısa devre arıza durumu: Kısa devre arızaları şebeke bağlantılı FV sistemlerinde önemli bir sorun olup geçici arızaların AMOD koşullarıyla karıştırılmaması gerekir. Bu senaryoda, arıza 0,1'inci saniyede başlamakta olup kısa devre arıza direnci 0,7 ohm olarak belirlenmiştir. Şekil 5.11'de tüm DD yöntemlerinin arızaya verdiği tepkiler zamana göre verilmiştir. Şebeke tarafındaki arıza sonucunda OBN'de gerilim düşmesi meydana gelmiştir. Arıza başlangıcında, FV sistem çıkış

gücü 1025 W'tır ve yerel RLC yükü 975 W aktif güç çekmektedir. Önerilen ÖİDD yönteminde, detay katsayısı tepe değerinin 0,015 olduğu görülmektedir ve bu değer deneysel testlerle belirlenen ada durumu eşik değerinin altındadır. ADD kullanılan yöntem de kısa devre arızasına benzer tepki vermektedir.


Gerilim Grafiği




ADD 2. Seviye Detay Katsayıları (d2)



ÖİDD 2. Seviye Detay Katsayıları (d2)



SDD Katsayıları Kümülasyonu




Şekil 5.11 : Senaryo-4 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.


Senaryo-5-Kapasite bankı anahtarlanması durumu: Sistemde kapasite bankı anahtarlanması, gerilimde ve frekansta salınma neden olacağından bu durum AMOD olayları ile karıştırılabilir. Bu senaryoda, 0,4 kV and 500 VA güce sahip kapasite grubu

anahtarlanarak DD yöntemlerinin tepkileri gözlemlenmiştir. Şekil 5.12’de görüldüğü gibi kapasite bankası, 0,152’nci saniyede bir kesici yardımıyla devreye alınmıştır. Tüm DD yöntemlerinde elde edilen tepe değerleri belirlenen eşik değerinin altındadır ve bu durum AMOD olayı ile karıştırılmamıştır.


Gerilim Grafiği




ADD 2. seviye Detay Katsayıları (d2)



ÖİDD 2. seviye Detay Katsayıları (d2)



SDD Katsayıları Kümülasyonu

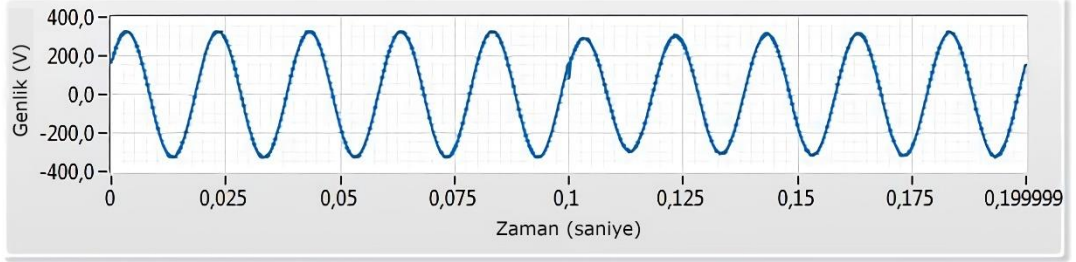


Şekil 5.12 : Senaryo-5 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.


Senaryo-6-Motor devreye alma durumu: AMOD tespit yöntemleri motor enerjilendirmesi esnasında hataya düşebilirler. Bu nedenle, 1,1 kW güce sahip bir asenkron motor, test sistemindeki ada koşullarını araştırmak için şebekeye bağlanmıştır. Motor başlatma durumunun deneysel sonucu Şekil 5.13'te gösterilmiştir.

Tek fazlı asenkron motor kesici yardımıyla $t = 0,1$ s'de devreye alınmıştır. Şekilde görüldüğü gibi, önerilen piramidal ÖİDD-Tabanlı yöntem asenkron motorların devreye alınma davranışlarına karşı hassas değildir. ÖİDD sonucu belirlenen $d2$ katsayısı tepe değeri belirtilen eşik değerinin altındadır. Buna karşılık, geleneksel ADD-Tabanlı yöntem bu duruma karşı hassastır ve yanlış AMOD durumu algılamaya neden olur.


Gerilim Grafiği




ADD 2. Seviye Detay Katsayıları (d2)



ÖİDD 2. Seviye Detay Katsayıları (d2)



SDD Katsayıları Kümülasyonu



Şekil 5.13 : Senaryo-6 için DD-Tabanlı AMOD tespit yöntemleri yanıtları.

Geleneksel yöntemde geniş bir alanda oluşan ADB, piramidal ÖİDD ile minimize edilmektedir. Önerilen yöntem hem düşük ADB sağlar hem de kısa tespit süresine

sahiptir. Çizelge 5.3, test sistemde incelenen kritik yük altındaki olaylar için katsayıların tepe değerlerini göstermektedir. ÖİDD ve SDD, tüm koşullarda ada durumunu tespit edebilir ve bu olayları diğer GKO'lardan ayırt edebilir. Ancak ADD ayrıştırması kullanan yöntem özellikle OBN'deki yerel yükün FV inverter çıkışından çok daha büyük olduğu durumlarda ada durumunu tespit edemez. Ayrıca, ADD kullanarak belirlenen eşik değerine göre motor devreye alma durumundaki olay sinyali yanlış bir şekilde AMOD olarak algılanabilmektedir.

Çizelge 5.3 : Çalışılan DD-Tabanlı yöntemler için katsayı tepe değerleri.

	ADD	Önerilen ÖİDD	SDD
Senaryo-1 Minimum güç uyumsuzluğu	0,02885	0,03347	0,00293
Senaryo-2 Minimum güç uyumsuzluğu (20 dB)	0,02925	0,03429	0,00295
Senaryo-3 Yüksek güç uyumsuzluğu ($\Delta P \ll 0$)	0,01698	0,03796	0,00314
Senaryo-4 Kısa devre arıza durumu	0,01478	0,01438	0,00187
Senaryo-5 Kapasite bankı anahtarlama	0,01324	0,01294	0,00046
Senaryo-6 Motor devreye alma durumu	0,03892	0,01715	0,00013

6. ÖNERİLEN GKO TESPİT VE SINIFLANDIRMA YÖNTEMLERİ

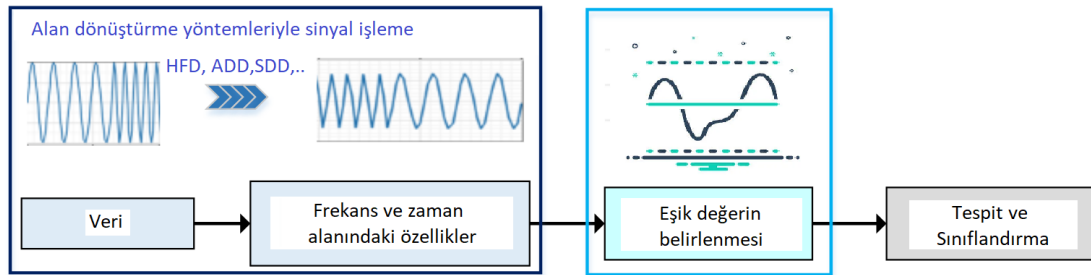
GKO'ların erken tespit edilmesi ve doğru bir şekilde sınıflandırılması, enerji şebekelerinin stabilitesini ve güvenilirliğini sağlamak açısından kritik bir öneme sahiptir. Bu bağlamda, önerilen GKO tespit ve sınıflandırma yöntemleri, geleneksel yöntemlere göre daha gelişmiş ve etkili sonuçlar sunmaktadır. Bölüm 6.1'de Tip-1 BKV ile GKO tespiti ve sınıflandırmasına ilişkin önerilen yöntem sunulmaktadır. BKV ile özellikle gürültülü sinyallerde ve benzer özellikler gösteren GKO olaylarındaki eşik değer probleminin önüne geçilirken az işlem yükü içeren ve yüksek doğruluğa sahip bir yöntem sunulmuştur. ÖİDD-Tabanlı öznelik çıkarımı ve çoklu sınıflandırıcı modelleri içeren hibrit yöntemler ise Bölüm 6.2'de sunulmuştur. Bu bölümde, farklı sınıflandırıcıların ADD ve önerilen ÖİDD yöntemleri için performansları detaylı olarak incelenmiştir. DD'ye dayalı olarak geliştirilen ancak gürültü altında performansı oldukça düşük olan sınıflandırıcıların performansı piramidal ÖİDD ile önemli ölçüde iyileştirilmiştir. Son olarak da GKO sınıflandırması için önerilen DÖ yöntemleri Bölüm 6.3'te irdelenmiştir. Burada, geleneksel üç aşamalı sürecin aksine, otomatik özellik çıkarma ve sınıflandırma için kapalı döngü derin ESA, UKSB ve hibrit (ESA-UKSB) modelleri kullanılmıştır ve daha karmaşık GKO olaylarını da içeren 19 sınıflık veri seti ile sonuçlar değerlendirilmiştir.

6.1 Tip-1 Bulanık Mantık Karar Verici ile GKO Tespiti ve Sınıflandırma

Geleneksel sinyal analizi-Tabanlı GKO tespit ve sınıflandırama yöntemlerinin akış şeması Şekil 6.1'de gösterilmektedir. Görüldüğü gibi bu yöntemlerde önce olay sinyaline alan dönüşümü yapılır ve sinyalin katsayıları/özellikleri çıkarılır. Daha sonra deneysel testler ile eşik değerler olay sınıfları için belirlenir ve öznelik parametrelerine göre GKO tespit edilir. Ancak DD gibi sinyal analiz yöntemlerinde önemli olan dalgacık tipi/seviye seçimi ve en önemlisi eşik değer seçimi ampirik testler sonucunda belirlenir. Eşik değer-Tabanlı uygulamalar, değer seçimindeki zorluklar ve gürültülü koşullardan kaynaklanan belirsiz durumlar nedeniyle yanlış algılama ve kaçırılan algılama eğilimleri gösterir. Bu, özellikle nominal olay ve arıza durumunun

çok yakın olduğu yüksek gürültü koşullarına sahip sinyaller için sorunlara neden olur. Ayrıca, EA şarj sistemleri gibi doğrusal olmayan yüklerde karmaşık GKO'lar oluşabilir. Sabit bir eşik değeri seçimi, yoğun çentik oluşumu ve harmonik içeren gerilim profili bozulmalarının tespitinde sorunlara neden olacaktır.

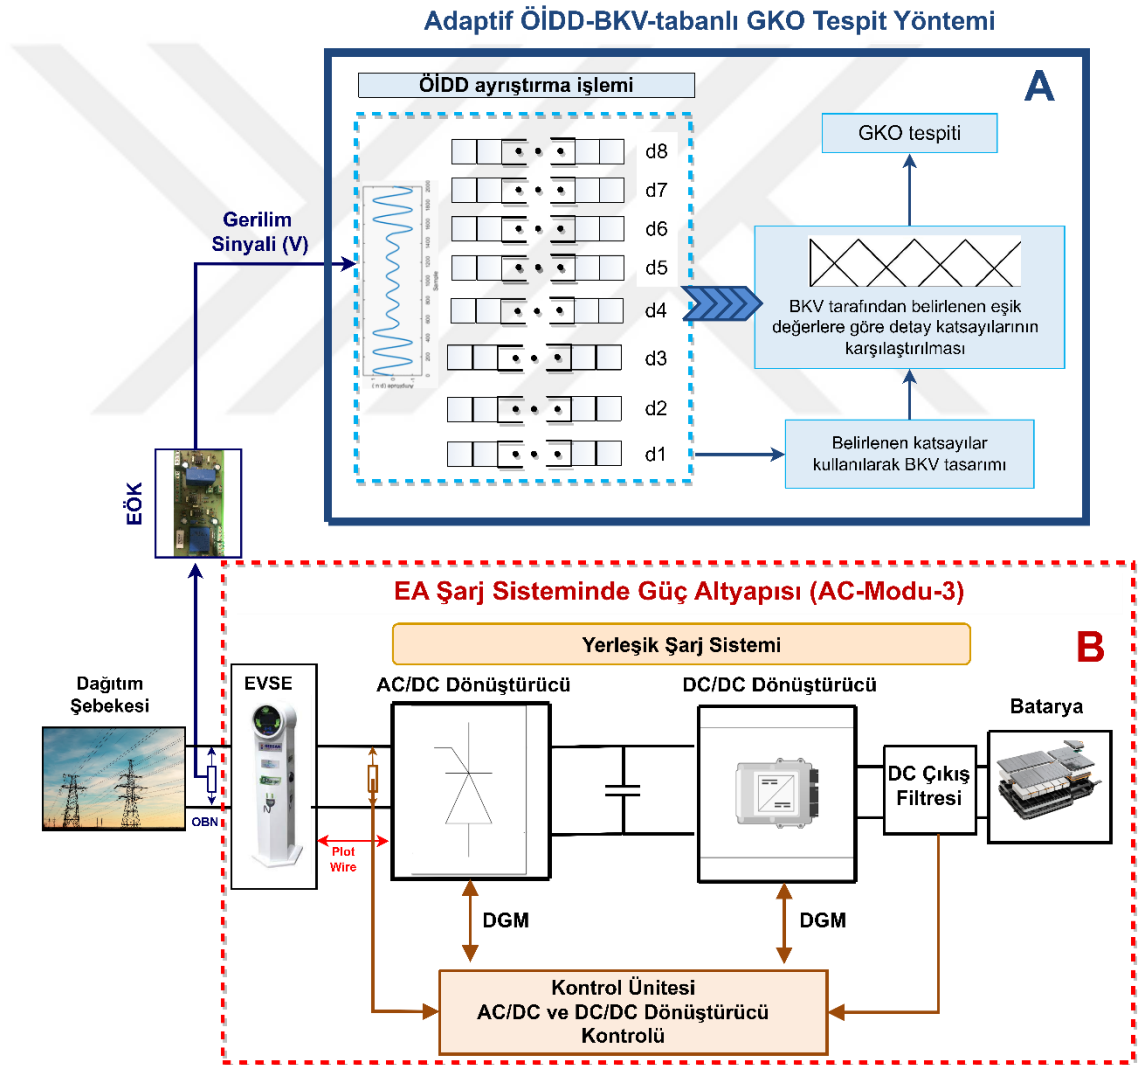
Önerilen yöntemde, piramidal ÖİDD ile elde edilen detay katsayılarına bulanık mantık-Tabanlı bir eşik değeri seçim mekanizması uygulanarak geleneksel sinyal işleme-Tabanlı yöntemlerin dezavantajları ortadan kaldırılmıştır. Basit ve güvenilir olan önerilen yöntemle, sinyaldeki gürültüyü azaltmak için yoğun işlem gerektiren filtreleme işlemine ihtiyaç duyulmamaktadır. BKV ile piramidal ÖİDD'nin birlikte kullanılması, sınıflandırma stratejisini önemli ölçüde geliştirmektedir. Bu adaptif yaklaşımla, eşik değeri yöntemlerinde sınır koşullarındaki algılama hataları önlenir ve aynı zamanda sadece gerilim sinyali kullanılarak maliyet ve hesaplama yükü en aza indirilir. Olay algılama süresi, IEEE 929-2000 standartlarında belirtilen sürenin altındadır.



Şekil 6.1 : Geleneksel sinyal analiz yöntemleri için GKO tespit akış şeması.

Şekil 6.2, GKO tespit ve sınıflandırması için önerilen ÖİDD&BKV-Tabanlı yöntemin blok diyagramını göstermektedir. B bloğunda yerleşik şarj cihazına sahip EA'lar için sistem bloğu gösterilmiştir. Burada, AC Mode-3 EA şarj cihazları, şebekedeki AC enerjisinin EA'lara aktarılmasından sorumludur ve şarj soketi algılama, EA ile haberleşme, şarj hızı kontrolü ve güvenlik gibi işlevleri yerine getirir. Gerilim sinyali, AC-DC dönüştürücü ile DC gerilime dönüştürülür. Bu gerilim, DC bara kapasitesi aracılığıyla DC-DC dönüştürücüye iletilir. Filtreleme işleminden sonra, dönüştürücü çıkışındaki gerilim EA bataryasına iletilir. Bu sistem düşük bir gerçek güç faktörüne sahiptir ve giriş akımında anahtarlamaya bağlı çentik ve harmonik oluşumuna neden olabilir.

A bloğunda ise önerilen yöntemin basit bir modeli verilmiştir. EVSE çıkışındaki gerilim sinyali, GKO tespitinde kullanılmaktadır. OBN noktasından alınan gerilim sinyaline uygulanan ÖİDD ayrıştırması sonucunda belirlenen delay katsayılarının tepe değerleri tespit edilmektedir ve sonrasında BKV ile bu değerler değerlendirilerek uygun GKO sınıfı belirlenmektedir. Gerçekleştirilen sistemde, AC dönüştürücü girişindeki OBN'den EÖK üzerindeki gerilim sensörleri (LV25-P) yardımıyla elde edilen gerilim sinyali, veri toplama kartı aracılığıyla alınır. Elde edilen veriler, 8 seviyeli ayrıştırma ile ÖİDD kullanılarak LabVIEW tabanlı olay tespit yazılımı tarafından değerlendirilir ve bulanık mantık çıkışlarına göre belirlenen eşik değerlere göre arıza durumları tespit edilir.



Şekil 6.2 : Önerilen ÖİDD-BKV yöntemi.

Önerilen yöntem çerçevesi dört aşamadan oluşmaktadır: 1) İntegral tabanlı model ve benzetim modeli kullanılarak veri oluşturma, 2) ÖİDD ile ayrıştırma işleminin

gerçekleştirilmesi ve detay katsayılarının tepe değerlerinin belirlenmesi, 3) BKV optimal parametrelerinin belirlenmesi ve GKO sınıflandırma ve 4) Gerçek veriler kullanılarak performans doğrulama.

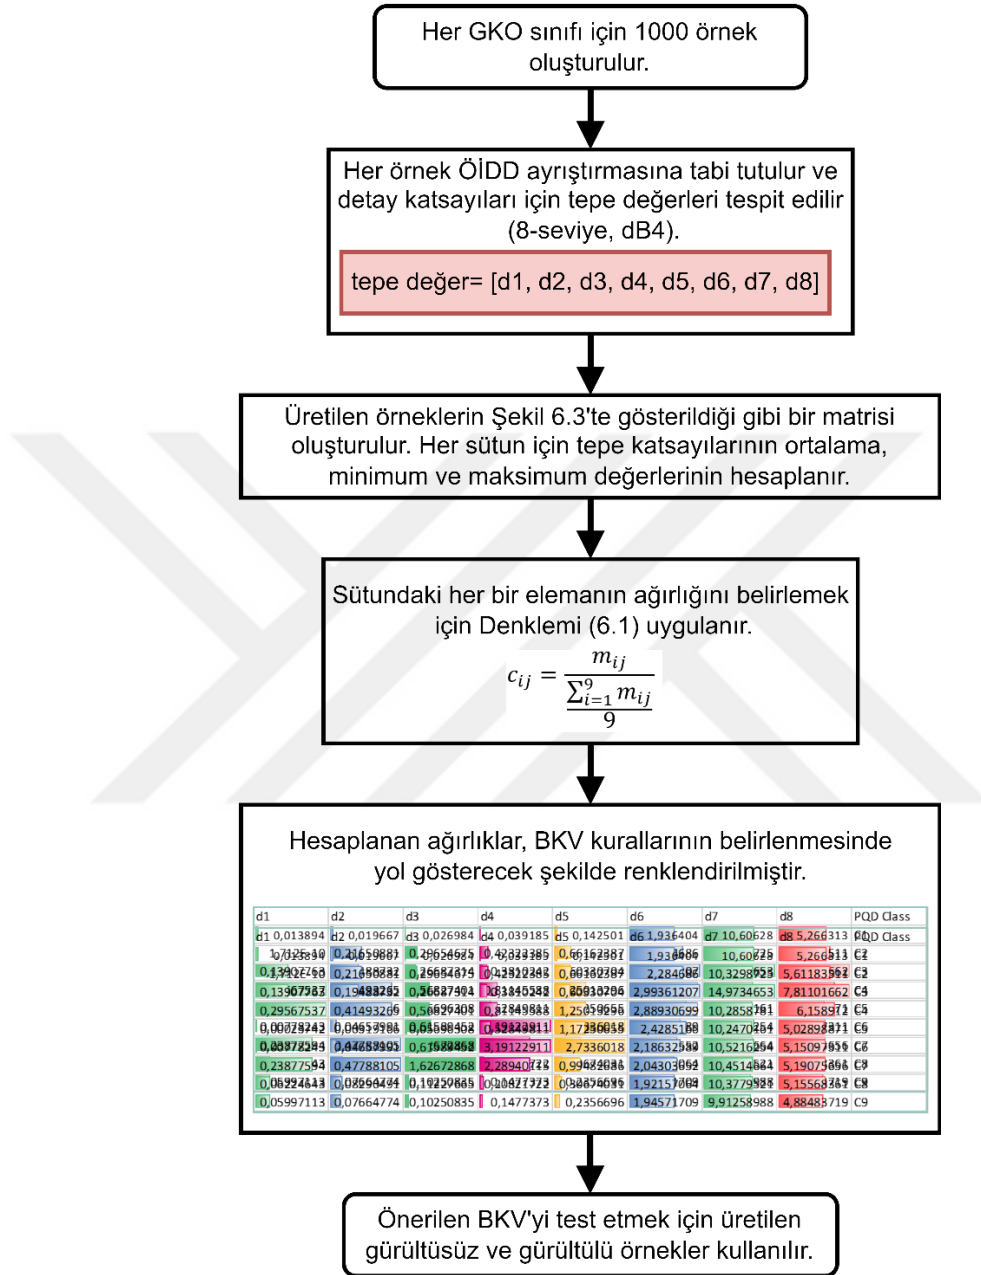
Süreç, LabVIEW'de bir matematiksel model kullanılarak GKO verilerinin üretilmesiyle başlamaktadır. Veriler 10 kHz örnekleme frekansında 0,2 saniye süreli olacak şekilde oluşturulmaktadır. Daha sonra, db4 dalgacığı kullanılarak üretilen sinyallere 8 seviyeli piramidal ÖİDD ayrıştırma işlemi uygulanmıştır. Bunu takiben her seviyedeki detay katsayıları için tepe değerleri belirlenir. Ayrıca, tüm GKO sınıflarının her detay katsayısı için tepe değerlerinin ortalama, minimum ve maksimum değerleri belirlenir. Üçüncü adımda, BKV'nin girdisi olarak elde edilen tepe değerleri vektörü ile BKV parametreleri seçilir. BKV, detay katsayılarının tepe değerlerini (d_1, d_2, \dots, d_8) girdi olarak kullanır ve GKO sınıfı BKV'nin çıktısıdır. Üyelik fonksiyonları, d_1 ile d_8 arasındaki tepe değerlerin ortalamasından yararlanarak üçgen fonksiyonlar tarafından modellenmektedir. Bulanık girdilere göre çıktı eşliğini belirleyen 9-bulanık kural herhangi bir olay sınıfında detay katsayıları tepe değerlerinin hangi iki parametresinin diğer GKO sınıflarından en fazla farklı olduğunu bulmak için kullanılır. Çıktı bulanık kümesi 9 sınıfa ayrılır (C_1, C_2, \dots, C_9). Son adımda, önerilen yöntem, deneysel test sistemi kullanılarak elde edilen GKO verileriyle doğrulanır.

6.1.1 BKV parametrelerinin seçimi

Kesin detay katsayılarının tepe değer ($d_1 \dots d_8$) girdilerini bulanık kümelerle ilişkilendirmek için BKV'de üyelik fonksiyonları tanımlanmıştır. Daha sonra bu konudaki analiz ve uzmanlık ile bulanık girdilere göre çıktı eşik değerini belirleyen bulanık kurallar oluşturulmuştur. Son aşamada ise bulanık çıkarım motoru eşik değerini belirlemek için gerekli bulanık işlemleri gerçekleştirmiştir. Bu çalışmada, katsayılar analiz edilmiş ve bunlardan ikisi bulanık karar verme sürecinde kullanılmıştır. Şekil 6.3'te verilen akış şeması, önerilen bulanık karar vericinin oluşturma ve test etme sürecini göstermektedir.

Önerilen BKV'nin kuralları, ÖİDD ayrıştırma işlemi ile elde edilen öznitelikleri içeren Şekil 6.4'teki matris dikkate alınarak oluşturulmuştur. Oluşturulan matris, binlerce örneğin ortalama değerlerinden oluşturulmuştur. Bu matrisin verileri, herhangi bir GKO sınıfındaki d_1 ile d_8 'in hangi iki parametresinin diğer GKO sınıflarından en farklı olduğunu bulmak için aşağıdaki denklemler ile işlenmiştir. Bu işlem, verilen

matrisin her bir ögesini her sütunun ortalama değerine böler. Böylece sütundaki her bir elemanın ağırlığı belirlenmiş olur. Ağırlıklar Şekil 6.4'teki gibi renklendirilerek görselleştirilmiştir.



Şekil 6.3 : Önerilen BKV sürecinin oluşturulması ve test edilmesi.

Oluşturulan matriste, sütundaki her bir elemanın ağırlığını belirlemek için Denklem (6.1) uygulanmıştır.

$$c_{ij} = \frac{m_{ij}}{\frac{\sum_{i=1}^9 m_{ij}}{9}} \quad (6.1)$$

Burada:

m : Şekil 6.4'teki verilerin her birini ifade etmektedir.

i : Şekil 6.4'te gösterildiği gibi 1 ile 9 arasında olan GKO sınıfını ifade eder. Aynı zamanda matrisin satır numarasını göstermektedir.

j : Elde edilen 8 seviyeli ÖİDD ayrıştırma işleminin maksimum değerlerini ifade eder. Ayrıca çizelgedeki matrisin sütun numarasını göstermektedir.

c : Sütundaki değerlerin sütunun ortalama değerine oranını ifade etmektedir.


d1	d2	d3	d4	d5	d6	d7	d8	PQD Class
0,013894	0,019667	0,026984	0,039185	0,142501	1,936404	10,60628	5,266313	C1
1,712E-10	0,21650881	0,29654675	0,42322385	0,66162387	2,284686	10,3298725	5,61183511	C2
0,13907763	0,19488732	0,26687314	0,3810242	0,60330704	2,99361207	14,9734653	7,81101662	C3
0,29567537	0,41493265	0,56827401	0,81145588	1,25013296	2,88930699	10,2858781	6,158912	C4
0,00023742	0,00319166	0,05696308	0,52849811	1,17250655	2,4285166	10,2470161	5,02898871	C5
0,00778243	0,04657991	0,61589452	3,19122911	2,7336018	2,18632589	10,5216254	5,15097311	C6
0,23877594	0,47788105	1,62672868	2,28940115	0,99482686	2,04303652	10,4514664	5,19075656	C7
0,06224643	0,08290491	0,11227665	0,20821722	0,30674031	1,92157064	10,3779521	5,15568361	C8
0,05997113	0,07664774	0,10250835	0,1477373	0,2356696	1,94571709	9,91258988	4,88483719	C9

Şekil 6.4 : ÖİDD ayrıştırma işlemi ile elde edilen özellikleri içeren matris.

Tüm öznitelikler, Şekil 6.4'te verilen ortalama değerler aracılığıyla üçgen bulanık üyelik fonksiyonları ile modellenmiştir. Böylece, her bir özelliğin kesin değerleri, bulanık alt kümeler kullanılarak bulanık sayılara dönüştürülmüştür. Şekil 6.5'te, özniteliklerin bulanık alt kümeleri gösterilmektedir. ÖİDD girdilerinin bulanık alt kümeleri, bulanık karar vermede hem bulanıklaştırma hem de durulaştırma aşamalarında kullanılmaktadır. ÖİDD sınıfları ayrıca Şekil 6.5'te gösterildiği gibi bulanık alt kümeler olarak tanımlanır. Üçgen bulanık üyelik fonksiyonu aşağıdaki denklem ile tanımlanabilir.

$$\mu(x) = \max \left[\min \left(\frac{x - x_1}{x_2 - x_1}, \frac{x_3 - x}{x_3 - x_2} \right), 0 \right] \quad (6.2)$$

burada x , d1'den d8'e kadar numaralandırılmış girişlerin ve GKO sınıflarını sunan çıkışların kesin değerleridir. Sırasıyla, x_1 , x_2 ve x_3 üçgen üyelik fonksiyonunun sol uç noktası, tepe noktası ve sağ uç noktasıdır. Girdi bulanık alt kümelerinin üyelik dereceleri Küçük (S), Orta (M) ve Büyük (B) olarak sunulur. Çıktı bulanık seti, yukarıda belirtilen GKO'ları temsil eden 9 sınıfa (C1-C9) ayrılmıştır.



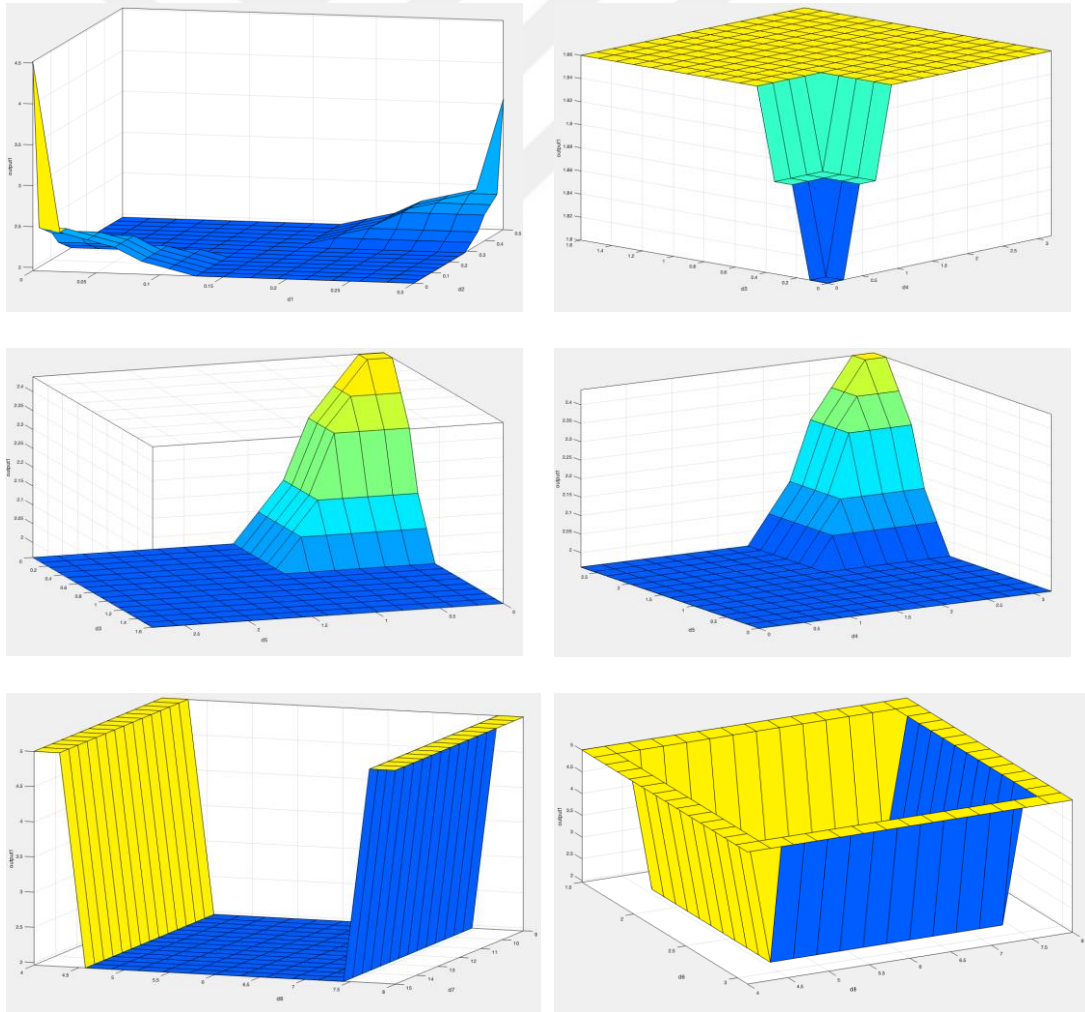
Şekil 6.5 : BKV'nin girişlerinin(d_1 - d_8) ve çıkışının (C) bulanık alt kümeleri.

Çizelge 6.1'de verilen matris, doğru koşulları belirlemek için 9 kuralın yeterli olduğunu göstermektedir. Bu nedenle, diğer korelasyonlar ihmal edilmektedir.

Çizelge 6.1 : BKV kuralları.

Kurallar				
Kural 1	d3 küçük (S) ise	ve	d4 küçük (S)	O zaman durum C1
Kural 2	d6 orta (M) ise	ve	d8 orta (M)	O zaman durum C2
Kural 3	d7 büyük (B) ise	ve	d8 büyük (B)	O zaman durum C3
Kural 4	d1 büyük (B) ise	ve	d2 büyük (B)	O zaman durum C4
Kural 5	d1 küçük (S) ise	ve	d2 küçük (S)	O zaman durum C5
Kural 6	d4 büyük (B) ise	ve	d5 büyük (B)	O zaman durum C6
Kural 7	d2 büyük (B) ise	ve	d3 büyük (B)	O zaman durum C7
Kural 8	d3 küçük (S) ise	ve	d5 küçük (S)	O zaman durum C8
Kural 9	d6 küçük (S) ise	ve	d8 küçük (S)	O zaman durum C9

Çizelge 6.1’de bahsedilen kurallar, Şekil 6.6’da bir yüzey olarak çizdirilmiştir. Bu şekil, aktif olarak kullanılan bazı girdilerin (d1-d2, d3-d4, d3-d5, d4-d5, d6-d8, d7-d8) ve BKV'nin çıkışı arasındaki ilişkileri göstermektedir.



Şekil 6.6 : İşlenen aktif kuralların yüzey grafikleri.

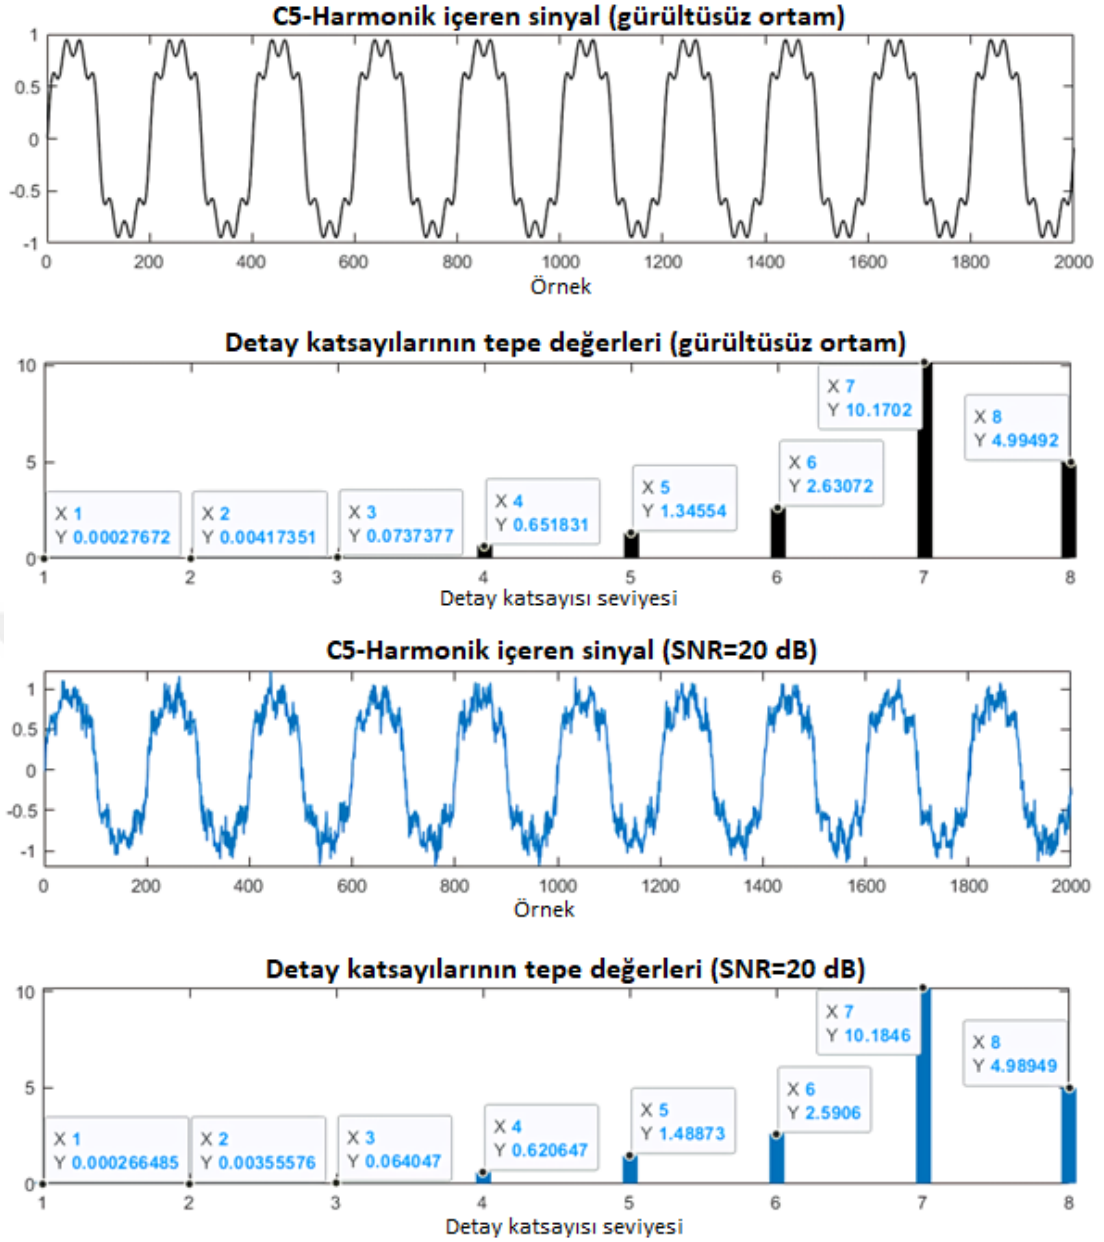
Kural işleme yöntemi olarak Mamdani (min-max) yöntemi seçilmiştir. Durulaştırma işleminde ise Bisektör operatörü kullanılmaktadır. BKV şu şekilde karar almaktadır: GKO sınıfının her çıktısı, en yüksek üyelik değeri için ± 0.5 aralığına sahiptir. Örnek olarak, BKV'nin çıktısı 4,5 ile 3,5 arasında ise, C4 GKO sınıfını temsil eden 4 olarak değerlendirilir.

6.1.2 Farklı gürültü koşullarında performans analizi

Bu bölümde ilk olarak, GKO'ların tepe değerlerini tespit etmede üstünlük gösteren piramidal ÖİDD ayrıştırmasının gürültüsüz ve gürültülü koşullarda performans analizi yapılmıştır. Daha sonra, ÖİDD-BKV'nin farklı gürültü koşulları altında simülatif ve matematiksel veriler için performans sonuçları her sınıf için analiz edilmiştir.

Önerilen yöntemde, ilk aşamada veri üretimi gerçekleştirildikten sonra, ikinci aşamada piramidal ÖİDD ile sinyal ayrıştırması gerçekleştirilir. ÖİDD detay katsayısı ve tepe değerleri belirlenir. Piramidal ÖİDD, öznelik çıkarma uygulamalarında önemli olan öteleme değişmez özelliğine sahiptir. Ayrıca, piramidal ÖİDD ile gürültü bastırma, zamanda değişmezdir. Geleneksel DD yaklaşımlarıyla karşılaştırıldığında, ÖİDD gürültü giderme sonucu üstün bir pürüzsüzlük ve hassasiyet dengesine sahiptir. Bu çalışmada, ÖİDD detay katsayılarının tepe noktaları, sinyal hakkında önemli bilgiler içermektedir. Gürültü içeren bir sinyaldeki tepe noktalarını belirlemek için piramidal ÖİDD ayrıştırmasının yapılmasının çok sayıda üstünlüğü bulunmaktadır. ÖİDD tabanlı tepe algılama yöntemi, çok ölçekli ÖİDD katsayılarında sıfır geçiş bulmayı içerdiğinden, geleneksel DD ayrıştırma yöntemlerinden daha sağlamdır ve gürültüye karşı daha az hassastır.

Şekil 6.7, gürültülü (SNR=20 dB) ve gürültüsüz koşullar altında harmonik olayı (C5) için piramidal ÖİDD ayrıştırması ile belirlenen 8 seviyeli detay katsayılarının tepe değerlerini göstermektedir. Her iki olay sinyali için 8 seviyeli ayrıştırmadan sonra elde edilen detay katsayılarının tepe değerleri benzer sonuçlar vermektedir. Burada, ÖİDD ADD'de kullanılan yarı-örnekleme işleminden kaynaklanan sorunları ortadan kaldırmaktadır ve bu sayede salınımı azaltırken gürültüye karşı sağlamlık da sağlar. Ayrıca, piramidal algoritmayla kullanılan ÖİDD, bilginin hem kaba hem de ince çözünürlük seviyelerinde çıkarılmasına izin verir. Sonuç olarak, piramidal ÖİDD yöntemi, sinyalden gelen gürültüyü azaltmak için yoğun işlem gerektiren bir filtreleme işlemine olan ihtiyacı ortadan kaldırmıştır.



Şekil 6.7 : C5 sınıfı için gürültüsüz ve gürültülü sinyallerde detay katsayılarının tepe değeri karşılaştırması.

ÖİDD-BKV doğruluk sonuçları Çizelge 6.2’de verilmiştir. Önerilen yöntem doğruluk performansı sonuçları gürültüsüz ve yüksek gürültülü koşullar için benzerdir. Gürültüsüz veriler için ortalama test doğruluğu, piramidal ÖİDD kullanan BKV yöntemi için %96,13’tür. Ayrıca önerilen yönteminin, 20-40 dB yüksek gürültü koşullarında ortalama test doğruluğu %94,96’dır. Bu sonuç, BKV-Tabanlı eşik değer seçim yönteminin ve piramidal ÖİDD'nin gürültü bağışıklığı özelliğinin doğal bir sonucudur. Seçilen 9 kural ile ÖİDD-BKV'nin performansı artarken, gerçek zamanlı uygulamalar için uygun bir hesaplama süresi elde edilmektedir.

Çizelge 6.2 : ÖİDD-BKV tabanlı yöntemin doğruluğu.

GKO Sınıfı	Gürültüsüz	SNR=20-40dB karışık veri
C1	100	99.8
C2	98.3	97.4
C3	98	97.5
C4	98.4	96.8
C5	100	99.8
C6	87.1	87
C7	87.5	85.4
C8	99.9	99.5
C9	96	91.5
Tüme veri	96.13	94.96

ÖİDD-BKV'nin C6 (kırpışma) ve C7'nin (salınımlı geçici olay) tanımlanmasındaki doğruluğu nispeten düşüktür. Bunun nedeni, her iki olay için ÖİDD ayrıştırmasıyla elde edilen tepe değerlerinin birbirine çok yakın olmasıdır. Olay anında gerilim genliği azaldıkça, C2 (çökme) ve C4 (kesinti) olaylarını ayırt etmek daha zor hale gelir. Önerilen yöntemde yüksek gürültü altında dahi doğruluk performansı %97'nin üzerinde olup C2 ve C4 olayları için çok iyi sonuçlar vermektedir. C1 (nominal), C2 (çökme), C3 (sıçrama), C4 (kesinti), C5 (harmonik) ve C8 (Darbeli geçici olay) sınıfları için sınıflandırma doğruluğu, yüksek gürültü koşulları ve gürültüsüz koşullar ile benzerdir. Bu sonuçlar önerilen yöntemin olayları birbirinden ayıran eşik değerlere yakın olaylar için bile yüksek performans gösterdiğini kanıtlamaktadır.

6.1.3 Performans doğrulama

ÖİDD-BKV yönteminin etkinliği, bir deneysel kurulum kullanılarak gerçek GKO verileri üzerinde de test edilmiştir. Çizelge 6.3, önerilen yöntemin EA şarj sistemleri ile farklı yükler entegre edilmiş DG-Tabanlı mikroşebeke test sisteminde oluşturulan olayların sınıflandırma doğruluğu sonuçlarını göstermektedir. Her olay için 30 örnek farklı senaryolarla veri toplama sistemi ile toplanmıştır. Deneysel veriler için ortalama test doğruluğu %96,66'dır. Deneysel GKO sınıflandırma doğruluğu, simülasyonlardan ve matematiksel modelden oluşturulan olaylardan elde edilen sonuçlara yakındır.

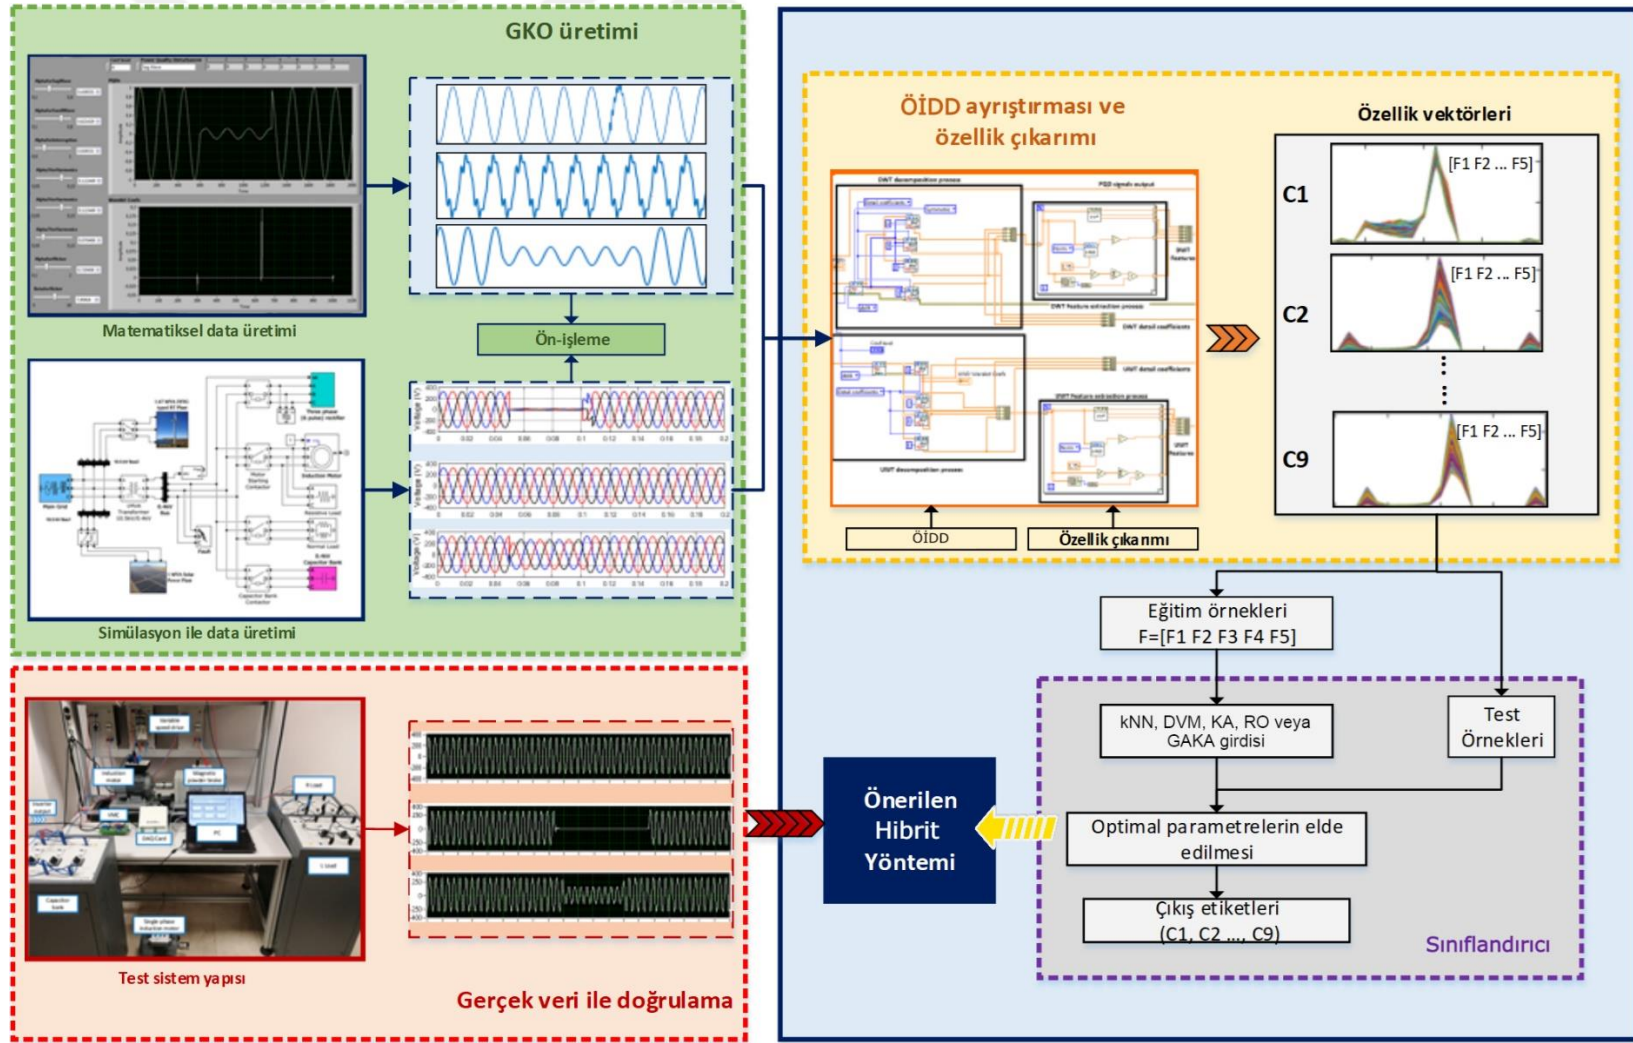
Çizelge 6.3 : Gerçek GKO veriler için sınıflandırma sonuçları.

Gerçek GKO verisi	Doğru tahminler
Gerilim Çökmesi (C2)	29
Gerilim Sıçraması (C3)	29
Harmonikler (C5)	30
Osilasyonlu Geçici Olay (C8)	30
Çentik (C9)	27
Genel Doğruluk (%)	%96.66

6.2 Sinyal Analiz ve Sınıflandırıcı Modelleri ile GKO Sınıflandırma

Geliştirilen ÖİDD ve sınıflandırıcı-Tabanlı hibrit yöntemler için geliştirme süreci grafiksel özet olarak Şekil 6.8’de verilmiştir [65]. İlk aşamada hem integral-Tabanlı matematiksel yöntemden hem de geliştirilen benzetim modeline ait simülasyonlardan GKO verileri üretilmiştir. Sonrasında, olay sinyallerine ÖİDD ile ayrıştırma işlemi uygulanmış ve farklı seviyelerde detay katsayıları elde edilmiştir. 8-seviyeli ayrıştırma sonucunda elde edilen her bir frekans bandına ait detay katsayılarının ortalama, varyans, standart sapma, enerji ve entropi değerleri hesaplanmıştır. Oluşturulan öznitelik vektörü sınıflandırıcı modellerinin girdisini oluşturmaktadır. Sınıflandırıcısının çıkışında GKO olay çıkış etiketleri (C1, C2, ..., C9) bulunmaktadır. Son aşamada ise gerçek GKO verileri ile önerilen yöntemin geçerliliği test edilmiştir.

Bu bölümde, öncelikle ÖİDD için ana dalgacık seçim süreci ve ayrıştırma seviyesinin belirlenmesi aşamaları aktarılacaktır. ÖİDD analizi sonrasında detay katsayılarına uygulanan öznitelik çıkarım süreci ve bu aşamadaki ÖİDD avantajları ayrıntılı görsellerle sunulmaktadır. En yüksek başarıma sahip DVM ve GAKA için ayrıntılı akış diyagramları verilirken karşılaştırılan sınıflandırıcılar için de seçilen parametreler ayrıntılandırılmıştır. Son aşamada ise simülatif, matematiksel ve gerçek GKO olayları için geliştirilen yöntem sonuçları verilmiştir. Ayrıca, ÖİDD ve ADD kullanılarak yapılan sınıflandırma sonuçları farklı gürültü koşullarında karşılaştırılmıştır. Geliştirilen modellerde, ÖİDD katsayılarından elde edilen öznitelikler kullanıldığında yüksek gürültülü GKO sinyallerinde bile yüksek başarımın elde edildiği görülmüştür.

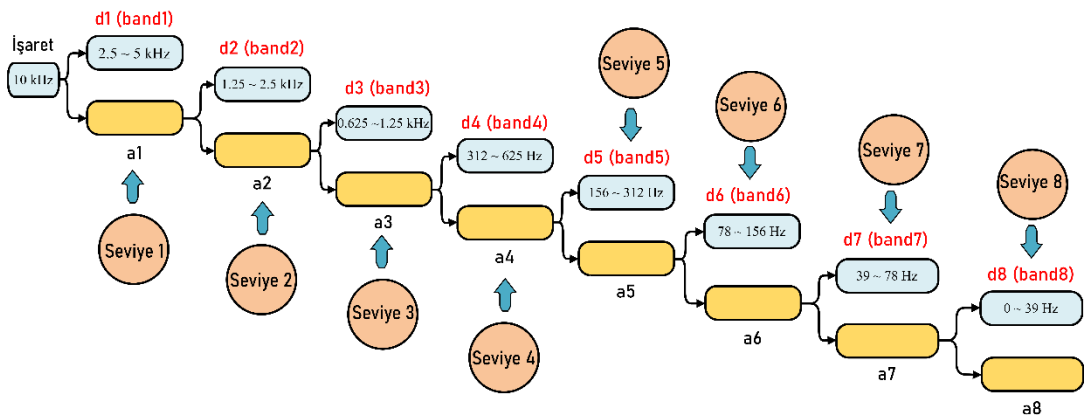


Şekil 6.8 : Geliştirilen ÖİDD ve Sınıflandırıcı-Tabanlı hibrit yöntemler için geliştirme süreci.

6.2.1 ÖİDD parametrelerinin belirlenmesi

DD uygulamalarında, GKO özniteliklerini çıkarmak için uygun bir ana dalga formu seçmek gereklidir. Daubechies (dbN) dalga formu ailesi, GKO gibi kısa sürelerde yüksek frekans bileşenlerini içeren sinyallerin analizinde avantajlar sağlar. Ek olarak, dbN ile yapılan ayrıştırma düşük ölçeklerde daha iyi bir zaman konumu elde edilebilir [65, 66]. Farklı koşullarda yapılan simülasyon ve deneysel testlerin sonucunda db4 dalga formu seçilmiştir. Seçilen db4 ana dalga biçimi, az sayıda örneği olan kısa bir dalga biçimini içerdiği için hesaplama süresini de azaltmaktadır [69]. db4'ün seçilme nedeni, zamanda en fazla lokalize, yani sıkı destekli olmasıdır. db4 için ölçülen hesaplama süresi 0,0123345 s'dir ve gerçek zamanlı sistem performansı için uygun bir süredir.

Yapılan çalışmalarda, ÖİDD-Tabanlı sinyal analiz yöntemi ile GKO sınıflandırması için 8-seviyeli ayrıştırmanın yeterli olduğu görülmüştür. 8-seviyeli ayrıştırma için detay katsayısı bileşenlerinin frekans aralıkları Şekil 6.9'da gösterilmiştir. Analiz sonucunda gerilim çökmesi/sıçraması/kesintisi gibi olayların belirgin olduğu frekans aralığı düşük frekans bantlarına karşılık gelmektedir (d5, d6, d7). Öte yandan, yüksek frekans aralığındaki (d2, d3, d4) analizlerde yüksek frekans bileşenine sahip darbeleri ve salınımlı geçici olaylar gözlemlenebilir.



Şekil 6.9 : 8-seviyeli ayrıştırma katsayı bileşenlerinin frekans aralıkları.

6.2.2 Öznitelik çıkarımı

Literatürde yüksek karmaşıklık ve işleme yükü gerektiren istatistiksel parametreler kullanılırken tez çalışmasında, ÖİDD ayrıştırması sonrasında elde edilen detay katsayılarının basit öznitelikleri sınıflandırıcı girdisi için kullanılmıştır. Oluşturulan

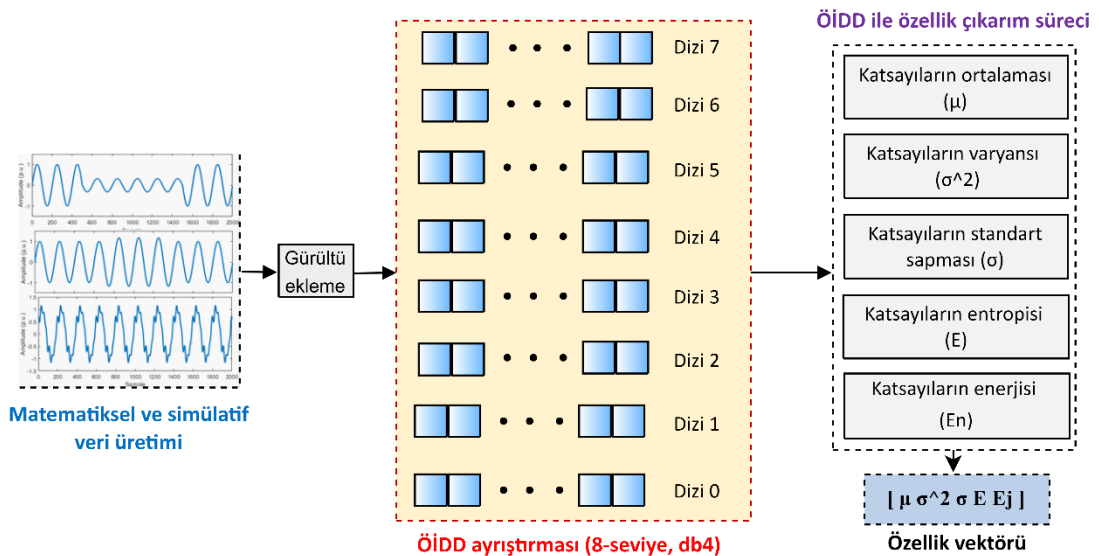
son öznitelik vektörünün az sayıda parametreden oluşması işlem yükünü en aza indirmektedir.

Şekil 6.10'de, öznitelik çıkarma yönteminin genel yapısı verilmiştir. Özellik çıkarma süreci, integral-Tabanlı matematiksel model ve benzetim modeli kullanılarak oluşturulan GKO sinyallerine piramidal algoritmayla ÖİDD ayrıştırması gerçekleştirilmesiyle başlamaktadır. 8-seviyeli ayrıştırma için "db4" ana dalgacık fonksiyonu kullanılarak detay katsayıları (D1, D2, D3, ..., D8) belirlenmektedir. Ayrıştırma işleminden sonra elde edilen detay katsayılarının (D1, D2, D3 ... D8) ortalaması (μ), standart sapması (σ^2), varyansı (σ), entropisi (E) ve enerjisi (E_n) hesaplanmaktadır. Öznitelik vektörleri şu şekilde tanımlanabilir:

$$\begin{aligned}
 F1 &= [\mu_{D1} \ \mu_{D2} \ \mu_{D3} \ \mu_{D4} \ \dots \ \mu_{D8}] \\
 F2 &= [\sigma^2_{D1} \ \sigma^2_{D2} \ \sigma^2_{D3} \ \sigma^2_{D4} \ \dots \ \mu\sigma^2_{D8}] \\
 F3 &= [\sigma_{D1} \ \sigma_{D2} \ \sigma_{D3} \ \sigma_{D4} \ \dots \ \sigma_{D8}] \\
 F4 &= [E_{D1} \ E_{D2} \ E_{D3} \ E_{D4} \ \dots \ E_{D8}] \\
 F5 &= [E_{nD1} \ E_{nD2} \ E_{nD3} \ E_{nD4} \ \dots \ E_{nD8}]
 \end{aligned}
 \tag{6.3}$$

Verilerin min-max normalizasyonu sonrası elde edilen son öznitelik vektörü aşağıdaki gibi olur:

$$F = [F1 \ F2 \ F3 \ F4 \ F5] \tag{6.4}$$



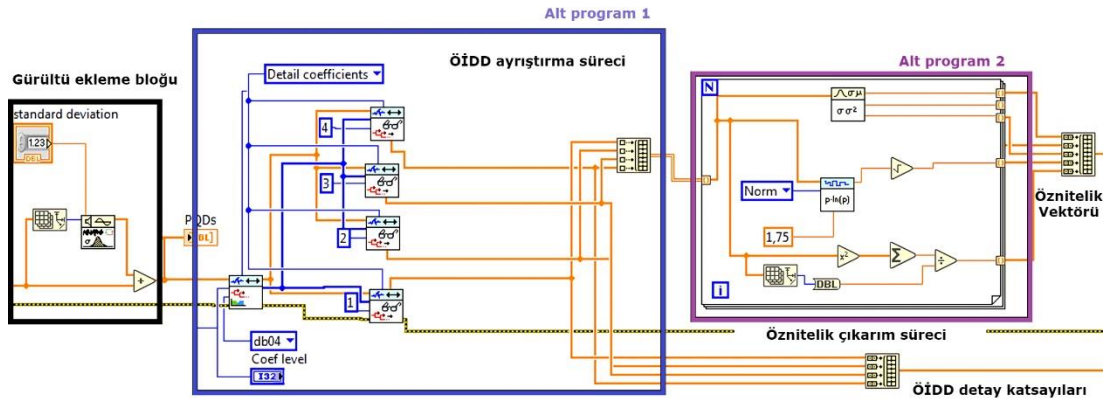
Şekil 6.10 : Önerilen öznitelik çıkarma işleminin mimarisi.

Detay katsaylarına uygulanan istatistiksel süreç sonrasında seçilmiş öznitelikler Çizelge 6.4'te gösterilmektedir. Çizelgede gösterilen denklemlerde, $i=1, 2, \dots, l$ seviyesindeki dalgacık ayrıştırmasının sayısını temsil ederken $j=1, 2, \dots, l$ dalgacık ayrışması seviyesini temsil etmektedir. Ayrıca, N her seviye için katsayıların sayısıdır ve D detay katsayılarıdır.

Çizelge 6.4 : Uygulanan istatistiksel süreç sonrasında seçilmiş öznitelikler.

	Özellikler	Denklem
F1	Ortalama (μ)	$\mu_i = \frac{1}{N} \sum_{j=1}^N (D_{ij})$
F2	Varyans(σ^2)	$\sigma_i^2 = \left(\frac{1}{N-1} \sum_{j=1}^N (D_{ij} - \mu_i)^2 \right)$
F3	Standart sapma (σ)	$\sigma_i = \left(\frac{1}{N-1} \sum_{j=1}^N (D_{ij} - \mu_i)^2 \right)^{1/2}$
F4	Entropi (E)	$E_i = - \sum_{j=1}^N \{D_{ij}^2 \log(D_{ij}^2)\}$
F5	Enerji (En)	$En_i = - \sum_{j=1}^N (D_{ij} ^2)$

Şekil 6.11, ÖİDD ayrıştırma ve öznitelik çıkarma için geliştirilen LabVIEW yazılımının blok panelini göstermektedir. Alt program 1'de farklı SNR seviyesinde gürültü eklenen GKO olayına uygulanan ÖİDD ayrıştırması için oluşturulan kısım gösterilmektedir. İstatistiksel işlemlerden yararlanılarak oluşturulan vektör ise özellik çıkarma alt programı 2 ile üretilmektedir.

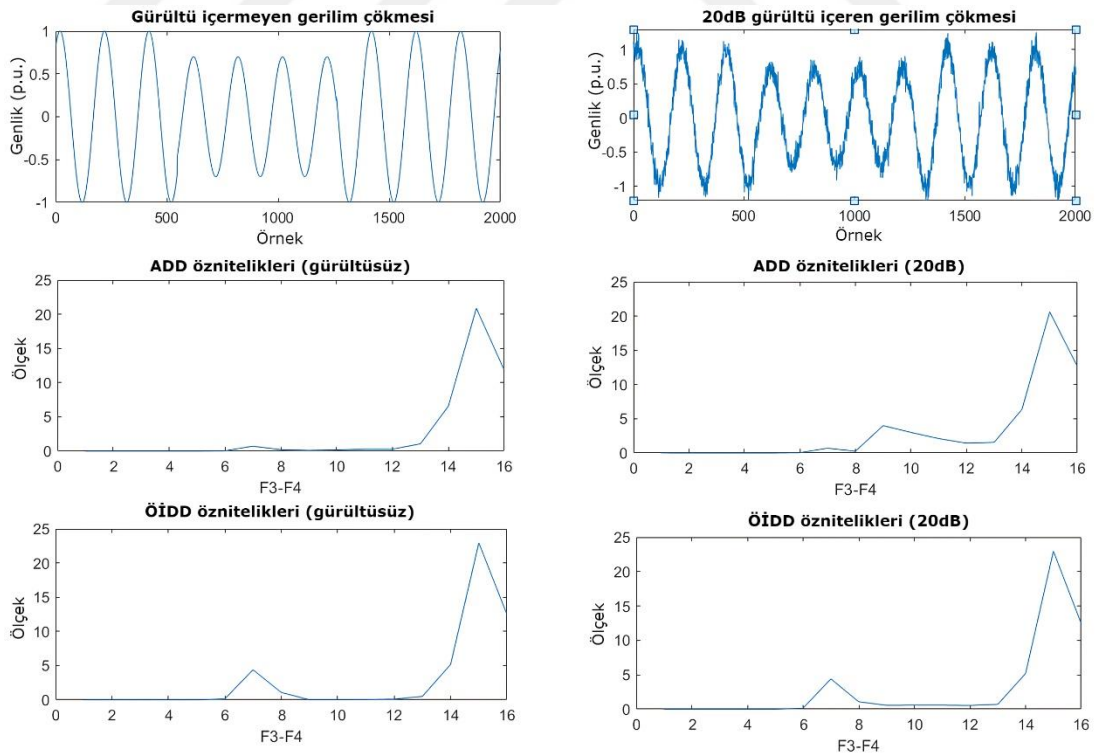


Şekil 6.11 : Geliştirilen ÖİDD analizi ve özellik çıkarma yazılımı blok paneli.

6.2.3 DD ile öznitelik analizi

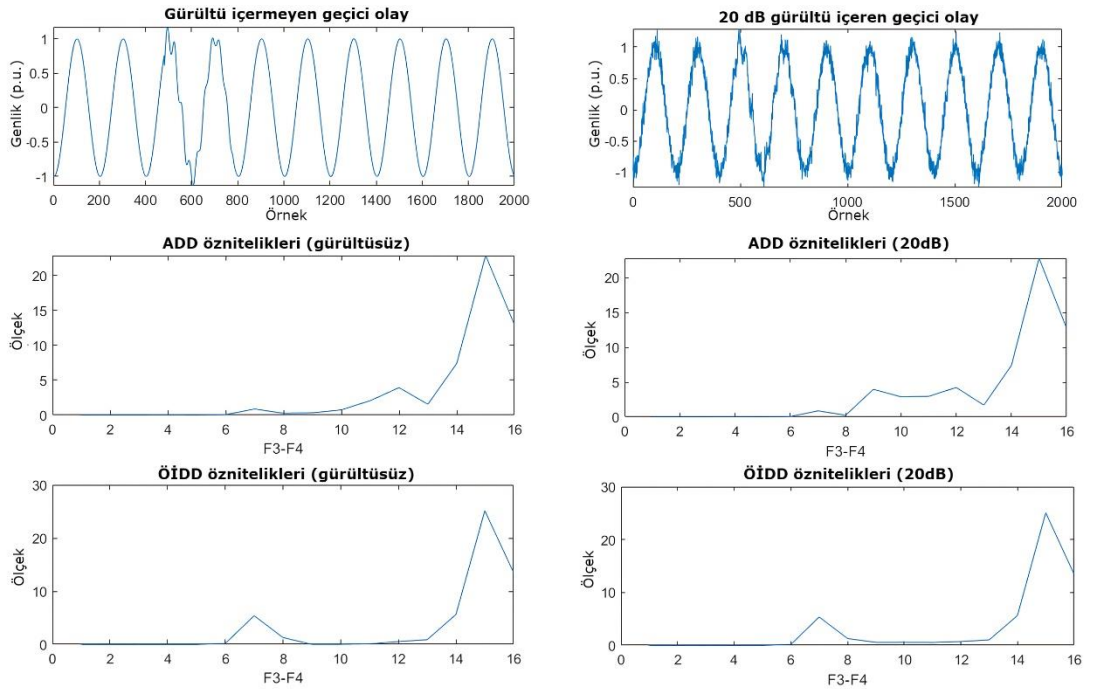
Önerilen ÖİDD-Tabanlı öznitelik çıkarma yönteminin etkinliğini doğrulamak için elde edilen öznitelikler, ADD ayrıştırması ile benzer işleme tabi tutulan özniteliklerle karşılaştırılmıştır.

Şekil 6.12, gürültülü ve gürültüsüz koşullarda üretilen gerilim çökmesi olayı için ADD ve ÖİDD sonucunda hesaplanan standart sapma ve entropi (F3, F4) değerlerinin karşılaştırma sonuçlarını göstermektedir. Olayın başlangıç ve bitiş zamanları sırasıyla 0.055 s (Örnek 551) ve 0.126 s (Örnek 1262) olarak belirlenmiştir. Bu saniyeler arasında gerilim sinyalinin genliği nominal değer %68,5'i kadar düşmektedir. Şekilde, ÖİDD'nin F3 ve F4'te salınımları ve gürültüyü azalttığı görülmektedir. ADD ile yapılan ayrıştırma sonucunda elde edilen öznitelikler, gürültüden önemli ölçüde etkilenmektedir. Gürültülü ortamda elde edilen farklı öznitelikler, sınıflandırıcı performansını önemli ölçüde düşürecektir ve karmaşık yapıların gerekliliğini ortaya çıkaracaktır. Bu durum, piramidal ÖİDD ayrıştırması ile elde edilen özniteliklerin, geleneksel DD-Tabanlı yöntemlerin dezavantajlarını ve sınırlamalarını ortadan kaldırdığını göstermektedir.



Şekil 6.12 : Gerilim çökmesi olayı için ADD ve önerilen ÖİDD-Tabanlı özniteliklerin karşılaştırma sonuçları.

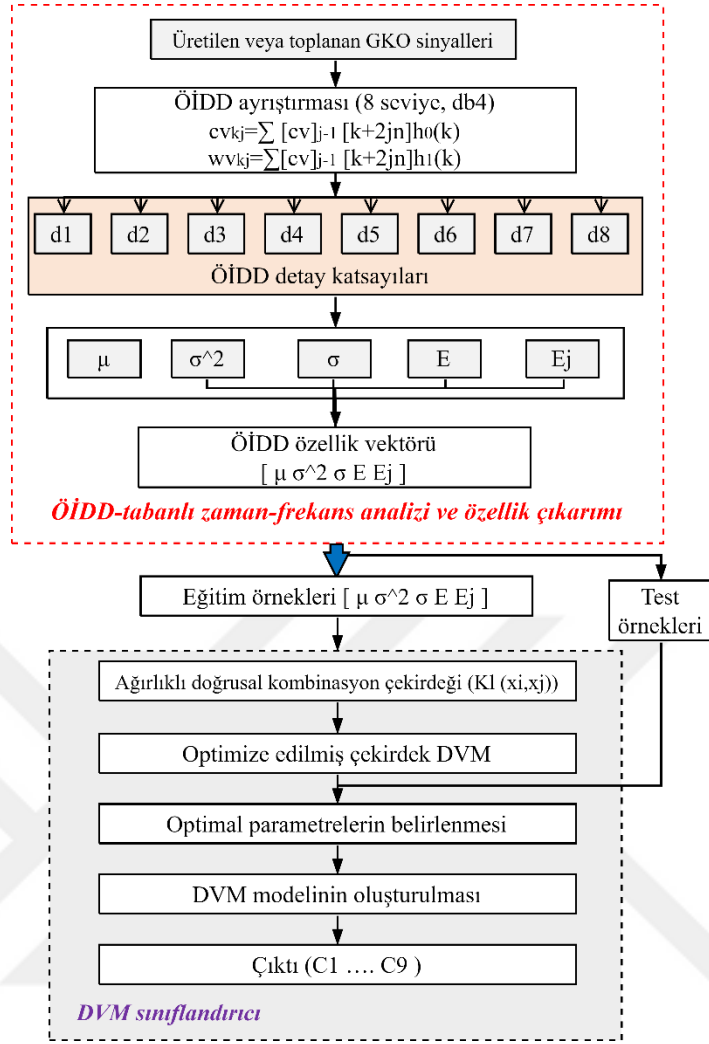
Piramidal ÖİDD ile elde edilen özniteliklerin etkinliğini doğrulamak için gerilim çökmesi olayıyla benzer şekilde salınımlı geçici durum olayı için de ADD ve ÖİDD ile elde edilen öznitelikler karşılaştırılmıştır. Gürültüsüz ve 20 dB gürültülü koşullarda ÖİDD ve ADD ayrıştırmasıyla elde edilen F3 ve F4 öznitelik vektörleri Şekil 6.13'te gösterilmektedir. Salınımlı geçici durum olayı, 0.045 s'de (Örnek 452) başlamaktadır ve 0.074 s'ye (örnek 741) kadar devam etmektedir. ADD ile elde edilen özniteliklerin gerilim çökmesi olayıyla benzer şekilde gürültüden etkilendiği görülmektedir. Önerilen yöntem F3 ve F4 öznitelikleri ise yüksek gürültü koşullarında bile gürültüsüz ortamdaki gibi sonuç vermektedir.



Şekil 6.13 : Salınımlı geçici olay için ADD ve önerilen ÖİDD-Tabanlı özniteliklerin karşılaştırma sonuçları.

6.2.4 Önerilen ÖİDD-DVM-Tabanlı hibrit GKO sınıflandırma yöntemi

Önerilen yöntemde ÖİDD katsayıları, OBN noktasından alınan gerilim sinyaline ön işleme uygulandıktan sonra 8-seviyeli ayrıştırma ile elde edilmektedir. Her seviyedeki detay katsayılarının ortalama, standart sapma, varyans, entropi ve enerjisi belirlenir ve tüm seviyeler için hesaplanan bu değerlerle bir öznitelik veri seti oluşturulur. Elde edilen öznitelij vektörü DVM girişidir. Çıkış ise olay sınıfıdır. Akış şeması Şekil 6.14'te gösterilmektedir. Kısaca, ÖİDD-DVM çerçevesi iki kısma ayrılabilir: 1) ÖİDD tabanlı zaman-frekans analizi, ardından istatistiksel yöntemlerle özellik çıkarma ve 2) GKO'ların DVM-Tabanlı modelle sınıflandırılması.



Şekil 6.14 : Önerilen ÖİDD ve DVM-Tabanlı yöntemin akış şeması.

Denklem (3.11) 'in OBN noktasından alınan gerilim sinyaline uygulanması için v_k 'nın gerilim dizisi olduğu durumda, ÖİDD katsayıları şu şekilde hesaplanabilir:

$$[cv_k]_j^U = \sum_n [cv]_{j-1}^U [k + 2^j n] h_0(k);$$

$$[wv_k]_j^U = \sum_n [cv]_{j-1}^U [k + 2^j n] h_1(k)$$
(6.5)

μ , σ^2 , σ , E_n ve E özellikleri her detay katsayı seviyesinden elde edilir. Bu öznitelikler, [150]'deki gibi ağırlıklı lineer kombinasyon çekirdek fonksiyonunu hesaplamak için elde edilir. Ardından, GKO'lar DVM tarafından sınıflandırılır. Geleneksel DVM yöntemi, öznitelik verilerini eşlemek için yalnızca bir çekirdek işlevi kullanır. Ancak bu durum, GKO'lar gibi birçok farklı özellik içeren sinyallerin sınıflandırılmasında performansı düşürmektedir. Sınıflandırmadaki başarıyı artırmak için ağırlıklı bir

lineer kombinasyon çekirdeği kullanılabilir. DVM'nin optimizasyon çerçevesi şu şekilde tanımlanmaktadır [149, 150]:

$$\min_{w,b,\xi_i} \left\{ \frac{\|w\|^2}{2} + C \sum_{i=1}^n \xi_i^2 \right\}$$

$$s. t. y_i(w^T K_l(x_i, x_j) + b) \geq 1 - \xi_i \quad (6.6)$$

$$\xi_i \geq 0, i = 1, \dots, n$$

burada, K_l , x_i ve x_j noktaları için ağırlıklı doğrusal kombinasyon çekirdeğini, w ağırlık vektörünü, b sapmayı, C ceza katsayısını ve ξ_i gevşek (slack) değişkeni göstermektedir. Karar fonksiyonu Denklem (3.24)'teki gibi ifade edilebilir.

Uygun bir çekirdek fonksiyonu seçmek için, lineer, polinom ve Gauss çekirdekleri DVM modelini doğrulamak için kullanılmıştır. Performanslar incelendiğinde, kombinasyon çekirdek fonksiyonunun tüm işlevlerinin basitliği ve daha yüksek doğruluk nedeniyle Gauss çekirdekleri seçilmiştir. Çekirdek (kernel) fonksiyonlarının parametrelerini seçerken, ilk adımda önceki deneyimlerden yararlanarak uygun bir değer aralığı belirlenmektedir. İkinci adımda, optimal parametreler Grid Search yöntemiyle seçilir ve çekirdek önbelleğinin boyutu belirlenir. Çekirdek fonksiyonu ve ağırlık katsayıları seçildikten sonra, daha fazla araştırma yapılır. Farklı çekirdek DVM parametreleri için performans testleri gerçekleştirilir ve en iyi parametreler Gauss çekirdeği (K_l) ve ceza katsayısı (C) için Grid Search yöntemi kullanılarak belirlenir.

6.2.5 Yöntem performansının veri seti üzerinde değerlendirilmesi

Önerilen öznitelik çıkarım yöntemi ile girdisi oluşturulan farklı sınıflandırıcı modellerinin performansları integral-Tabanlı matematiksel yöntem, benzetim modelinde gerçekleştirilen simülasyonlar ve geliştirilen test sisteminde OBN'den toplanan veriler üzerinden değerlendirilmiştir. Bu bölümde, özellikle performansın yüksek olduğu ÖİDD-DVM yöntemi ve ÖİDD-GAKA yöntemi ayrıntılı olarak analiz edilmiştir. Ayrıca kNN, KA ve RO sınıflandırıcılar kullanıldığında önerilen öznitelik çıkarım yönteminin sonuçlara etkisi de irdelenmiştir.

Bu çalışmada gerçekleştirilen makine öğrenimi tabanlı çok sınıflı sınıflandırma deneyleri, Google Colaboratory'de, 12 GB RAM'e sahip Tesla P100 GPU kullanılarak

gerçekleştirilmiştir. Google Colaboratory'de Python programlama dili ve TensorFlow çatısı üzerine inşa edilmiş yüksek seviyeli bir sinir ağı kütüphanesi olan Keras kullanılmıştır. Veri analizi için Pandas, model uygulaması için Scikit-Learn ve veri görselleştirmesi için Seaborn kütüphaneleri kullanılmıştır. Oluşturulan veri seti içe aktarılmış ve rastgele karıştırılmıştır. Veri setinin, %70'i eğitim ve %30'u test için kullanılmıştır. Her modelin en iyi doğruluk puanını veren çok sınıflı sınıflandırıcı model parametreleri Çizelge 6.5'te sunulmaktadır.

Çizelge 6.5 : Parametre seti.

Sınıflandırıcı	Parametre Seti
kNN	n neighbors=3, leaf size=30, metric='minkowski', weights = uniform, p=2.
DVM	kernel=gaussian, cache size=200, max iteration=1, C=200.0, step size= 0.01, $K_l = 3,2$, tol=0.001
KA	criterion=gini, splitter=best, minimum samples split=2, minimum samples leaf=1, ccp alpha=0.0 minimum weight fraction leaf=0.0, presort='deprecated', minimum impurity decrease=0.0
RO	criterion=gini, n estimators=500, minimum samples split=2, minimum samples leaf=1, minimum weight fraction leaf=0.0, minimum impurity decrease=0.0, verbose=0, ccp alpha=0.0
GAKA	loss=deviance, learning rate=0.1, estimators=1000, subsample=1.0, criterion=Friedman MSE, tol=0.0001, minimum samples split=2, ccp alpha=0.0, minimum samples leaf=1, minimum weight fraction leaf=0.0, maximum depth=3, minimum impurity decrease=0.0, validation fraction=0.1

Farklı gürültü seviyeleri altında önerilen hibrit ÖİDD-DVM yönteminin performansı, zaman-frekans domeninde yapılan analizden elde edilen özniteliklerle doğrudan ilişkilidir. DVM, GAKA, KA, RO ve kNN sınıflandırıcılarının test performans skorları Çizelge 6.6'da verilmiştir. Ayrıca, ADD ve önerilen Piramidal ÖİDD'nin doğruluk performansı üzerindeki etkisi de bu çizelgede incelenmektedir. Geliştirilen DVM sınıflandırıcı, ÖİDD katsayılarından elde edilen öznitelikler kullanıldığında yüksek gürültü içeren GKO sinyallerinde dahi başarılı sonuçlar vermektedir. GAKA da test verilerinde doğruluk açısından önemli başarı elde etmiştir. ADD katsayılarından elde edilen öznitelikler kullanıldığında GAKA sınıflandırıcısının performansı, geliştirilen DVM sınıflandırıcısından daha yüksek olmaktadır. KA sınıflandırıcısı, sinyal

ayırıştırma sürecinde ADD yerine ÖİDD kullanıldığında, daha yüksek doğrulukta sınıflandırma performansı göstermektedir. Gerçek zamanlı uygulamalarda sıkça kullanılan KA, ÖİDD ile birlikte yüksek doğruluklu sınıflandırma için de kullanılabilir. Bununla birlikte, KA ile elde edilen sınıflandırma doğruluğu, iyileştirilmiş çekirdek DVM sınıflandırıcısı ile karşılaştırıldığında daha düşük olduğundan bu çalışmada ileri aşamadaki testler için tercih edilmemiştir. kNN sınıflandırıcısının doğruluk performansı ÖİDD ile arttırılsa da yeterli değildir. Çünkü, kNN yöntemi özellikle küçük veri setleri için etkilidir, ancak büyük veri setleri için yüksek hesaplama maliyeti nedeniyle kullanımı sınırlıdır. Ayrıca, veri setindeki gürültüye, anormallere ve boyutluluğa karşı diğer sınıflandırıcılara göre daha hassas olabilir.

Çizelge 6.6 : Sınıflandırıcıların test veri seti doğruluk performansı.

Model	Sınıflandırma Doğruluğu (%)							
	Gürültüsüz		SNR=25dB		SNR=30dB		SNR=40dB	
	ÖİDD	ADD	ÖİDD	ADD	ÖİDD	ADD	ÖİDD	ADD
kNN	99.16	93.13	98.57	88.92	98.76	90.72	99.15	93.09
DVM	99.85	97.28	99.32	91.59	99.50	93.59	99.76	96.62
KA	98.76	95.43	97.95	85.36	98.11	87.86	98.41	92.50
RO	99.39	97.21	98.48	91.39	98.65	93.01	98.97	96.02
GAKA	99.59	97.61	99.17	94.17	99.29	95.01	99.50	96.66

Performansı yüksek olan DVM ve GAKA için her bir GKO sınıfına karşı performansları farklı gürültü seviyeleri altında incelenmiştir. Önerilen olay tanıma yönteminin performansını göstermek için doğru olayları yanlış tanımlanmış olaylardan ayırmaya izin veren bir karışıklık matrisi kullanılmıştır. Karışıklık matrisinde, sütunlar gerçek sınıfları temsil ederken, satırlar tahmin edilen sınıfları temsil etmektedir. Köşegen dışı hücreler yanlış tahmin edilen olaylara karşılık gelirken köşegen hücreler doğru tahmin edilen sınıflara karşılık gelmektedir.

Farklı gürültü seviyeleri için önerilen ÖİDD-DVM yönteminin test sonuçları, Çizelge 6.7, Çizelge 6.8, Çizelge 6.9 ve Çizelge 6.10'da verilen karışıklık matrislerinde gösterilmiştir. Önerilen yöntemde, C9 olayı için minimum doğruluk oranı %97,7 olarak belirlenmiştir ve bu oran 25 dB yüksek gürültü seviyeleri altında elde edilmiştir. Diğer olay sınıfları için ise ÖİDD-DVM yönteminin doğruluk oranı tüm gürültü seviyeleri altında %99'un üzerindedir. Çizelge 6.7'deki karışıklık matrisi, gürültüsüz

koşullar için her GKO sinyalini tanıma doğruluğu hakkında bilgi sağlamaktadır. Önerilen yöntemin doğruluk oranı her sınıf için %99,5'in üzerindedir. Ayrıca, önerilen yöntemin C2 (gerilim çökmesi) ve C4 (gerilim kesintisi) sınıflarını ayırt etmedeki doğruluğu diğer GKO'lardan daha düşüktür. Bunun nedeni, şebeke kodu standartlarında belirtilen gerilim çökmesi ve gerilim kesintisi olaylarındaki ayırmadaki sınır değere çok yakın olan olayların da test verilerinde kullanılmasıdır.

Çizelge 6.7 : ÖİDD-DVM test sonuçları için karışıklık matrisi (gürültüsüz).

		Tahmin edilen sınıflar								
Gerçek		C1	C2	C3	C4	C5	C6	C7	C8	C9
C1		586								
C2			587		3					
C3				630			1			
C4			3		608					
C5						619				
C6							593			
C7								626		
C8									616	
C9									1	612

Önerilen ÖİDD-DVM yönteminin, 40 dB gürültü seviyesinde her GKO olayı için gösterdiği performans Çizelge 6.8'de gösterilmektedir. Önerilen yöntem, düşük gürültülü sinyallerde, gürültüsüz koşullardaki doğruluk oranını korumaktadır.

Çizelge 6.8 : ÖİDD-DVM test sonuçları için karışıklık matrisi (SNR=40 dB).

		Tahmin edilen sınıflar								
Gerçek		C1	C2	C3	C4	C5	C6	C7	C8	C9
C1		645								
C2			553		5					
C3				596			1			
C4			4		594					
C5						639				
C6		1					623			
C7								599		
C8									622	
C9									2	591

Çizelge 6.9'daki karışıklık matrisi, 30 dB yüksek gürültü koşullarında GKO sinyallerini tanıma doğruluğu hakkında bilgi sağlamaktadır. Önerilen ÖİDD-DVM yönteminin performansı incelendiğinde, C9 (çentik) için doğruluk oranının diğer sınıflara göre daha düşük olduğu görülmektedir. Ancak, bu durumda bile önerilen yöntemin C9 olayı için doğruluk oranı %98,18'dir. Çentik etkisi tarafından oluşturulan frekans bileşenleri, klasik harmonik ölçme cihazlarıyla tanımlanamazlar. Önerilen

yöntem, yüksek doğrulukla çentik tespiti yapabilmektedir. Ayrıca, test verilerine neredeyse tüm olası çentik durumlarındaki alan ve derinlik değerleri örneklenmiştir.

Çizelge 6.9 : ÖİDD-DVM test sonuçları için karışıklık matrisi (SNR=30 dB).

		Tahmin edilen sınıflar								
Gerçek		C1	C2	C3	C4	C5	C6	C7	C8	C9
C1		589								
C2			605		3					
C3				619		2				
C4			5		615					
C5						576				
C6				1			584			
C7								596	5	
C8									595	
C9									11	596

SNR değeri 25 dB olan gürültü altında her bir GKO olayı için önerilen yöntemin doğruluk performansı ise Çizelge 6.10'da gösterilmektedir. Açıkça görülmektedir ki önerilen ÖİDD ile elde edilen öznelıklar, çok yüksek gürültü koşullarında bile sınıflandırma doğruluğunu artırmaktadır.

Çizelge 6.10 : ÖİDD-DVM test sonuçları için karışıklık matrisi (SNR=25 dB).

		Tahmin edilen sınıflar								
Gerçek		C1	C2	C3	C4	C5	C6	C7	C8	C9
C1		596								
C2			601		6					
C3				613		3				
C4			8		618					
C5						583				
C6				1			576			
C7								600	5	
C8									591	
C9									14	592

Performansı yüksek olan bir diğer önerilen GKO sınıflandırma yöntemi olan ÖİDD-GAKA için her bir GKO sınıfı için doğruluk sonuçları da farklı gürültü seviyeleri altında ayrıntılandırılmıştır. Piramidal ÖİDD-GAKA yönteminin farklı gürültü seviyeleri için test sonuçları Şekil 6.15, Şekil 6.16 ve Şekil 6.17'de verilmiştir. Şekil 6.15'teki karışıklık matrisi, piramidal ÖİDD-GAKA yönteminin gürültüsüz koşullardaki performansını detaylı bir şekilde göstermektedir. Şekilde görüldüğü gibi, önerilen yöntem, her GKO sınıfı için doğruluk oranı %99,5'in üzerindedir. Ayrıca, bazı sınıflar için doğruluk performansı %100'dür. Bununla birlikte, ÖİDD-GAKA'nın C4

(gerilim kesintisi) ve C2 (gerilim çökmesi) tanımlamalarında doğruluk oranı diğer GKO sınıflarına göre daha düşüktür. Bunun nedeni, C2 ve C4'ü ayıran limit değere çok yakın olayların bulunmasıdır.

	C1	C2	C3	C4	C5	C6	C7	C8	C9
C1	603								
C2		607		8					
C3			610			2			
C4		8		617					
C5					573				
C6	1					582			
C7							586		
C8								596	
C9								3	598

Tahmin Edilen Etiket

Şekil 6.15 : ÖİDD-GAKA test sonuçları (gürültüsüz veri seti).

Şekil 6.16'da, 40 dB düşük gürültü koşullarında her tür GKO sinyali için ÖİDD-GAKA'nın detaylı performansı gösterilmektedir. Geleneksel yöntemlerde, gürültü içeren sinyallerde doğruluk performansı saf sinyallere göre oldukça düşmektedir. Ancak, önerilen yöntemin doğruluk oranı her GKO sınıfı için %99'dan daha yüksektir. Geleneksel yöntemlerdeki zayıf gürültü bağıışıklığı sorunu önerilen yaklaşımla ortadan kaldırılarak bu başarı elde edilmiştir. Şekil 6.17, 30 dB gürültü altında her tür olay sinyali için ÖİDD-GAKA'nın detaylı performansını göstermektedir. C9 (çentik) için doğruluk oranı diğer sınıflara göre %97,7 olup daha düşüktür. Test verilerine çentik olayının alan ve derinlik parametrelerinin tüm olası değerleri eklenmiştir. Bu durumda dahi yüksek gürültü altındaki performans değerleri de yüksektir. Bu sonuçlar, ÖİDD-GAKA yönteminin GKO sınıflandırmasında yüksek doğruluk elde edebildiğini göstermektedir. Ayrıca, piramidal ÖİDD ile elde edilen öznelilikler sayesinde sınıflandırıcının doğruluk performansı yüksek gürültü altında bile gürültüsüz koşullara benzerdir.

	C1	C2	C3	C4	C5	C6	C7	C8	C9
C1	637								
C2		549		8					
C3			599			3			
C4		9		601					
C5					618				
C6	1					619			
C7							620		
C8								630	
C9								6	589

Tahmin Edilen Etiket

Şekil 6.16 : ÖİDD-GAKA test sonuçları (SNR=40 dB).

	C1	C2	C3	C4	C5	C6	C7	C8	C9
C1	591								
C2		599		9					
C3			623			3			
C4		10		609					
C5					581				
C6	1		2			585			
C7							589		
C8								603	
C9								14	596

Tahmin Edilen Etiket

Şekil 6.17 : ÖİDD-GAKA test sonuçları (SNR=30 dB).

En iyi performansı gösteren ÖİDD-DVM ve ÖİDD-GAKA yöntemleri, Bölüm 4.2’de detayları açıklanan mikroşebeke benzetim modelinde gerçekleştirilen senaryolar sonucunda oluşturulan GKO veri seti ile de test edilmiştir. Bu veri setinde, beş farklı olay sınıfı için 90 örnek bulunmaktadır. Simülasyonlarda örnekleme frekansı 10 kHz olarak seçilmiş olup ana frekans 50 Hz’dir. Çizelge 6.11’de test sonuçları verilmiştir. Genel olarak, matematiksel verilerle elde edilen doğruluk sonuçlarının simüle edilen verilerle elde edilen sonuçlarla benzer olduğu görülmektedir. ÖİDD-GAKA yönteminde, simüle edilen sinyallerde sadece gerilim çökmesi ve gerilim kesintisi olayları için eşik değerine yakın sorunlar oluşmuş ve bu da doğruluğun azalmasına neden olmuştur. ÖİDD-DVM ise tüm veride %100 doğruluk göstermiştir. Özetle, önerilen hibrit yöntemler, GKO’ları doğru bir şekilde tanımlama ve kategorize etme konusunda uygunluk ve yetenek göstererek, mikroşebeke sistemlerinde genel güç kalitesi değerlendirmesi ve yönetimine katkı sağlar.

Çizelge 6.11 : Benzetim modelinden üretilen veri seti üzerindeki performans.

Olay Sınıfları	Test Örnekleri	ÖİDD-GAKA Doğru Tahmin	ÖİDD-DVM Doğru Tahmin
Gerilim çökmesi (C2)	20	19	20
Gerilim sıçraması (C3)	20	20	20
Gerilim kesintisi (C4)	20	19	20
Harmonikler (C5)	15	15	15
Osilasyonlu geçici olay (C7)	10	10	10
Çentik (C9)	5	5	5

Son olarak, en iyi performansı gösteren ÖİDD-DVM ve ÖİDD-GAKA, Bölüm 4.3’te detayları açıklanan test sisteminde toplanan gerçek GKO veri seti ile de test edilmiştir. GKO sinyalleri, veri toplama sistemi ile 10 kHz örnekleme frekansında toplanmıştır. Olay süresi on periyottur ve 2000 noktadan oluşmaktadır. Eğitilmiş modeller elde edilen GKO verilerini tanımlamak için de kullanılmıştır. Önerilen ÖİDD-DVM ve ÖİDD-GAKA yöntemlerinin deneysel veri sonuçları Çizelge 6.12’de gösterilmiştir. Her iki yöntem de gerçek veri seti için benzer sonuçlar göstermektedir. Ayrıca ADD ile çıkarılan öznelikleri kullanan hibrit modellerin de doğruluk sonuçları bu çizelgede verilmektedir. Sonuç olarak, ADD-Tabanlı geliştirilen ancak gürültü altında performansı düşük olan sınıflandırıcıların performansı ÖİDD ile iyileştirilmiştir.

Çizelge 6.12 : Gerçek veri seti üzerindeki performans.

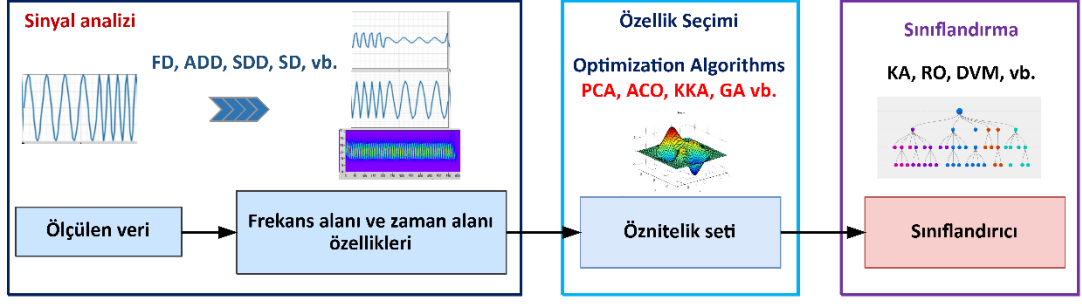
Olay Sınıfları	Test Örnekleri	Doğru Tahmin ÖİDD-DVM		Doğru Tahmin ÖİDD-GAKA	
		ÖİDD	ADD	ÖİDD	ADD
Gerilim çökmesi	35	34	29	34	29
Gerilim sıçraması	35	34	30	34	30
Harmonikler	15	15	15	15	15
Osilasyonlu geçici olay	20	20	15	20	15
Çentik	15	15	14	15	14

6.3 Derin Öğrenme-Tabanlı Yöntem ile GKO Sınıflandırma

Bu bölümde, öncelikle önerilen ESA, UKSB ve hibrit model olmak üzere çoklu derin ağ modelleri ile değiştirilmiş ağırlıklı çoğunluk oylaması (Weighted Majority Voting - AÇO) içeren yöntem ayrıntılandırılmıştır. Sonrasında, 19 sınıflık veri seti hakkında bilgi verilmiş ve yazılım-donanım sistemine değinilmiştir. Performans metrikleri tanıtıldıktan sonra farklı modellerin gürültü altındaki performansları değerlendirilmiştir. Son aşamada ise simülatif ve gerçek GKO olayları için geliştirilen yöntem sonuçları verilmiştir.

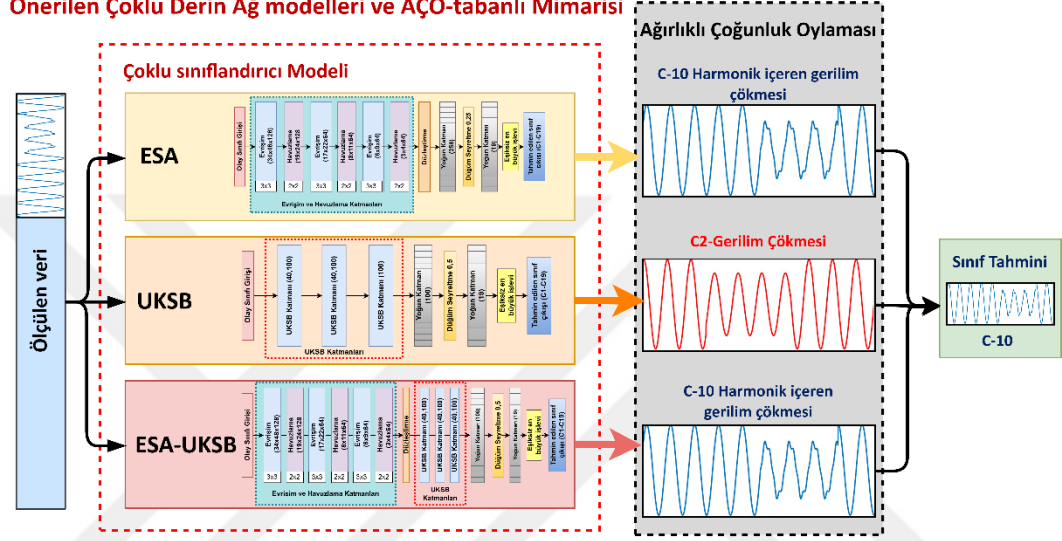
6.3.1 Önerilen derin ağ modelleri ve AÇO-Tabanlı yöntem

DG-Tabanlı mikroşebeke sistemlerinde GKO sınıflandırması için çoklu DÖ modelleri ve modifiye edilmiş AÇO algoritması temelli bir yöntem önerilmiştir. Yönteme ait akış diyagramı Şekil 6.18’de verilmiştir. Geleneksel GKO sınıflandırma yöntemleri genellikle üç aşamadan oluşur: sinyal analizi, öznitelik çıkarımı/seçimi ve sınıflandırıcı ile tahminin belirlenmesi. Ancak bu yöntemler çeşitli dezavantajlara ve limitlere sahiptir. Sinyal analizi yöntemleriyle öznitelik çıkarma işlemi yoğun bir hesaplama yüküne sahiptir ve bu yöntemler gürültüden etkilenmeye eğilimlidir. Öznitelik seçim süreci ise kullanılan filtreleme ve optimizasyon yöntemleri ile karmaşık ve zaman alıcı bir sürece dönüşür. Ayrıca, bu yöntemlerde insan müdahalesi vardır ve aşamalar arasında kapalı döngü geri bildirim bulunmamaktadır. Gerçekleştirilen tez çalışmasında, çoklu DÖ modeline dayalı AÇO mekanizmasını kullanan bir hibrit yöntem karmaşık ve tekli GKO’ları sınıflandırmak için önerilmekte olup bu dezavantajlar ortadan kaldırılmaktadır.



Geleneksel 3-Aşamalı Mimari

Önerilen Çoklu Derin Ağ modelleri ve AÇO-tabanlı Mimaris



Şekil 6.18 : Önerilen yöntem ile geleneksel yöntemlerin karşılaştırılması.

Otomatik öznitelik çıkarma ve sınıflandırma için ESA, UKSB ve Hibrit (ESA-UKSB) modeller kullanılmaktadır. Bu modeller için en yüksek başarıma sahip mimarilere ait parametreler sırasıyla Şekil 3.2, Şekil 3.4 ve Şekil 3.5'te verilmiştir. Çoğunluk oylamasında (ÇO) en çok oyu alan sınıf, atanan son sınıf olarak seçilmektedir. Çalışma kapsamında, önerilen modifiye AÇO yönteminin performans üstünlüğünü kanıtlamak için geleneksel ÇO yöntemi ile de testler gerçekleştirilmiştir. Tüm sınıflar eşit oy alırsa, en yüksek performans oranına sahip sınıfa karar verilir ve Denklem 6.7 ile verilen her bir sınıflandırıcı C_j 'nin oylamasıyla \hat{y} sınıf etiketi tahmin edilir.

$$\hat{y} = \text{mode}\{C_1(x), C_2(x), \dots, C_m(x)\} \quad (6.7)$$

Denklem 6.7 ile verilen her bir sınıflandırıcının C_j oyu ile sınıf etiketi \hat{y} tahmin edilir. ÇO'dan farklı olarak AÇO'da, W_j ağırlığını C_j sınıflandırıcısıyla ilişkilendirerek ağırlıklı çoğunluk oyu hesaplanır:

$$\hat{y} = \arg \sum_{j=1}^m w_j \chi_A(C_j(x) = i) \quad (6.8)$$

Denklem 6.8’de $\chi_A [C_j(x) = i \in A]$ karakteristik fonksiyondur ve A , benzersiz sınıf etiketleri kümesidir [151]. Ayrıca diğer sınıflandırıcı daha iyi ise model için ağırlıklar artırılır. C_{xL} ve C_{yL} değerlerinin C_j ’nin en kafa karıştırıcı çıktı etiketleri olduğu, C_{kL} ve C_{mL} ’nin doğrulama sürecinde en iyi tahmin edilen çıktı etiketleri olduğu durum için ağırlıklar Denklem 6.9’da verilmiştir. Yöntemde, sürecin başında W_j “1” olarak belirlenir. Denklemde, α_i artış veya azalma katsayısıdır. α_i katsayısı değeri ampirik olarak gerçekleştirilen deneylerle belirlenmiştir. α_i ’nin artması ağırlık farkını artırır ve düzgün karar verilmesine izin vermez. Bunun yanı sıra, α_i ’nin azalması farkı azaltır ve olumlu etki edemez. 0-1 arasında α_i değeri için deneyler gerçekleştirilmiş olup en iyi sonuç 0,7 olarak belirlenmiştir.

$$W_j = \begin{cases} W_j - \alpha_i & C_j = C_{xL} \text{ veya } C_{yL} \\ W_j + \alpha_i & C_j = C_{kL} \text{ veya } C_{mL} \\ W_j & \text{Aksi takdirde} \end{cases} \quad (6.9)$$

Değiştirilmiş AÇO algoritmasının sözde kodu aşağıdaki gibidir:

-
1. C_j ağırlıklarını $W_j = 1$ ile başlat,
 2. Doğrulama setindeki her χ_A için tahminleri topla,
 3. En çok karışan sınıfları belirle: C_{xL}, C_{yL} ,
 4. En iyi tahmin edilen sınıfları belirle: C_{kL}, C_{mL} ,
 5. En çok karışan sınıflar için ağırlıkları güncelle: $W_j = W_j - \alpha_i$,
 6. En iyi tahmin edilen sınıflar için ağırlıkları güncelle: $W_j = W_j + \alpha_i$,
 7. Test setindeki her χ_A için tahminleri al: $\hat{y} = \arg \max \sum_{j=1}^m w_j \chi_A(C_j(x) = i)$.
-

6.3.2 Tekli-çoklu GKO içeren veri seti ve donanım/yazılım sistemi

Integral tabanlı-matematiksel model ile üretilen GKO veri setinde, önerilen diğer yöntemlerden farklı olarak tekli (örnek: C2-gerilim çökmesi), ikili (örnek: C10-harmonik içeren gerilim çökmesi), üçlü (örnek: C16-harmonik ve kırpışma içeren gerilim çökmesi) ve dördü (örnek: C18-harmonik, osilasyonlu geçici olay ve kırpışma içeren gerilim çökmesi) tekli ve kompleks olaylar yer almaktadır. Veri seti, 8 tekli ve 10 kompleks GKO olayı ile nominal sinyal olmak üzere toplam 19 sınıf içermektedir. GKO sınıfları Çizelge 6.13’te verilmiştir.

Çizelge 6.13 : Tekli ve kompleks GKO sınıfları.

Sınıf	Olay
C1	Nominal
C2	Gerilim çökmesi
C3	Gerilim sıçraması
C4	Gerilim kesintisi
C5	Harmonikler
C6	Kırpışma
C7	Osilasyonlu geçici durum olayı
C8	Darbeli geçici durum
C9	Çentik
C10	Harmonik içeren gerilim çökmesi
C11	Harmonik içeren gerilim sıçraması
C12	Kırpışma içeren gerilim çökmesi
C13	Kırpışma içeren gerilim sıçraması
C14	Osilasyonlu geçici durum olayı içeren gerilim çökmesi
C15	Osilasyonlu geçici durum olayı içeren gerilim sıçraması
C16	Harmonik ve kırpışma içeren gerilim çökmesi
C17	Harmonik ve kırpışma içeren gerilim sıçraması
C18	Harmonik, geçici durum olayı ve kırpışma içeren gerilim çökmesi
C19	Harmonik, geçici durum olayı ve kırpışma içeren gerilim sıçraması

Çalışmada kullanılmak için seçilen 19 sınıf için GKO parametreleri Çizelge 6.14’te verilmiştir. Integral-Tabanlı matematiksel model ile üretilen veri sayısı her sınıf için 2000 olmak üzere toplamda 38000’dir. Her deney için, tüm veri setinin sırasıyla eğitimde %70’i, doğrulamada %10’u ve testte %20’si kullanılmıştır. Gerçekleştirilen deneyler, Google Colaboratory’de, 12 GB RAM’e sahip Tesla P100 GPU kullanılarak gerçekleştirilmiştir. Google Colaboratory’de TensorFlow çatısı üzerinden Python programlama dili olan Keras kütüphanesi kullanılmıştır.

Çizelge 6.14 : GKO parametreleri.

Parametreler	
Temel frekans	50 Hz
Örnekleme frekansı	10 kHz
Temel frekansın döngü sayısı	10 periyot - 2000 nokta - 0.2 s
GKO sinyallerinin gerilim genlik değeri	p.u.
Her sınıf için örnek sayısı	2000

6.3.3 Önerilen yöntemin farklı koşullarda performans değerlendirmesi

Deneyle, DESA, DUKSB ve DESA-DUKSB hibrit modelleri kullanarak gerçekleştirilmiştir. Her bir yöntem için en iyi modeli belirlemek amacıyla çeşitli testler yapılmıştır. Çizelge 6.15, 30-50 dB SNR değerleri arasında gürültü eklenerek oluşturulan veri setinde önerilen modellerin her bir sınıf için doğruluk performansını göstermektedir. Her bir sınıflandırma modeli için en fazla karıştırılan sınıflar ile en başarılı tahmin edilen sınıflar belirlenmiş olup Çizelge 6.16'da verilmiştir. Ayrıca bu sonuçlar Çizelge 6.15'te renklendirilmiştir. Tekil GKO'ları sınıflandırmada DESA başarılı bir performans sergilerken, özellikle üç veya daha fazla olay içeren kompleks GKO'ları sınıflandırmada DUKSB daha üstün sonuçlar göstermektedir.

Çizelge 6.15 : Derin modellerin performans karşılaştırması.

Sınıf	Farklı gürültü seviyesi altında test doğruluğu (%)		
	DESA	DUKSB	DESA-DUKSB
C1	99,76	98,01	99,88
C2	98,59	99,76	99,7
C3	99,93	98,04	99,23
C4	99,81	97,99	96,11
C5	100	98,01	99,17
C6	99,85	95,76	96,53
C7	99,88	93,43	98,68
C8	100	98,74	99,27
C9	97,32	91,2	99,23
C10	95,92	98,88	99,23
C11	98,63	98,13	97,89
C12	99,01	98,55	97,63
C13	99,18	98,67	98,11
C14	93,66	98,13	98,56
C15	97,32	98,32	98,62
C16	92,88	98,78	94,78
C17	92,82	98,52	94,52
C18	90,76	98,95	98,95
C19	89,17	98,01	94,01
Genel	97,08	97,67	97,94

Önerilen yöntemde, karıştırılan sınıflar için ağırlıklar 0,7 katsayısı ile orantılı azaltılmaktadır. Benzer şekilde, iyi tahmin edilen ağırlıklar ise 0,7 katsayısıyla orantılı olarak Denklem 6.9’da gösterildiği gibi güncellenmiştir. Elde edilen yeni ağırlıklara göre test seti için AÇO uygulanmıştır.

Çizelge 6.16 : En çok karıştırılan ve en iyi tahmin edilen sınıflar.

Model	En çok karıştırılan sınıflar	En iyi tahmin edilen sınıflar
DESA	C2, C10, C14, C16, C17, C18, C19	C1, C3, C4, C5, C6, C7, C8, C11, C12, C13
DUKSB	C1, C7, C9	C2, C10, C15, C16, C17, C18, C19
DESA-DUKSB	C4, C16, C17, C19	C1, C7, C9, C10, C15

Çizelge 6.17, farklı SNR değerlerinde gürültü içeren ve gürültüsüz koşullarda, AÇO ve geleneksel çoğunluk oylaması yöntemleri için doğruluk performanslarını göstermektedir. Gürültü içermeyen verilerde, önerilen çoklu DÖ modeli ile kullanılan AÇO mekanizmasıyla doğrulama doğruluğu ve test doğruluğu %99’un üzerine çıkmaktadır. Ayrıca, 30 dB’lik yüksek gürültülü koşullarda %98,12 doğrulama ve %98,05 test doğruluğu ile en iyi performans önerilen yöntemle elde edilmektedir. Modifiye edilmiş AÇO temelli çoklu derin sınıflandırıcı içeren yöntemde, geleneksel üç aşamalı süreçten farklı olarak kapalı döngü derin modeller otomatik öznelik çıkarma ve sınıflandırma için kullanılmaktadır. Yeni yöntem hem doğruluk hem de gürültüye karşı dayanıklılık açısından kompleks GKO sınıflandırma tekniklerine göre üstün performans sergilemektedir. Ayrıca, modifiye edilmiş AÇO yöntemi, ÇO’ya göre daha iyi performans sergilemektedir. AÇO’nun tek dezavantajı, doğrulama raporlarının gözlemlenerek değişiklik kurallarının güncellenmesinin gerekmesidir.

Çizelge 6.17 : AÇO mekanizması ile tekli ve çoklu ağ modellerinin performansı.

Model	Oylama Yöntemi	Gürültüsüz (%)		SNR=40dB (%)		SNR=30 dB (%)	
		Val.	Test	Val.	Test	Val.	Test
DESA	-	98.62	98.25	96.89	96.73	96.32	96.26
DUKSB	-	98.58	98.15	97.92	97.85	97.23	97.02
DESA-DUKSB	-	98.60	98.23	98.25	98.01	97.61	97.58
DESA, DUKSB, DESA-DUKSB	ÇO	99.28	99.08	98.18	98.08	97.54	97.51
DESA, DUKSB, DESA-DUKSB	AÇO	99.34	99.26	98.62	98.58	98.12	98.05

AÇO-derin modeller içeren hibrit yöntem Bölüm 4.2’de detayları açıklanan mikroşebeke benzetim modelinde gerçekleştirilen senaryolar sonucunda oluşturulan GKO veri setiyle de test edilmiştir. Simülasyonlarda tüm parametreler Çizelge 6.14 ile aynıdır. Test setinde, DG çıkışlarının/yüklerinin farklı kombinasyonları kullanılmıştır. Kaydedilen test setinde gerilim çökmesi/sıçraması/kesintisi ve nominal durum dalga örnekleri bulunmaktadır. Çentik olayını oluşturmak için, altı darbeli bir dönüştürücü aracılığıyla doğrusal olmayan bir yük beslenir. Ana harmonik kaynaklarının sırası, fazı, konumu, miktarı ve büyüklüğü gibi faktörler dikkate alınarak simüle edilen farklı olay kombinasyonları harmonik sınıfına dahil edilmiştir. Mikroşebekelerde, çevresel faktörler (ışınım, rüzgar hızı vb.), DG işletme koşulları, inverter kontrol stratejileri ve doğrusal olmayan yüklerdeki dengesizlikler tekli GKO’lara yol açmakla beraber kompleks olaylar da meydana getirmektedir. Ayrıca, DG’ler ve dağıtım ağı arasındaki güç etkileşimi nedeniyle GKO’lar üst üste gelecek ve daha karmaşık bir tip oluşturacaktır. Bu tür kompleks olaylar, geleneksel üç aşamalı süreçte ihmal edilmeye meyillidir ve cihazların hizmet ömrünü kısaltmaktadır, hasara neden olmaktadır ve güvenliği tehlikeye atmaktadır. Önerilen yöntemin sınıflandırma doğruluk sonuçları Çizelge 6.18’de gösterilmektedir. AÇO-derin modeller içeren hibrit yöntem, kısa devre arızalarının ve endüstriyel sürücü sistemleri ile mikroşebekelerde anahtarlanan yüklerin/kapasitelerin varlığından kaynaklanan tekli ve kompleks GKO’ları algılamaktadır ve yüksek doğrulukta sınıflandırmaktadır. Simülatif veri sonuçları Çizelge 6.18’de gösterilmektedir. Simülatif verilerde genel doğruluk %98,4 olup matematiksel model ile üretilen verilerdeki sınıflandırma performansı ile benzerdir.

Çizelge 6.18 : Simülatif veri sonuçları.

GKO sınıfları	Test örnekleri	Doğru Tahmin
Gerilim çökmesi	20	20
Gerilim sıçraması	20	20
Gerilim kesintisi	20	20
Harmonikler	15	15
Osilasyonlu geçici durum olayı	10	9
Çentik	5	5
Harmonik içeren gerilim çökmesi	7	7
Harmonik içeren gerilim sıçraması	8	8
Osilasyonlu geçici durum olayı	10	9
içeren gerilim çökmesi	10	9
Osilasyonlu geçici durum olayı	10	10
içeren gerilim sıçraması	10	10

AÇO-derin modeller içeren hibrit yöntem için gerçek veri sonuçları ise Çizelge 6.19'da gösterilmiştir. Gerçek veriler için sınıflandırma doğruluğu %97,27'dir. Karmaşık GKO'lar için en düşük performans harmonik içeren gerilim çökmesi olayı için gözlemlenmektedir ve bu durum için bile sınıflandırma doğruluğu %93,33'tür.

Çizelge 6.19 : Gerçek veri sonuçları.

GKO sınıfları	Test örnekleri	Doğru Tahmin
Gerilim çökmesi	35	34
Gerilim kesintisi	35	34
Harmonikler	15	15
Osilasyonlu geçici durum olayı	10	10
Harmonik içeren gerilim çökmesi	15	14

7. LİTERATÜRDEKİ YÖNTEMLERLE KARŞILAŞTIRILMA

Bu bölümde, önerilen AMOD çalışma ve GKO tespit/sınıflandırma yöntemleri iki farklı başlık altında literatürdeki çalışmalarla karşılaştırılmıştır. AMOD çalışma yöntemleri, tespit süresi, simülasyon/uygulama, ADB, GK'ye etki ve GKO'lardan ayırt edilebilme/edilememe parametrelerine göre karşılaştırılmıştır. GKO tespit ve sınıflandırma yöntemleri ise sınıflandırılan olay sayısı ve farklı gürültü seviyelerinde başarımlarına göre karşılaştırılmıştır.

7.1 Önerilen AMOD Tespit Yönteminin Literatürle Karşılaştırılması

Önerilen AMOD çalışma tespit yöntemi, Çizelge 7.1'de literatürdeki yöntemlerle karşılaştırılmıştır. Referans [152]'deki çalışmada aktif frekans kayması ve dalgacık entropisinin bir kombinasyonu kullanılmıştır. Tespit süresi diğer yöntemlere göre daha düşüktür ancak bu yöntemde enjekte edilen bozucu sinyal nedeniyle GK bozulması yüksek orandadır. Başka bir aktif yöntemde ise [153], frekans kaydırma yöntemi kullanılmıştır. GK'ye olumsuz etkileri olan bu yöntemde ADB oldukça düşürülmüştür. Referans [92], ADB'yi azaltmak için yine aktif bir yöntem önermiştir. Ancak bu çalışmada, tespit süresine ilişkin herhangi bir bilgi verilmemiştir. Referans [154]'te, birden fazla DG içeren sistemlerde, bara gerilim indeksi-Tabanlı pasif yöntem önerilmiştir. Yöntem, basit ve kolaylıkla uygulanabilir olmasına göre tespit süresi oldukça yüksektir. DPD ve KA-Tabanlı geliştirilmiş pasif yöntemde [53], birçok ölçeklenebilirlik sorunu vardır ve çalışma simülasyon aşamasında kalmıştır. DD ve DSA'yı beraber kullanan yoğun işlem yükü içeren gelişmiş pasif yöntemde [83], ADB neredeyse sıfıra yakın olup tespit süresi ise 180 ms'dir. Ancak bu çalışma da simülasyondan öteye geçememiştir. Ayrıca, kullanılan öznitelik matrisi oldukça büyük boyutta olup yoğun işlemci performansı gerektirmektedir. Referans [93]'te, ADD-Tabanlı yöntem, gerçek zamanlı AMOD çalışma tespiti için asenkron generatör tipi rüzgar türbinlerine uygulanmıştır. Tespit süresi 200 ms'dir ve GK'ye olumsuz bir etki yoktur. Ancak bu çalışmada, AMOD çalışma testindeki en önemli kriterlerden biri olan ADB ele alınmamıştır. Referans [70] ve Referans [155]'teki çalışmalar AMOD

çalışma durumunu daha hızlı tespit etse de bu çalışmalar gerçek zamanlı bir test sistemine uygulanmamıştır. Önerilen yöntem ise gerçek zamanlı bir DG sistemde test edilmiştir. Aynı zamanda, hem neredeyse sıfır olan bir ADB'ye sahiptir ve tespit süresi belirtilen standartların altındadır.

Çizelge 7.1 : Önerilen yöntemin literatürdeki yöntemlerle karşılaştırılması.

Kategori	Referans	Yöntem	Tespit süresi (ms)	Test Sistemi	ADB	GK Bozulması
Hibrit	[152]	DD+ Frekans kaydırma	320 ms	Simülasyon	Neredeyse sıfır	Var
Aktif	[153]	Akım Enjeksiyonu	60 ms	Simülasyon	Küçük	Var
	[30]	Aktif RoCoF	200 ms	Simülasyon	Küçük	Var
Geleneksel Pasif	[154]	Gerilim indeksi	300 ms	Simülasyon	Neredeyse sıfır	Yok
	[53]	DPD + KA	5 ms	Simülasyon	Neredeyse sıfır	Yok
	[83]	DD + DSA	180 ms	Simülasyon	Neredeyse sıfır	Yok
Gelişmiş Pasif	[60]	SDD	110 ms	Gerçek zamanlı	Neredeyse sıfır	Yok
	[93]	ADD	200 ms	Gerçek zamanlı	---	Yok
	[92]	YSA	---	Simülasyon	Küçük	Var
	[70]	AMA	2 periyot	Simülasyon	Neredeyse sıfır	Yok
	[155]	VMA + MSE	1 periyot	Simülasyon	Neredeyse sıfır	Yok
	---	Önerilen yöntem	75 ms	Gerçek zamanlı	Neredeyse sıfır	Yok

Önerilen geliştirilmiş pasif yöntem literatürdeki DD-Tabanlı yöntemlerle test sistemi sonuçlarına göre karşılaştırılmıştır. ÖİDD-Tabanlı AMOD çalışma tespit yaklaşımının farklı AMOD ve AMOD olmayan koşulların gerçekleştirilebildiği deney sisteminde üstünlükleri doğrulanmıştır. Sonuçlar, piramidal ÖİDD'nin, Çizelge 7.2 ve Çizelge 7.3'te gösterildiği gibi mevcut DD yöntemlerinden daha iyi performans sergilediğini göstermektedir. AMOD ve AMOD çalışma olmayan durumların sınıflandırılması, yüksek gürültü koşullarında bile önerilen yöntemle önemli ölçüde iyileştirilmiştir. Önerilen yöntem, AMOD çalışmayı yaklaşık sıfır ADB ile 75 ms'de tespit etmektedir. Sonuç olarak, ÖİDD-Tabanlı AMOD çalışma tespit yöntemi, gerçek zamanlı olarak en iyi performansa sahiptir ve YEK-Tabanlı DG'lerde AMODu tespit etmek için en uygun olan yöntemdir.

Çizelge 7.2 : Çalışılan DD-Tabanlı otomatik tespit yöntemlerinin karşılaştırılması.

	Tespit süresi (ms)	Algılama Süresi (ms)	ADB
ADD	74,730	74,721	$(\Delta P) / P_{Load} \ll -33\%$. Ayrıca, yüksek güçlü motor başlatma koşulu ayırt edilemiyor.
SDD	105,455	106,329	Neredeyse sıfır
Önerilen yöntem	75,145	75,321	Neredeyse sıfır

Çizelge 7.3 : Önerilen yöntemin literatürdeki yöntemlerle karşılaştırılması.

Özellikler	ADD	SDD	Önerilen yöntem
Gürültü hassasiyeti	Yüksek	Orta	Çok düşük
Tepe noktası tespit doğruluğu	Güvenilir değil	---	Robust
Tepki süresi	Kısa	Uzun	Kısa
DG'ler için AMOD/ GKO ayırımı yapabilme	Uygun değil	Uygun	En uygun

7.2 Önerilen GKO Sınıflandırma Yöntemlerinin Literatürle Karşılaştırılması

Önerilen GKO sınıflandırma yöntemleri, Çizelge 7.4'te literatürdeki yöntemlerle karşılaştırılmıştır. Önerilen ÖİDD-DVM yöntemi ile elde edilen GKO sınıflandırma doğruluğu, literatürdeki güncel çalışmaların çoğuna göre daha yüksektir. Bazı yöntemlerin [90,99,104,156] yüksek doğruluğa sahip olduğu gözlemlenmektedir; ancak düşük ve yüksek düzeyde gürültü koşullarında bu yöntemlerin sınıflandırma doğruluğu hakkında bilgi verilmemektedir. SD ve Adaptif olasılıksal sinir ağı (AOSA) [90], değişken mod ayrıştırması (DMA)-DVM [157] ve kuaternion dalgacık dönüşümü (KDD)-DVM [100] hibrit yöntemlerinin önerildiği çalışmalar, diğer GKO sınıflandırma yöntemlerinden daha fazla öznetelik kullanmaktadır. Birçok özneteliğin kullanılması sınıflandırma performansını artırabilir, ancak hesaplama süresini de artırır. ÖİDD-DVM'in, farklı gürültü seviyeleri altında ve gürültü olmayan koşullarda GKO'lar için sınıflandırma doğruluğu, [106,156] referanslarındaki DÖ-Tabanlı yaklaşımlar dışında diğer yöntemlerden daha yüksektir. Referans [156]'da yüksek karmaşıklığa sahip 1D ve 2D sinyallere uygulanan DESA kullanılmaktadır. Bu nedenle, önerilen DESA yönteminin gerçek zamanlı uygulamalarda kullanılması zorluklar içermektedir. Referans [106]'da ise hem Wigner-Ville ayrıştırması (WVA) hem de DESA kullanarak bir hibrit yöntem önerilmiştir. Bu yöntemde sınıflandırma doğruluğu çok yüksektir, ancak hem bir sinyal analizi yöntemi hem de karmaşık bir

sınıflandırıcı mimarisi kullanması büyük bir işlem yükünü beraberinde getirir. Önerilen ÖİDD-DVM'in, düşük ve yüksek düzeyde gürültü koşullarında sınıflandırma doğruluğu sırasıyla %99,76 ve %99,50'dir. Çizelge 7.4'te gösterildiği gibi, birçok çalışmada DD kullanılmaktadır [70, 90, 91, 99, 100, 101]: Ancak bu yöntemler, özellikle gürültülü sinyallerin analizinde birçok eksiklik içermektedir. Referans [70]'te ampirik dalgacık dönüşümü (AKDD) ve Referans [101]'de ise dalgacık tabanlı küresel bozulma oranı (DKBO) yöntemleri, tez kapsamında önerilen DVM yöntemiyle beraber kullanılmıştır. Ancak yüksek gürültü altında bu yöntemlerde sınıflandırma doğruluğu oldukça düşmektedir. Sinyaldeki gürültü oranı arttıkça, literatürdeki DD-Tabanlı GKO sınıflandırma sistemlerinin güvenilirliği azalmaktadır. Bu eksiklikler, önerilen yöntemle giderilmiştir.

Çizelge 7.4 : GKO sınıflandırma yöntemlerinin literatürle karşılaştırılması.

Yöntem	Sınıf sayısı	Doğruluk (%)		
		Saf	40 dB	30 dB
SD - AOSA [89]	11	98.2	---	---
DPD - DVM[90]	8	99.66	---	---
ADD - OSA [91]	9	99.87	98.6	95.2
HFD - YSA [162]	8	---	93.95	95.65
SD - KA [161]	13	99.28	98.8	97.49
AKDD - DVM [70]	9	97.22 (25-55 dB karışık veri)		
SD - DVM [71]	9	97.77 (20 dB veri)		
BKV - DD [154]	8	99.66	---	---
1D - 2D DESA [156]	13	99.97	---	---
DMA - DVM [157]	9	99.66	---	99.33
KDD - DVM [100]	14	99.12	---	97.28
DKBO - DVM [101]	10	94.2 (20-50 dB karışık veri)		
SD - NSGA-II [161]	15	96.43(20 dB veri)		
SD - OSA [102]	9	99.26	99.13	98.63
SD - OSA [104]	11	97.4	---	---
DESA [107]	16	99.96	99.66	98.13
ESA- UKSB [108]	6	84.76 (gerçek veri)		
WVA - ESA[106]	9	99.67 (10-40 dB karışık veri)		
SD - KA - GA [159]	13	96.1 (simülatif Nordic 32 sistem)		
SD - BKV - PSO [158]	8	93.25 (yüksek gürültülü koşullar)		
ÖİDD-BKV	9	94.96 (20-40 dB karışık veri)		
ÖİDD-DVM	9	99.85	99.76	99.50
Piramidal ÖİDD-GAKA	9	99.59	99.50	99.29
AÇO-Derin modeller	19	99.26	98.58	98.05

Önerilen piramidal ÖİDD-GAKA hibrit GKO sınıflandırma yöntemi de literatürdeki derin ağ modelleri hariç diğer yöntemlerde göre sınıflandırma doğruluğu için daha iyi performans vermektedir [90,99,100,104,156,157]. Referans [106]'da önerilen WVD-ESA hibrit yönteminin, matematiksel veriler için sınıflandırma doğruluğu çok yüksektir, ancak kırışma gibi deneysel sinyaller için bu oran %81'e düşmektedir. Piramidal ÖİDD-GAKA, 40 dB gürültü altında %99,50 ve 30 dB gürültü altında %99,29 sınıflandırma doğruluğuna sahiptir. Geleneksel çalışmalarda alan dönüşüm yöntemleri kullanılmıştır, ancak gürültülü koşullarda başarımları düşüktür. Geleneksel yöntemlerle karşılaştırıldığında, özellikle yüksek düzeyde gürültü koşullarında gürültü direncinde önemli bir iyileşme vardır. Önerilen piramidal ÖİDD, hızlı bir yöntem olan GAKA'nın aşırı öğrenme sorununu çözmek için kullanılmıştır. Ayrıca, yüksek frekans çözünürlüğüne sahip olup GAKA performansı piramidal ÖİDD ile önemli ölçüde iyileştirilmiştir. Bununla birlikte, oldukça küçük boyutlu bir öznitelik vektörüyle yüksek doğruluk sağlanmış olup tespit hızı artırılmıştır.

Hızlı ve kolay uygulanabilir bir yöntem olan ÖİDD-BKV, [101, 108, 158] referanslarında önerilen yöntemlerden daha iyi bir performans göstermektedir. Referans [101]'de önerilen DVM sınıflandırıcı ile ADD-Tabanlı DKBO içeren çalışmada, çökme ve sıçrama olaylarına yönelik sınıflandırma doğruluğu %89'dur. Bunun nedeni ADD yönteminin gürültüye olan duyarlılığıdır. Referans [108], 6 olayın sınıflandırılması için ESA ve UKSB içeren bir yaklaşım önermektedir. Bu mimari gerçek ölçümler kullanılarak test edilmiştir. Hesaplama yükü ve karmaşıklığı yüksek olan bu yöntemin performansı nispeten düşüktür. Ayrıca bu çalışmada yalnızca 6 tip GKO olayı dikkate alınmıştır. SD-BKV ile adaptif parçacık sürü optimizasyonu (PSO) kullanılan GKO sınıflandırma yöntemi Referans [158]'de önerilmiştir. Bu yöntemin yüksek gürültü koşulları için sınıflandırma doğruluğu %93,25'tir. Uygulanan karmaşık yapıya ve optimizasyon yöntemine rağmen sınıflandırma performansı zayıftır. Referans [91], ADD ve OSA birleştiren hibrit bir yöntem önermektedir. Bu yöntemin matematiksel veriler için sınıflandırma doğruluğu yüksek olsa da 30 dB yüksek gürültü koşullarında bu oran %95'tir. Sinyal-gürültü oranı arttıkça sınıflandırma performansı büyük ölçüde azalmaktadır. Ayrıca, benzer olaylarda eşik değerinin birbirine yakın olması ve veri üzerindeki gürültü performansı düşürmektedir. Farklı sinyal analizi ve makine öğrenmesi yöntemlerinin test edildiği çalışmada [159], optimizasyon yöntemi olarak genetik algoritma (GA) kullanılmıştır. En yüksek sınıflandırma doğruluğu, GA

kullanan KA - hiperbolik SD sınıflandırıcıyla sağlanmıştır. Simüle edilmiş veriler, Nordic 32 test sistemi modeli kullanılarak üretilmiştir. Bu yöntemin gürültüsüz koşullar için sınıflandırma doğruluğu %99,5 ve 20 dB gürültü senaryosunda ise %96,1'dir. Hem sinyal analizi, hem makine öğrenmesi hem de optimizasyon yöntemlerinin kullanıldığı bu yöntem için sinyaldeki gürültü arttıkça performans düşmektedir. Önerilen piramidal ÖİDD kullanan BKV yöntemi için ortalama test doğruluğu gürültüsüz koşullarda %96,13, yüksek düzey gürültü koşullarında ise %94,96'dır. Kolay uyarlanabilir ÖİDD-BKV, gürültü içeren sinyallerde eşik değer-Tabanlı sinyal analiz yöntemlerinin performans eksikliğini ortadan kaldırmaktadır. Basit ve güvenilir olan bu yöntem, sinyaldeki gürültüyü azaltmak için yoğun işlem gerektiren filtreleme işlemine olan ihtiyacı ortadan kaldırmıştır. Literatürdeki yöntemlerden farklı olarak önerilen yöntemde, sinyal ayrıştırma ile elde edilen katsayı değerlerinin yalnızca tepe değerleri kullanılarak basit bir bulanık mantık karar çizelgesi ile olaylar yüksek doğrulukla tespit edilebilmektedir.

Önerilen AÇO-derin ağlar yöntemi ise 19 farklı sınıf için gürültülü koşullar dahil yüksek sınıflandırma başarımı göstermektedir. Çizelge 7.4 incelendiğinde, Referanslar [160,161] için başarımların tez çalışması kapsamında önerilen yöntem kadar yüksek olmasa da kabul edilebilir boyuttadır. Bununla birlikte, literatürdeki diğer yöntemlere göre çok daha büyük boyutlu bir öznitelik matrisi kullanılmıştır. Referans [160]'ta SD ile KA birlikte kullanılırken, Referans [161]'de baskın olmayan sıralama genetik algoritması-II (NSGA-II) ile SD kullanılmıştır. Referans [162]'de hızlı Fourier dönüşümü (HFD) ve YSA birlikte kullanılmıştır. Özetle, sinyal analiz yöntemleri geleneksel çalışmalarda kullanılmaktadır [91, 160, 162] ancak özellikle gürültülü sinyallerin analizinde birçok eksiklikleri vardır. Önerilen çoklu derin ağlar ve gelişmiş AÇO-Tabanlı yöntem ile bu sorun ortadan kaldırılmıştır. YEK-Tabanlı DG gibi kaynaklar ile EA şarj istasyonları gibi yüksek güçlü lineer olmayan yükler içeren mikroşebeke yapıları kompleks GKO oluşumlarına sebep olmaktadır. Pratik olarak sahada kaydedilen tüm GKO'lar karmaşık olaylardır. Ayrıca kaydedilen verilerde gürültü her zaman mevcuttur. O nedenle üç veya daha fazla olay içeren verilerin tanımlanabilmesi gerekmektedir. Referanslardan [106, 107]'de elde edilen başarımların yüksek olmasına rağmen sınıflandırılan olayların sayısı sınırlıdır. Bununla birlikte, derin ağ modelleri ile öznitelik çıkarımı yapmak otomatik süreçleri engeller ve hesaplama yükünü artırır. 16 farklı GKO, Referans [107]'de %98,13 doğrulukla 30 dB

gürültülü koşullar için sınıflandırılmıştır. Karmaşık GKO'lar yalnızca iki veya üç olayla sınırlı değildir. Diğer çalışmalardan farklı olarak önerilen yöntem, dört olayın aynı anda gözleendiği durumlar da dahil olmak üzere 19 farklı sınıfta yüksek performans göstermiştir.



8. ENDÜSTRİYEL PROTOTİP GERÇEKLEŞTİRİLMESİ

Önerilen DVM-Tabanlı GKO sınıflandırma yöntemi ve ÖİDD-Tabanlı AMOD çalışma tespit yöntemi, LabVIEW ortamında geliştirilen yazılım ve ilgili donanımlar kullanılarak tak-çalıştır yapıda bir prototip haline getirilmiştir. Bu prototip, GKO olaylarını sınıflandırmakla beraber AMOD çalışma tespitini gerçekleştirebilmektedir. Uzaktan erişimin de bulunduğu prototipte ilgili standartlara uygun bir şekilde koruma sağlanabilmektedir.

Bu bölümde, öncelikle geliştirilen LabVIEW yazılımı hakkında bilgi verilmiştir. Sonrasında geliştirilen donanım sistemi detaylandırılmıştır. Son bölümde ise gerçekleştirilen testlere ait sonuçlar incelenmiştir.

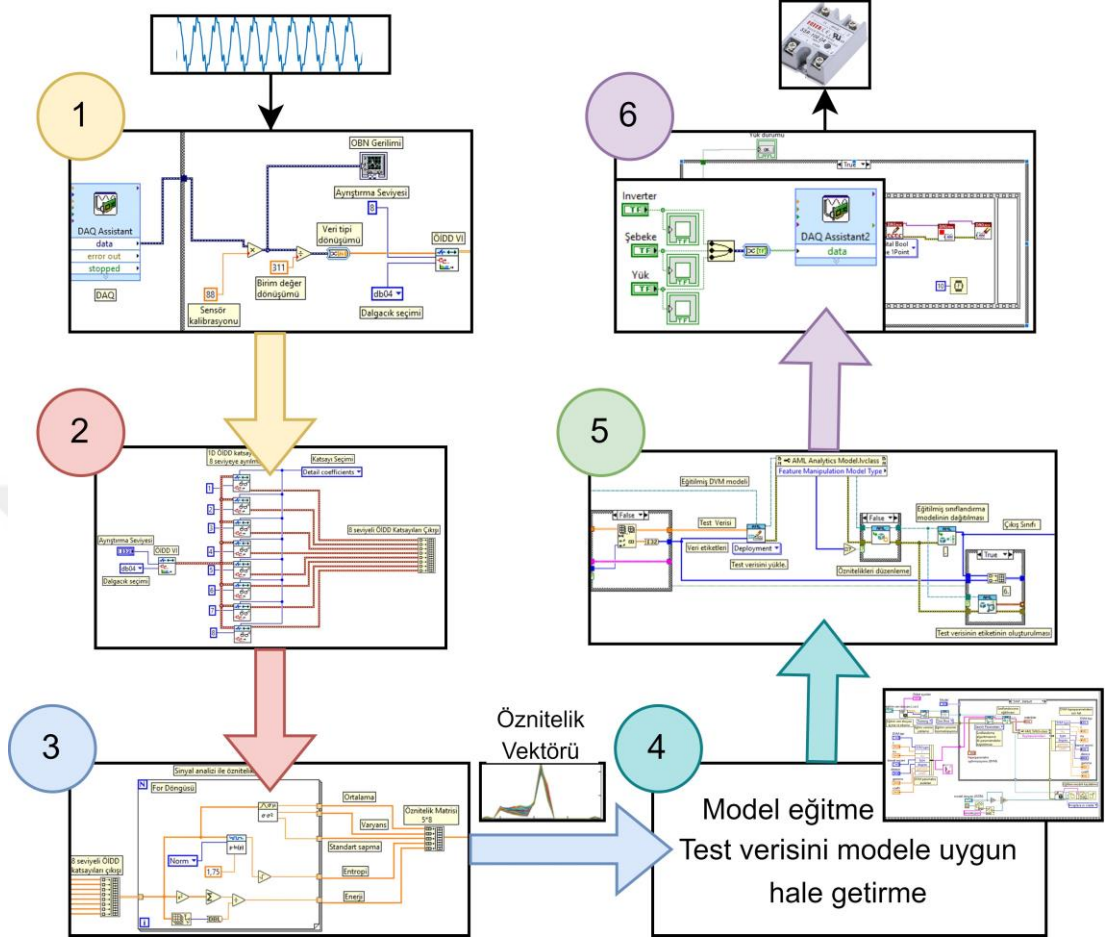
8.1 Geliştirilen LabVIEW-Tabanlı Yazılım

Tez çalışması kapsamında ana yazılımı oluşturan geliştirilen alt programlar şu şekilde gruplandırılabilir (Şekil 8.1):

- Veri toplama, ÖİDD uygulama ve öznitelik çıkarım yazılımı,
- Model eğitme yazılımı,
- Eğitilen modelin entegrasyon yazılımı,
- Tespit/sınıflandırma sonuçlarını değerlendirme ve gerekli koruma tedbirlerini alma yazılımı (ilgili kesicinin aktif edilmesi).

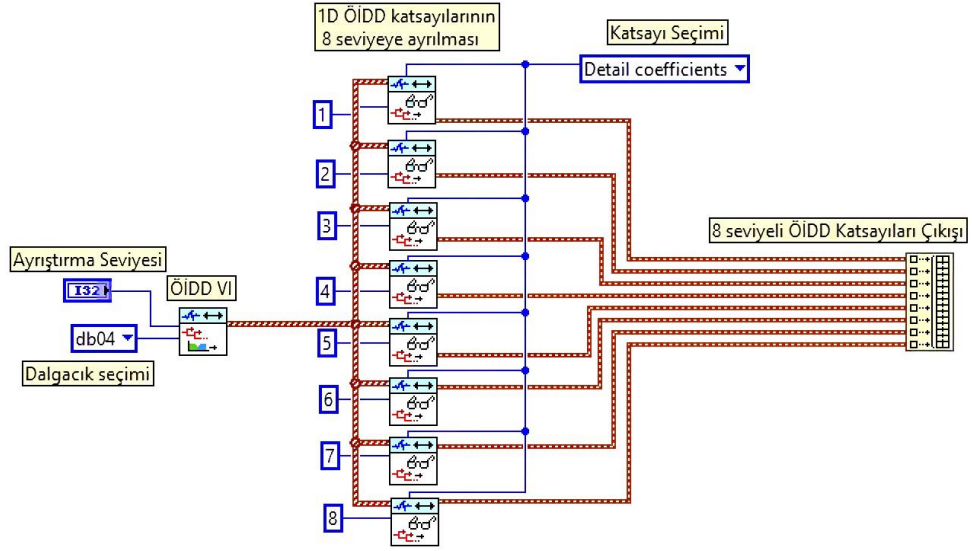
OBN noktasından EÖK ve DAQ yardımıyla alınan gerilim sinyali USB kablosu ile PC'ye aktarıldıktan sonra Şekil 8.1'de verilen 1 numaralı blok diyagramındaki işlemlere tabi tutulur. Burada, ölçüm cihazları ile karşılaştırma sonucu sensör kalibrasyonu için bir katsayı çarpanı belirlenmiştir. Daha sonrasında eğitim verisi birim değer-Tabanlı oluşturulduğu için birim değer dönüşümü yapılmıştır. Dinamik veri tipi sinyal analizi için dönüştürüldükten sonra ÖİDD alt programına aktarılmıştır. Aynı zamanda 10 kHz ile örneklenen OBN gerilim sinyalinin ekranda yazdırılması

için grafik bloğu eklenmiştir. ÖİDD ile sinyal analizi bir sonraki alt porgramda çalışmaktadır.



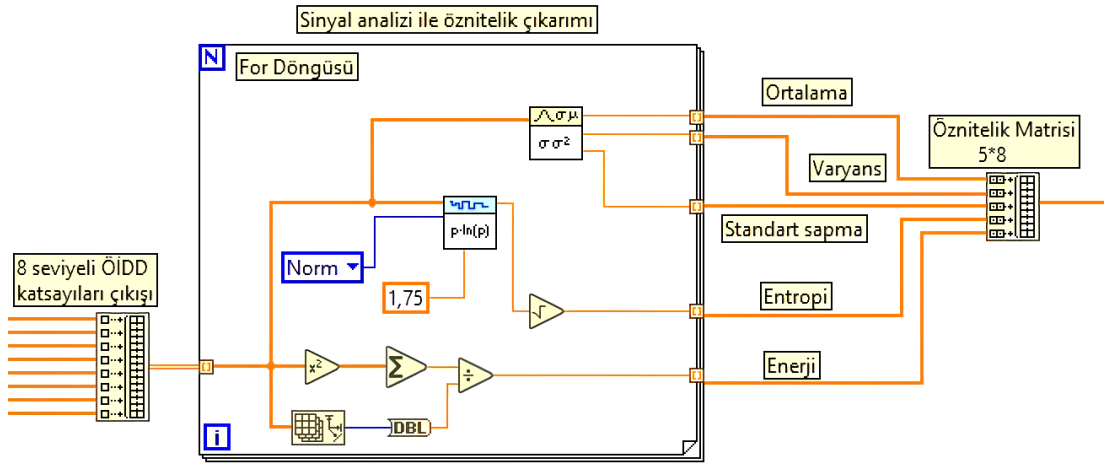
Şekil 8.1 : Geliştirilen yazılım için genel akış diyagramı.

OBN noktasından alınan gerilim sinyaline ön işlemler uygulandıktan sonra ÖİDD ile 8-seviyeli ayrıştırma için Şekil 8.2’de verilen 2 numaralı LabVIEW blok diyagramı çalıştırılır. ÖİDD VI için ayrıştırma seviyesi ve dalgacık seçimi parametreleri belirlenir. Ayrıştırma sonucu 1-D ÖİDD katsayıları 8 sütunda oluşturulur. Katsayı seçimi yaklaşım/detay seçeneklerine göre yapılır. Katsayılarının alınması için her seviyeye karşılık ayrı bir WA Get Coefficients of Undecimated Wavelet Transform VI kullanılmıştır. Hangi detay katsayısının seçileceği bu VI’da belirlenebilmektedir. Ayrıştırma sonucu oluşan katsayılar matrisi ise öznitelik çıkarımı için bir sonraki alt programa gönderilir.



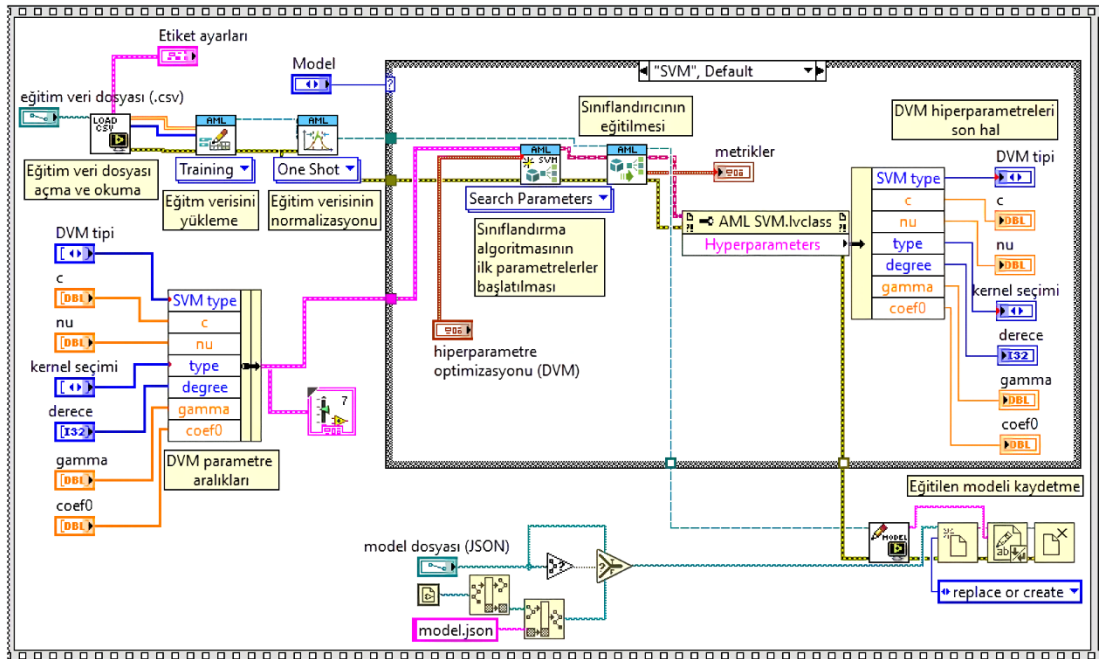
Şekil 8.2 : 8-seviyeli ÖİDD ayrıştırması için LabVIEW blok diyagramı.

ÖİDD ayrıştırması önceki aşamada detay katsayılarını ($D_1, D_2, D_3 \dots D_8$) hesaplamak için kullanılmıştır. Öznitelik çıkarım alt programının girdisi ise burada oluşturulan ÖİDD detay katsayıları matrisidir. Öznitelik çıkarım alt programında, her seviyedeki detay katsayıları için ortalama (μ), varyans (σ^2), standart sapma (σ), entropi (E) ve enerji (E_n) değerleri hesaplanmaktadır. Şekil 8.3'te istatistiksel parametreler kullanılarak gerçekleştirilen öznitelik çıkarımını gösteren 3 numaralı LabVIEW blok diyagramı verilmiştir. Blokların kullanım amaçları görsel üzerinde belirtilmiştir. Yazılım, 8×2000 veri noktasından oluşan bir matris doğrudan öznitelik çıkarım alt programına girdi olarak verilir. Çıkışta ise 5×8 boyutunda bir öznitelik matrisi oluşturulur. Bu öznitelik matrisi, ön işlemden geçirildikten sonra DVM sınıflandırıcı alt-programının girdisini oluşturmaktadır.



Şekil 8.3 : Öznitelik çıkarımı LabVIEW blok diyagramı.

Bir önceki alt programda oluşturulan öznitelik matrisi eğitilen modelin girdisini oluşturmaktadır. Şekil 8.4'te, 4 numara ile gösterilen DVM için oluşturulan eğitim alt programı gösterilmektedir. LabVIEW-Tabanlı model geliştirilen yazılımla daha önce alınan matematiksel ve simülatif veriler kullanılarak eğitim işlemi gerçekleştirilebilmektedir. Öncelikle oluşturulan eğitim veri seti dosya konumu belirtilerek açılır ve okunur. Sonrasında eğitim verisi yüklenerek normalize edilir. Grid search algoritmasının kullanılarak hiperparametrelerin belirlendiği bu yazılımda, hangi çekirdek fonksiyonlarının kullanılacağı, w ağırlık vektörü, b sapma, C ceza katsayısı ve ξ_i gevşek (slack) değişkeni için değer aralıkları girilir. Sonrasında model eğitimi başlatılır. Model performansını değerlendirmek için çapraz doğrulama kullanılmaktadır. Çapraz doğrulama işlemi tamamlandığında, her kat için elde edilen performans metriklerinin ortalaması alınmaktadır. Doğruluk değerine göre hiperparametreler optimize edilmektedir. DVM parametrelerinin başarımının en yüksek olduğu hiperparametreler ekranda gösterilmektedir. Aynı zamanda geliştirilen yazılımda, eğitilen model daha sonrasında gerçek zamanlı uygulamada test edilmek üzere "json" dosyası olarak istenilen konuma kaydedilebilmektedir. Kaydedilen "json" dosyası ana yazılımdaki modelde çağrılacaktır. Ayrıca burada, test verileri eğitim için uygun hale getirilmektedir.




Şekil 8.4 : LabVIEW-Tabanlı model eğitim yazılımı.

LabVIEW içerisinde bulunan “Classification (Deployment) VI” alt programı, geliştirilen yazılımda modeli sisteme entegre etmek için kullanılmıştır. Bu ifade, YZ projelerinde, eğitilmiş bir sınıflandırma modelinin gerçek dünya uygulamalarına entegre edilerek kullanıma sunulmasını ifade etmektedir. Kısaca, modelin üretim ortamına yerleştirilmesi ve kullanılabilir hale getirilmesi anlamına gelmektedir. Değiştirilmiş alt program Şekil 8.1’de 5 numara ile gösterilmiştir. Eğer önerilen model DVM gibi gözetimli bir öğrenme tipi ise çıkışta gösterilmek üzere sınıf etiketleri oluşturulur. Çıkış sınıfı ise son aşamadaki alt programa gönderilmektedir. Çıkış sınıfı ise, 6 numaralı alt programda değerlendirilerek gerekli koruma sistemi aktif edilmektedir. Örneğin, AMOD çalışma ve AMOD olmayan durumları karşılaştıran ikili sınıflandırma problem için gelen sınıflandırıcı çıkışı nominal sınıf olan 1’den farklı ise çok kısa sürede SSR devreye alınarak DG devre dışı bırakılacaktır.

8.2 Uygulamaya İlişkin Donanım Sistemi


Geliştirilen prototipin ayrıntılı görünümü Şekil 8.5’te verilmiştir. Panel içerisinde, yük altında 40 A’ya kadar çalışabilen BL-24040D model SSR bulunmaktadır. SSR önerilen yöntem ada çalışma modunu tespit ettiğinde tetiklenmektedir. SSR’in kontrol gerilimi 3-32V DC’dir. Sıfır geçiş tetiklemeli bu cihazın maksimum açma süresi yarım periyot (10 ms)’tur. Oldukça hızlı açma yapabilen SSR 600 V tepe değerlere kadar çalışabilmektedir. Ayrıca 100 gramdan daha hafif olup geliştirilen prototipte oldukça küçük yer kaplamaktadır. Inverter çıkışındaki gerilim ve akım verilerini DAQ’a göndermek için küçültülmüş bir EÖK tasarlanmıştır. Küçültülmüş EÖK’te LEM LV-25-P gerilim transdüseri ve LEM LA-55-P akım transdüseri bulunmaktadır. LV-25-P ile alınan inverter çıkış gerilim verisi, DAQ kartının girişine aktarılmaktadır. Bu eleman için, Bölüm 4’te verilen test sistemine benzer şekilde birincil nominal RMS akımı (I_{PN}) 10 mA ve birincil nominal RMS gerilimi (V_{PN}) 10-500 V’tur. LA-55-P ile alınan inverter çıkış akım verisi, gerilim sinyali gibi DAQ kartının girişine aktarılmıştır. LA-25-P için birincil nominal RMS akım (I_{PN}) 50 A’dır. Her iki sensör tipi için de besleme gerilim aralığı 12-15 V’tur. SSR, sensör ve DAQ kart beslemeleri pano içerisine konumlandırılan farklı DC çıkış gerilimleri üretebilen kaynaktan sağlanmaktadır. NI MX USB-6221 DAQ’ın analog veri okuma hızı 12kb/s’dir. Kartın analog ve dijital giriş/çıkışları test sistemine benzer şekilde klemenslere aktarılmıştır.

DAQ verileri PC'ye USB kablo ile aktarılmaktadır. Son aşamada LabVIEW yüklü PC yardımıyla izleme-kontrol ve koruma gerçekleştirilebilmektedir.



Şekil 8.5 : Donanım sistemi.

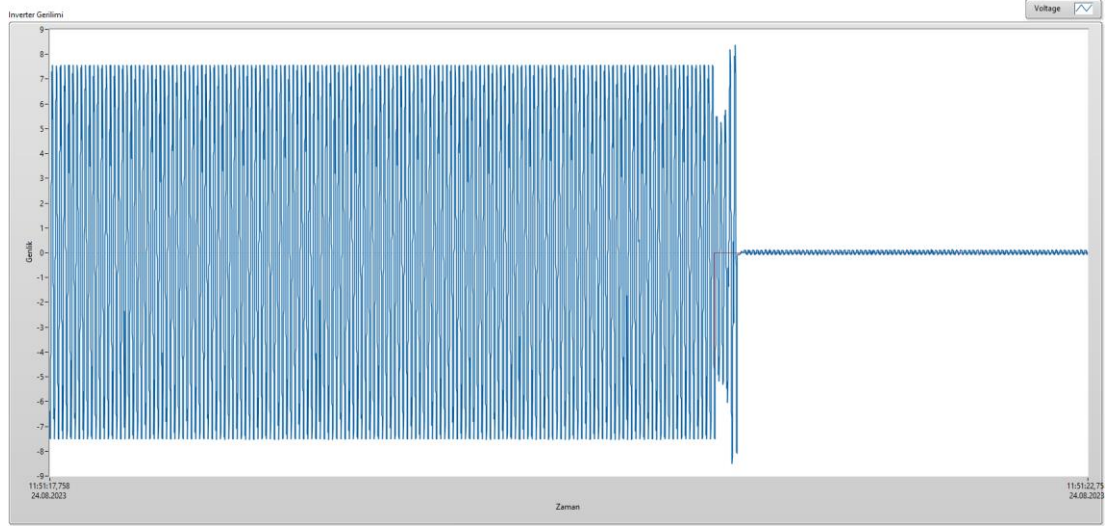
Prototip testi gerçekleştirilirken Şekil 8.6'daki düzenekten yararlanılmıştır. Test sistemi yazılımı yüklü PC ile şebeke tarafındaki kesici açılıp AMOD olayı gerçekleştirilebilmektedir. Ayrıca yükler anahtarlanarak GKO olayları oluşturulabilir. Geliştirilen yazılım iste prototipe bağlı olup AMOD çalışma/GKO olayı olduğunda sistemi korumaya almaktadır.



Şekil 8.6 : Test Sistemi.


8.3 Gerçek Zamanlı Test Sisteminden Elde Edilen Sonuçlar

AMOD Çalışma Test 1 (%30-%40 aktif güç uyuşmazlığı): Şebeke bağlantılı FV sistem tarafından aktarılan akım değeri 1,56 A ve yük tarafından çekilen akım 2,306 A olmak üzere reaktif güç uyuşmazlığının neredeyse sıfır olduğu durum için Şekil 8.7'deki sonuç verilmiştir. Bu durumdaki aktif güç uyuşmazlığı ise yaklaşık %32'dir. Görselde test sistemini yöneten yazılım tarafından AMOD olayını gerçekleştirmek için açılan şebeke tarafındaki kesici kırmızı renk ile gösterilmiştir. AMOD çalışma gerçekleştirildikten yaklaşık 5 periyot içerisinde olay geliştirilen yazılım yüklü PC tarafından hem tespit edilmiş hem de gönderilen komutla ilgili SSR açılmıştır. IEEE929-2000 standartlarında izin verilen 2 saniyeden çok daha kısa sürede tespit gerçekleştirilmiş ve açma sağlanmıştır.



Şekil 8.7 : Test 1 için inverter çıkış gerilimi grafiği.

AMOD Çalışma Test 2 (%0-%10 aktif güç uyuşmazlığı): Şebeke bağlantılı FV sistem tarafından aktarılan akım değeri 1,30 A ve yük tarafından çekilen akım 1,38 A olmak üzere reaktif güç uyuşmazlığının neredeyse sıfır olduğu durum için Şekil 8.8'de inverter çıkış gerilimi verilmiştir. Bu durumdaki aktif güç uyuşmazlığı ise yaklaşık %4 olup oldukça düşük seviyededir. AMOD çalışma ilk test sonuçlarına gerçekleştikten benzer şekilde yaklaşık 5 periyot içerisinde geliştirilen yazılım tarafından hem tespit edilmiş hem de gönderilen komutla ilgili SSR açılmıştır. Oldukça düşük güç uyuşmazlığının olduğu bu durumda dahi IEEE929-2000 standartlarında izin verilen 2 saniyeden çok daha kısa sürede tespit gerçekleştirilmiş ve açma sağlanmıştır.



Şekil 8.8 : Test 2 için inverter çıkış gerilimi grafiği.

GKO Sınıflandırma Testleri (Chroma 61500-5 sınıf) : Tez çalışmasında Chroma 61500 AC güç kaynağı şebeke gibi modellenerek nominal, gerilim çökmesi, gerilim sıçraması, gerilim kesintisi ve harmonik - ara harmonik sınıfları için toplamda yaklaşık 20000 gerçek GKO sinyali toplanmıştır. Verilerin %20'si test, %80'i eğitim olarak bölünmüştür. Gerçek zamanlı toplanan verilerin eğitim ve test sayıları dağılımı Çizelge 8.1'de verilmiştir.

Çizelge 8.1 : Chroma 61500-5 sınıf için veri dağılımı.

Sınıf	Eğitim	Test
Nominal	3677	684
Gerilim çökmesi	2517	464
Gerilim çökmesi	3104	589
Gerilim kesintisi	2584	488
Harmonik	3726	701

Şekil 8.9'da elde edilen sonuçların karmaşıklık matrisi verilmiştir. Gerilim kesintisi ve harmonik olayları %100 bir başarımla tahmin edilmiştir. Tüm sınıflar için elde edilen GKO sınıflandırma başarımları %99'un üzerindedir. En düşük başarımlar nominal sinyalde gerçekleşmiştir. Yanlış tespit oranı (YTO) ve Pozitif öngörme değeri (PÖD) sonuçları da verilmiştir. Bu metrikler, hangi sonuçların güvenilir olduğunu ve hangi sonuçların yanlış pozitifler olduğunu anlamak için kullanılmıştır. İdeal olarak, PÖD yüksek olmalı ve YTO düşük olmalıdır, böylece olumlu sonuçların çoğu gerçek pozitiflerdir ve yanlış pozitifler minimize edilmiştir. Sonuçların oldukça iyi olduğu görülmektedir.

1	663		4		
2	9	463	1		
3	6		586		
4	4	2		487	
5					701
	1	2	3	4	5

Tahmin edilen sınıf

(a)

1	97.2%		0.7%		
2	1.3%	99.6%	0.2%		
3	0.9%		99.2%		
4	0.6%	0.4%		100.0%	
5					100.0%
	1	2	3	4	5

Tahmin edilen sınıf

PÖD	97.2%	99.6%	99.2%	100.0%	100.0%
YTO	2.8%	0.4%	0.8%		

(b)

Şekil 8.9 : GKO sınıflandırma test sonuçları.

9. SONUÇLAR VE TARTIŞMA

Tez çalışması kapsamında, şebeke koduna ve belirli standartlara uygun olarak AMOD çalışma ve GKO tespit/sınıflandırması için akıllı yöntemler önerilmiştir. Aynı zamanda önerilen yöntemi kullanan izleme-tespit-koruma sistemi için prototip ürün geliştirilmesi sağlanmıştır. Bu kapsamda, yenilenebilir enerji kaynakları (YEK) ve EA şarj istasyonları içeren bir mikroşebeke test sistemi oluşturulmuştur. Ayrıca literatürde önemli bir eksik olan ortak kullanılacak ve yöntem performanslarını değerlendirebilecek veri seti eksikliği giderilmeye çalışılmıştır. Olay sinyalleri için matematiksel, simülatif ve test sistemi gerçek verilerinden oluşan veri setleri alandaki araştırmacılar için kolaylık sağlayacaktır.

Geleneksel pasif ve gelişmiş pasif AMOD çalışma tespit yöntemleri, YEK-Tabanlı DG gibi kaynakların ve EA şarj sistemleri gibi lineer olmayan yüklerin olduğu sistemlerde hatalı açma yapabilmektedir. Bu problemin üstesinden gelmek için tek fazlı DG'lerdeki AMOD çalışma araştırılmış ve FV-Tabanlı bir sistem için yeni bir ÖİDD-Tabanlı yöntem önerilmiştir. Piramidal ÖİDD-Tabanlı AMOD çalışma tespit yaklaşımı, güç uyumsuzluğunun minimum olduğu en zor şartlar da dahil olmak üzere farklı AMOD çalışma koşulları ve üretilen GKO'lar için gerçek zamanlı deneysel kurulumla doğrulanmıştır. Önerilen yöntem, yüksek gürültü koşulları için bile AMOD çalışma tespit performansını önemli ölçüde iyileştirmektedir. ÖİDD-Tabanlı yöntem, ortalama 75 ms'de AMOD çalışmayı yaklaşık sıfır ADB ile tespit edebilmektedir. Bu avantajlarıyla, önerilen yöntem, farklı DG'ler için güvenilir ve kolaylıkla kullanılabilir bir koruma sağlar.

ÖİDD'nin çok sayıda avantajıyla beraber dezavantajları da bulunmaktadır. Gereksiz alt bantlar ve çoklu filtreleme işlemleri nedeniyle ADD'ye göre hesaplama açısından daha yoğun bir işlem gerektirir. Bu artan karmaşıklık, gerçek zamanlı veya düşük karmaşıklık gerektiren durumlarda bir dezavantaj olabilir. Bu nedenle, kaç seviyeli bir ayrıştırmanın uygulanması gerektiği ayrıntılı olarak araştırılmalıdır. Ayrıca gerçek zamanlı uygulamalarda, ADD'ye göre sadece birkaç milisaniye gecikme olduğu görülmüştür. Bununla birlikte, önerilen ÖİDD yöntemi literatürdeki ADD, SDD ve

DPD'ye göre gelişmiş kaydırmaya dayanıklılık sunsa da tüm durumlarda tam olarak kaydırmaya dayanıklı olmayabilir. Bu, hassas kaydırmaya dayanıklılığın kritik bir gereksinim olduğu uygulamalarda kullanılabilirliğini sınırlayabilir. Son olarak ÖİDD yöntemi de diğer DD yöntemlerinde olduğu gibi, sonlu destekli sinyallere uygulandığında sınır etkilerinden etkilenebilir. Bu sınır etkilerini yönetmek, gereksiz alt bantlar nedeniyle daha karmaşık olabilir. Bu dezavantajlara rağmen ÖİDD, sinyaldeki ince detayları yakalama yeteneği, gürültüye karşı dayanıklılık ve öznelik çıkarma görevlerindeki gelişmiş performans gibi çok güçlü yanlara sahiptir.

Gelecekteki AMOD çalışma tespit çalışmaları, veri sayısının artırılması ve önerilen algoritmanın alanda programlanabilir kapı dizileri (FPGA)-Tabanlı bir karta gömülmesine odaklanmaktadır. Önerilen gelişmiş pasif yöntem çoklu inverter yapılarına uygundur ancak gerçek zamanlı testleri gerçekleştirilememiştir. İlerleyen süreçte iki veya daha fazla şebeke bağlantılı DG içeren bir test sistemi kurularak bu testlerin de gerçekleştirilmesi düşünülmektedir.

Tez çalışması kapsamında GKO tespit-sınıflandırması için dört farklı yöntem önerilmiştir: ÖİDD-DVM-Tabanlı GKO sınıflandırma yöntemi, ÖİDD-GAKA-Tabanlı GKO sınıflandırma yöntemi, ÖİDD-BKV-Tabanlı GKO tespit yöntemi ve Derin modeller-AÇO-Tabanlı tekil ve kompleks GKO sınıflandırma yöntemi.

ÖİDD-DVM yönteminde, DG'lerdeki GKO'ların sınıflandırılması için çoklu çekirdek içeren DVM sınıflandırıcı ve ÖİDD-Tabanlı öznelik çıkarma yöntemi önerilmiştir. Önerilen öznelik çıkarım sürecinin performans iyileştirmesini kanıtlamak için diğer DD-Tabanlı yöntemlerle karşılaştırmalar yapılmıştır. Ayrıca ÖİDD'nin performansı farklı sınıflandırıcı modelleri için de incelenmiştir. Özetle, ÖİDD tabanlı ayrıştırma, zaman-frekans analizinin çözünürlüğünü geliştirmiştir. DD'ye dayalı olarak geliştirilen ancak gürültü altında düşük performansa sahip olan sınıflandırıcıların performansı, ÖİDD ile önemli ölçüde iyileştirilmiştir.

Önerilen şemanın performansını değerlendirmek için farklı sınıflandırıcılar kNN, DVM, KA ve RO dikkate alınmıştır. ÖİDD ile elde edilen öznelikleri kullanan tüm sınıflandırıcıların doğruluk performansı, ADD ile elde edilen öznelikleri kullananlardan önemli ölçüde daha yüksektir. Gerçek zamanlı uygulamalarda sıklıkla kullanılan KA'da ÖİDD kullanıldığında 25 dB çok yüksek gürültü altında bile sınıflandırma doğruluğu %97,95 iken ADD kullanıldığında bu oran %85,36'dır.

Önerilen yöntem sayesinde, GAKA'nın güç sistemindeki popülaritesi artabilir. GKO'lar için genel tanıma testi doğruluğu, önerilen ÖİDD ve DVM tabanlı hibrit yöntem için %99,85'tir. Düşük seviyeli gürültü ve yüksek seviyeli gürültü koşulları altında sınıflandırma doğruluğu sırasıyla %99,66 ve %99,32'dir. Sonuçlar, önerilen hibrit yöntemin kullanılmasının DG sistemlerindeki GKO sınıflandırılmasında daha fazla güvenilirlik sağladığını ve kolayca kullanılabilir sonuçlar sunduğunu göstermektedir.

Önerilen ÖİDD-GAKA-Tabanlı GKO sınıflandırma yönteminde ise piramidal ÖİDD ile sınıflandırma başarımı oldukça yükseltilmiştir. Test/tahminde en hızlı algoritma olan GAKA'nın performansındaki düşüşler genellikle sinyaldeki gürültü nedeniyle aşırı uydurmadan kaynaklanmaktadır. ÖİDD süreci ile bu dezavantaj ortadan kalkmakta ve nominal koşullardaki gibi yüksek bir sınıflandırma doğruluğu elde edilebilmektedir. Gürültüsüz koşullarda ÖİDD-GAKA için test doğruluğu %99,59'dur. Ayrıca önerilen yöntem düşük seviyeli gürültü koşullarında %99,50, yüksek seviyeli gürültü koşullarında ise %99,29 sınıflandırma doğruluğuna sahiptir. Piramidal ÖİDD, ADD ile karşılaştırılmış ve performansı farklı çok sınıflı sınıflandırıcılar için değerlendirilmiştir. Sonuçlar, önerilen yöntemin mevcut DD ve sınıflandırıcı içeren yöntemlerden daha iyi gürültü bağıışıklığına ve performansa sahip olduğunu göstermektedir.

GKO'ların tespitinde kullanılan geleneksel sinyal analiz-Tabanlı yöntemlerde ilk olarak olay sinyaline alan dönüşümü yapılır ve katsayıları/öznitelikleri çıkarılır. Daha sonra ayırıştırma işlemi parametreleri ve eşik değerler ampirik testlerle belirlenir. Belirlenen parametrelere göre olay sinyali tespit edilir. Ancak bu uygulamalarda gürültülü koşullardan kaynaklanan belirsiz durumlar nedeniyle yanlış algılama ve eksik algılama eğilimi olabilir. Sabit bir eşik değer seçilmesi, EA şarj istasyonu bağlantılı DG'lerde, gürültü ve harmonik etkisiyle olayların tespitinde sorunlara neden olacaktır. Önerilen adaptif ÖİDD-BKV yöntemi, bu çalışmada eşik tabanlı sinyal analiz yöntemlerinin gürültü içeren sinyallerdeki performans eksikliğini gidermiştir. Adaptif olarak algılama yapabilen bu yaklaşım, eşik değer yöntemlerindeki sınır koşullarındaki algılama hatalarını önlerken, sadece gerilim sinyalini kullanarak maliyeti ve hesaplama yükünü en aza indirmektedir. Ayrıca ÖİDD-BKV, sinyaldeki gürültüyü azaltmak için yoğun işlem gerektiren bir filtreleme sürecine olan ihtiyacı ortadan kaldırmıştır. Matematiksel ve simüle edilmiş verilerin test doğruluğu,

gürültüsüz koşullarda piramidal ÖİDD kullanan BKV yöntemi için %96,13'tür. 20-40 dB yüksek seviyeli gürültü koşullarında ise %94,96 sınıflandırma doğruluğuna sahiptir. Gürültüsüz ve yüksek gürültülü koşullarda sınıflandırma doğruluğunun benzer olması, piramidal ÖİDD'nin sinyaldeki salınımı azaltması ve diğer DD yöntemlerine kıyasla gürültü duyarlılığının minimum seviyede olmasıdır. Ayrıca, önerilen yöntemin etkinliği DG destekli Mod 3 EA şarj cihazları, indüksiyon motorları, yerel yükler ve sürücüler altında test edilmiştir. Deneysel veriler için test doğruluğu %96,66'dır.

GKO'ları geleneksel otomatik tanımlama yöntemlerinin genellikle üç aşaması vardır: sinyal analizi, öznitelik seçimi ve sınıflandırıcı. Ancak, bu yöntemler gürültü sinyalinden etkilenebilir, insan müdahalesini içerir, karmaşık süreçlere sahiptir ve zaman alıcıdır. Diğer önerilen yöntemlerden farklı olarak mikroşebekede aynı anda dört olayın gözlemlendiği durumlar da dahil olmak üzere sekiz tek ve on kompleks GKO olayını sınıflandırmak için çoklu derin modeller-AÇO yöntemi önerilmiştir. Otomatik öznitelik çıkarma ve sınıflandırma için kapalı döngü derin ESA, UKSB ve hibrit (ESA-UKSB) modeller kullanılmaktadır. DESA-UKSB yapısında, öznitelik çıkarımı için ESA'nın ve zaman serisi veri işleme için UKSB'nin avantajları, kompleks GKO sınıflandırma doğruluğunu iyileştirmek için kullanılmıştır. Bu çalışmada, oylama sisteminde birden fazla derin sınıflandırıcı kullanmanın zorluklarını ortadan kaldırmak için geliştirilmiş bir AÇO mekanizması da önerilmektedir. Önerilen derin ağlar-AÇO gürültüsüz ortamda %99,26, düşük seviyeli gürültüde %98,58 ve yüksek seviyeli gürültüde %98,05 doğruluk oranına sahiptir. Ayrıca, gerçek veriler için sınıflandırma doğruluğu %97,78'dir. Gürültü bağışıklığında geleneksel sınıflandırıcı içeren yöntemlerden daha iyi performans sağlar. Ayrıca, değiştirilmiş AÇO yönteminin performansı ÇO'dan daha iyidir. Bu yöntemin tek dezavantajı, modifikasyon kurallarının doğrulama raporlarının gözlemlenmesiyle yapılması gerekliliğidir.

Tez çalışmasında, tek fazlı sistemde çalışma, EVSE ekipmanına bağlı çalışma ve IOT sistemlerinin hesaba katılmaması gibi sınırlar mevcuttur. Veri setinin oluşturulmasında Mod 3 şarj cihazlarının özellikleri dikkate alınmıştır. Bununla birlikte, çalışmada kullanılan Mod 3 EA şarj cihazları CP ve PP protokollerini ve standartlara uygun bir iletişim sistemi içermektedir. Dolayısıyla EVSE ile elektrikli araç arasında belirli bir akım değeri için güç aktarımı sağlanmaktadır. Dışarıdan

müdahale mümkün olmadığından, gözlemlenen GKO olayları sınırlı sayıda elde edilmektedir. Gelecek çalışmalarda, farklı güç ve yapıdaki EA şarj cihazları kullanılarak olası tüm senaryolar için gerçek veriler elde edilebilir. Ayrıca, IOT ve 5G teknolojisini içeren akıllı şebekelerde GKO'ların tespiti ve sınıflandırılması üzerine yoğunlaşılacaktır. Önerilen yöntemler, tek fazlı sistem üzerinde doğrulanmış olup 3 fazlı sistemler bazında çalışmaların da yapılması planlanmaktadır. Bununla birlikte, gelecekteki GKO sınıflandırma/tespit çalışmaları, optimizasyon yöntemleri gibi öznitelik seçim tekniklerini kullanarak öznitelik vektör veya matris boyutunu azaltmaya odaklanmalıdır. Gömülü sistemlerde, daha az özelliğe sahip sınıflandırıcı modeli daha verimli çalışabilir.



KAYNAKLAR

- [1] **Khan, M. A., Haque, A., Kurukuru, V. B., & Saad, M.** (2022). Islanding detection techniques for grid-connected photovoltaic systems-A review, *Renewable and Sustainable Energy Reviews*, 154, 111854.
- [2] **Shobana, S., Praghsh, K., Ramya, G., Rajakumar, B. R., & Binu, D.** (2022). Integrating renewable energy in electric V2G: Improved optimization assisting dispatch model, *International Journal of Energy Research*, 46(6), 7917-7934.
- [3] **Lin, R. H., Zhao, Y. Y., & Wu, B. D.** (2020). Toward a hydrogen society: Hydrogen and smart grid integration, *International Journal of Hydrogen Energy*, 45(39), 20164-20175.
- [4] **IEEE Std. 929-2000**, IEEE Recommended Practice for Utility Interface of Photovoltaic (PV) Systems, *Institute of Electrical and Electronics Engineers, Inc.*, New York, NY.
- [5] **Boemer, J. C., Huque, M., Seal, B., Key, T., Brooks, D., & Vartanian, C.** (2017, July). Status of Revision of IEEE Std 1547 and 1547.1, *2017 IEEE Power & Energy Society General Meeting* (pp. 1-5).
- [6] **Bayrak, G., & Cebeci, M.** (2014). A novel anti islanding detection method for grid connected fuel cell power generation systems, *International Journal of Hydrogen Energy*, 39(16), 8872-8880.
- [7] **Mureddu, M., Caldarelli, G., Damiano, A., Scala, A., & Meyer-Ortmanns, H.** (2016). Islanding the power grid on the transmission level: less connections for more security, *Scientific Reports*, 6(1), 34797.
- [8] **IEEE Standard for Interconnection and Interoperability of Distributed Energy Resources with Associated Electric Power Systems Interfaces**, *IEEE Std 1547-2018 (Revision of IEEE Std 1547-2003)*, vol., no., pp.1-138, 6 April 2018.
- [9] **Raza, S., Mokhlis, H., Arof, H., Laghari, J. A., & Wang, L.** (2015). Application of signal processing techniques for islanding detection of distributed generation in distribution network: A review, *Energy Conversion and Management*, 96, 613-624.
- [10] **Tshenyego, O., Samikannu, R., & Mtengi, B.** (2021). Wide area monitoring, protection, and control application in islanding detection for grid integrated distributed generation: A review, *Measurement and Control*, 54(5-6), 585-617.
- [11] **El Azzaoui, M.** (2021). An effective islanding detection method with wavelet-based nuisance tripping suppressing, *IEEE Transactions on Power Electronics*, 36(12), 13792-13801.

- [12] **Xie, X., Xu, W., Huang, C., & Fan, X.** (2021). New islanding detection method with adaptively threshold for microgrid, *Electric Power Systems Research*, 195, 107167.
- [13] **Hussain, A., Kim, C. H., & Admasie, S.** (2021). An intelligent islanding detection of distribution networks with synchronous machine DG using ensemble learning and canonical methods, *IET Generation, Transmission & Distribution*, 15(23), 3242-3255.
- [14] **Samet, H., Hashemi, F., & Ghanbari, T.** (2015). Minimum non detection zone for islanding detection using an optimal Artificial Neural Network algorithm based on PSO, *Renewable and Sustainable Energy Reviews*, 52, 1-18.
- [15] **Özcanlı, A. K., & Baysal, M.** (2022). A novel Multi-LSTM based deep learning method for islanding detection in the microgrid, *Electric Power Systems Research*, 202, 107574.2172.
- [16] **Ezzat, A., Elnaghi, B. E., & Abdelsalam, A. A.** (2021). Microgrids islanding detection using Fourier transform and machine learning algorithm, *Electric Power Systems Research*, 196, 107224.
- [17] **Hussain, A., Kim, C. H., & Mehdi, A.** (2021). A comprehensive review of intelligent islanding schemes and feature selection techniques for distributed generation system, *IEEE Access*, 9, 146603-146624.
- [18] **Bollen, M. H.** (2000). Understanding power quality problems (Vol. 3). New York: IEEE press.
- [19] **Muscas, C.** (2010). Power quality monitoring in modern electric distribution systems, *IEEE Instrumentation & Measurement Magazine*, 13(5), 19-27.
- [20] **IEEE Recommended Practice for Monitoring Electric Power Quality**, IEEE Std 1159-2009 (Revision of IEEE Std 1159-1995), vol., no., pp.1-94, 26 June 2009.
- [21] **Bayrak, G., & Yılmaz, A.** (2019). Assesment of power quality disturbances for grid integration of PV power plants, *Sakarya University Journal of Science*, 23(1), 35-42.
- [22] **Gadanayak, D. A.** (2021). Protection algorithms of microgrids with inverter interfaced distributed generation units—A review, *Electric Power Systems Research*, 192, 106986.
- [23] **Wang, S., & Chen, H.** (2019). A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network, *Applied energy*, 235, 1126-1140.
- [24] **Ray, P. K., Mohanty, S. R., & Kishor, N.** (2012). Classification of power quality disturbances due to environmental characteristics in distributed generation system, *IEEE Transactions on sustainable energy*, 4(2), 302-313.
- [25] **Khetarpal, P., & Tripathi, M. M.** (2020). A critical and comprehensive review on power quality disturbance detection and classification, *Sustainable Computing: Informatics and Systems*, 28, 100417.

- [26] **Chawda, G. S., Shaik, A. G., Shaik, M., Padmanaban, S., Holm-Nielsen, J. B., Mahela, O. P., & Kaliannan, P.** (2020). Comprehensive review on detection and classification of power quality disturbances in utility grid with renewable energy penetration, *IEEE Access*, 8, 146807-146830.
- [27] **Abu Sarhan, M.** (2023). An Extensive Review and Analysis of Islanding Detection Techniques in DG Systems Connected to Power Grids, *Energies*, 16(9), 3678.
- [28] **Khan, M. A., Haque, A., Kurukuru, V. B., & Saad, M.** (2022). Islanding detection techniques for grid-connected photovoltaic systems-A review, *Renewable and Sustainable Energy Reviews*, 154, 111854.
- [29] **Reddy, V. R., & Sreeraj, E. S.** (2019). A feedback-based passive islanding detection technique for one-cycle-controlled single-phase inverter used in photovoltaic systems, *IEEE Transactions on Industrial Electronics*, 67(8), 6541-6549.
- [30] **Gupta, P., Bhatia, R. S., & Jain, D. K.** (2014). Average absolute frequency deviation value based active islanding detection technique, *IEEE Transactions on Smart Grid*, 6(1), 26-35.
- [31] **Pourbabak, H., & Kazemi, A.** (2014). A new technique for islanding detection using voltage phase angle of inverter-based DGs, *International Journal of Electrical Power & Energy Systems*, 57, 198-205.
- [32] **Xie, X., Huang, C., & Li, D.** (2020). A new passive islanding detection approach considering the dynamic behavior of load in microgrid, *International Journal of Electrical Power & Energy Systems*, 117, 105619.
- [33] **Makwana, Y. M., & Bhalja, B. R.** (2017). Experimental performance of an islanding detection scheme based on modal components, *IEEE Transactions on Smart Grid*, 10(1), 1025-1035.
- [34] **Bakhshi, M., Noroozian, R., & Gharehpetian, G. B.** (2017). Novel islanding detection method for multiple DGs based on forced Helmholtz oscillator, *IEEE Transactions on Smart Grid*, 9(6), 6448-6460.
- [35] **Rabuzin, T., Hohn, F., & Nordström, L.** (2021). Computation of sensitivity-based islanding detection parameters for synchronous generators, *Electric Power Systems Research*, 190, 106611.
- [36] **Jang, S. I., & Kim, K. H.** (2004). An islanding detection method for distributed generations using voltage unbalance and total harmonic distortion of current, *IEEE transactions on power delivery*, 19(2), 745-752.
- [37] **Paiva, S. C., de Araujo Ribeiro, R. L., Alves, D. K., Costa, F. B., & Rocha, T. D. O. A.** (2020). A wavelet-based hybrid islanding detection system applied for distributed generators interconnected to AC microgrids, *International Journal of Electrical Power & Energy Systems*, 121, 106032.
- [38] **Chaitanya, B. K., Yadav, A., Pazoki, M., & Abdelaziz, A. Y.** (2021). A comprehensive review of islanding detection methods, *Uncertainties in Modern Power Systems*, 211-256.

- [39] **Trujillo, C. L., Velasco, D., Figueres, E., & Garcerá, G.** (2010). Analysis of active islanding detection methods for grid-connected microinverters for renewable energy processing, *Applied Energy*, 87(11), 3591-3605.
- [40] **Kunte, R. S., & Gao, W.** (2008, September). Comparison and review of islanding detection techniques for distributed energy resources, *40th North American power symposium* (pp. 1-8).
- [41] **Mukarram, M. J., & Murkute, S. V.** (2020, February). Sandia frequency shift method for anti-islanding protection of a gridtied photovoltaic system. *IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)* (pp. 1-5).
- [42] **Worku, M. Y., Hassan, M. A., Maraaba, L. S., & Abido, M. A.** (2021). Islanding detection methods for microgrids: A comprehensive review, *Mathematics*, 9(24), 3174.
- [43] **Liu, F., Kang, Y., Zhang, Y., Duan, S., & Lin, X.** (2010). Improved SMS islanding detection method for grid-connected converters, *IET renewable power generation*, 4(1), 36-42.
- [44] **Mohanty, A., Rout, B., & Pradhan, R.** (2023). A comparative Studies on different islanding detection methods for distributed generation systems, *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 45(1), 2284-2316.
- [45] **Singh, R., Mohanty, S. R., Kishor, N., & Thakur, A.** (2018). Real-time implementation of signal processing techniques for disturbances detection, *IEEE Transactions on Industrial Electronics*, 66(5), 3550-3560.
- [46] **Khodaparastan, M., Vahedi, H., Khazaeli, F., & Oraee, H.** (2015). A novel hybrid islanding detection method for inverter-based DGs using SFS and ROCOF, *IEEE Transactions on Power Delivery*, 32(5), 2162-2170.
- [47] **Sirjani, R., & Okwose, C. F.** (2016). Combining two techniques to develop a novel islanding detection method for distributed generation units, *Measurement*, 81, 66-79.
- [48] **Shi, K., Ye, H., Xu, P., Yang, Y., & Blaabjerg, F.** (2020). An islanding detection based on droop characteristic for virtual synchronous generator, *International Journal of Electrical Power & Energy Systems*, 123, 106277.
- [49] **Nayak, A. M., Mishra, M., & Pati, B. B.** (2020, December). A hybrid islanding detection method considering voltage unbalance factor, *IEEE International Symposium on Sustainable Energy, Signal Processing and Cyber Security (iSSSC)* (pp. 1-5).
- [50] **Bakhshi-Jafarabadi, R., Sadeh, J., Serrano-Fontova, A., & Rakhshani, E.** (2022). Review on islanding detection methods for grid-connected photovoltaic systems, existing limitations and future insights, *IET Renewable Power Generation*, 16(15), 3406-3421.
- [51] **Gupta, N., Dogra, R., Garg, R., & Kumar, P.** (2022). Review of islanding detection schemes for utility interactive solar photovoltaic systems, *International Journal of Green Energy*, 19(3), 242-253.

- [52] **Vadlamudi, B., & Anuradha, T.** (2023). Review of islanding detection using advanced signal processing techniques, *Electrical Engineering*, 1-22.
- [53] **Gupta, N., & Garg, R.** (2018). Algorithm for islanding detection in photovoltaic generator network connected to low-voltage grid, *IET Generation, Transmission & Distribution*, 12(10), 2280-2287.
- [54] **Bayrak, G.** (2018). Wavelet transform-based fault detection method for hydrogen energy-based distributed generators, *international journal of hydrogen energy*, 43(44), 20293-20308.
- [55] **Mishra, M., Sahani, M., & Rout, P. K.** (2017). An islanding detection algorithm for distributed generation based on Hilbert–Huang transform and extreme learning machine, *Sustainable Energy, Grids and Networks*, 9, 13-26.
- [56] **Niaki, A. M., & Afsharnia, S.** (2014). A new passive islanding detection method and its performance evaluation for multi-DG systems, *Electric Power Systems Research*, 110, 180-187.
- [57] **Jurado, F., & Saenz, J. R.** (2002). Comparison between discrete STFT and wavelets for the analysis of power quality events, *Electric power systems research*, 62(3), 183-190.
- [58] **Samantaray, S. R., Samui, A., & Babu, B. C.** (2011). Time-frequency transform-based islanding detection in distributed generation, *IET renewable power generation*, 5(6), 431-438.
- [59] **Panigrahi, B. K., Bhuyan, A., Shukla, J., Ray, P. K., & Pati, S.** (2021). A comprehensive review on intelligent islanding detection techniques for renewable energy integrated power system, *International Journal of Energy Research*, 45(10), 14085-14116.
- [60] **Yilmaz, A., & Baytak, G.** (2020). An improved CWT-based islanding detection method for a developed microgrid in real-time, *Mugla Journal of Science and Technology*, 6, 10-17.
- [61] **Hanif, M., Basu, M., & Gaughan, K.** (2012). Development of EN50438 compliant wavelet-based islanding detection technique for three-phase static distributed generation systems, *IET renewable power generation*, 6(4), 289-301.
- [62] **Andrade, L. C., Oleskovicz, M., & Fernandes, R. A.** (2016). Adaptive threshold based on wavelet transform applied to the segmentation of single and combined power quality disturbances, *Applied Soft Computing*, 38, 967-977.
- [63] **Zafar, T., & Morsi, W. G.** (2013). Power quality and the un-decimated wavelet transform: An analytic approach for time-varying disturbances, *Electric Power Systems Research*, 96, 201-210.
- [64] **Yilmaz, A., & Bayrak, G.** (2019). A real-time UWT-based intelligent fault detection method for PV-based microgrids, *Electric Power Systems Research*, 177, 105984.
- [65] **Yilmaz, A., Küçüker, A., Bayrak, G., Ertekin, D., Shafie-Khah, M., & Guerrero, J. M.** (2022). An improved automated PQD classification method for distributed generators with hybrid SVM-based approach

using un-decimated wavelet transform, *International Journal of Electrical Power & Energy Systems*, 136, 107763.

- [66] **Yilmaz, A., Küçüker, A., & Bayrak, G.** (2022). Automated classification of power quality disturbances in a SOFC&PV-based distributed generator using a hybrid machine learning method with high noise immunity, *international journal of hydrogen energy*, 47(45), 19797-19809.
- [67] **Yilmaz, A., & Bayrak, G.** (2022). A new signal processing-based islanding detection method using pyramidal algorithm with undecimated wavelet transform for distributed generators of hydrogen energy, *International Journal of Hydrogen Energy*, 47(45), 19821-19836.
- [68] **Silva, K. M., Souza, B. A., & Brito, N. S.** (2006). Fault detection and classification in transmission lines based on wavelet transform and ANN, *IEEE Transactions on power delivery*, 21(4), 2058-2063.
- [69] **Valtierra-Rodriguez, M., de Jesus Romero-Troncoso, R., Osornio-Rios, R. A., & Garcia-Perez, A.** (2013). Detection and classification of single and combined power quality disturbances using neural networks, *IEEE transactions on industrial electronics*, 61(5), 2473-2482.
- [70] **Thirumala, K., Pal, S., Jain, T., & Umarikar, A. C.** (2019). A classification method for multiple power quality disturbances using EWT based adaptive filtering and multiclass SVM, *Neurocomputing*, 334, 265-274.
- [71] **Li, J., Teng, Z., Tang, Q., & Song, J.** (2016). Detection and classification of power quality disturbances using double resolution S-transform and DAG-SVMs, *IEEE Transactions on Instrumentation and Measurement*, 65(10), 2302-2312.
- [72] **Kumar, D.** (2021). Islanding detection in microgrid compromising missing values using NI sensors, *IEEE Systems Journal*, 16(2), 1786-1795.
- [73] **Mlakić, D., Baghaee, H. R., & Nikolovski, S.** (2018). A novel ANFIS-based islanding detection for inverter-interfaced microgrids, *IEEE Transactions on Smart Grid*, 10(4), 4411-4424.
- [74] **Rosolowski, E., Burek, A., & Jedut, L.** (2007). A new method for islanding detection in distributed generation, *Wroclaw University of Technology: Wroclaw, Poland*.
- [75] **Samantaray, S. R., El-Arroudi, K., Joos, G., & Kamwa, I.** (2010). A fuzzy rule-based approach for islanding detection in distributed generation, *IEEE transactions on power delivery*, 25(3), 1427-1433.
- [76] **Khan, M. A., Haque, A., & Kurukuru, V. B.** (2020). Performance assessment of stand-alone transformerless inverters, *International Transactions on Electrical Energy Systems*, 30(1), e12156.
- [77] **Kurukuru, V. S. B., Blaabjerg, F., Khan, M. A., & Haque, A.** (2020). A novel fault classification approach for photovoltaic systems, *Energies*, 13(2), 308.
- [78] **Li, Y., Lu, N., Wang, X., & Jiang, B.** (2019). Islanding fault detection based on data-driven approach with active developed reactive power variation, *Neurocomputing*, 337, 97-109.

- [79] **Heidari, M., Seifossadat, G., & Razaz, M.** (2013). Application of decision tree and discrete wavelet transform for an optimized intelligent-based islanding detection method in distributed systems with distributed generations, *Renewable and sustainable energy reviews*, 27, 525-532.
- [80] **Merlin, V. L., Santos, R. C. D., Grilo, A. P., Vieira, J. C. M., Coury, D. V., & Oleskovicz, M.** (2016). A new artificial neural network based method for islanding detection of distributed generators, *International Journal of Electrical Power & Energy Systems*, 75, 139-151.
- [81] **Baghaee, H. R., Mlakić, D., Nikolovski, S., & Dragicčvić, T.** (2019). Anti-islanding protection of PV-based microgrids consisting of PHEVs using SVMs, *IEEE Transactions on Smart Grid*, 11(1), 483-500.
- [82] **Manikonda, S. K., & Gaonkar, D. N.** (2019). IDM based on image classification with CNN, *The Journal of Engineering*, 2019(10), 7256-7262.
- [83] **Kong, X., Xu, X., Yan, Z., Chen, S., Yang, H., & Han, D.** (2018). Deep learning hybrid method for islanding detection in distributed generation, *Applied Energy*, 210, 776-785.
- [84] **Menezes, T. S., Fernandes, R. A., & Coury, D. V.** (2020). Intelligent islanding detection with grid topology adaptation and minimum non-detection zone, *Electric Power Systems Research*, 187, 106470.
- [85] **Gururani, A., Mohanty, S. R., & Mohanta, J. C.** (2016). Microgrid protection using Hilbert–Huang transform based-differential scheme, *IET Generation, Transmission & Distribution*, 10(15), 3707-3716.
- [86] **Cho, S. H., Jang, G., & Kwon, S. H.** (2009). Time-frequency analysis of power-quality disturbances via the Gabor–Wigner transform, *IEEE transactions on power delivery*, 25(1), 494-499.
- [87] **Camarena-Martinez, D., Valtierra-Rodriguez, M., Perez-Ramirez, C. A., Amezcua-Sanchez, J. P., de Jesus Romero-Troncoso, R., & Garcia-Perez, A.** (2015). Novel downsampling empirical mode decomposition approach for power quality analysis, *IEEE Transactions on Industrial Electronics*, 63(4), 2369-2378.
- [88] **Bayrak, G., & Yilmaz, A.** (2020). Signal processing-based automated fault detection methods for smart grids, *Smart Technologies for Smart Cities*, 57-85.
- [89] **Lee, C. Y., & Shen, Y. X.** (2011). Optimal feature selection for power-quality disturbances classification, *IEEE Transactions on power delivery*, 26(4), 2342-2351.
- [90] **Manimala, K., Selvi, K., & Ahila, R.** (2012). Optimization techniques for improving power quality data mining using wavelet packet-based support vector machine, *Neurocomputing*, 77(1), 36-47.
- [91] **Khokhar, S., Zin, A. A. M., Memon, A. P., & Mokhtar, A. S.** (2017). A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network, *Measurement*, 95, 246-259.

- [92] **Latran, M. B., & Teke, A.** (2015). A novel wavelet transform based voltage sag/swell detection algorithm, *International Journal of Electrical Power & Energy Systems*, 71, 131-139.
- [93] **Karegar, H. K., & Sobhani, B.** (2012). Wavelet transform method for islanding detection of wind turbines, *Renewable Energy*, 38(1), 94-106.
- [94] **Pinto, S. J., & Panda, G.** (2015). Wavelet technique based islanding detection and improved repetitive current control for reliable operation of grid-connected PV systems, *International Journal of Electrical Power & Energy Systems*, 67, 39-51.
- [95] **Naik, C. A., & Kundu, P.** (2013). Power quality index based on discrete wavelet transform, *International Journal of electrical power & energy systems*, 53, 994-1002.
- [96] **Bhuiyan, S. M., Khan, J., & Murphy, G.** (2017). WPD for detecting disturbances in presence of noise in smart grid for PQ monitoring, *IEEE Transactions on Industry Applications*, 54(1), 702-711..
- [97] **Starck, J. L., Donoho, D. L., & Elad, M.** (2004). Redundant multiscale transforms and their application for morphological component separation (No. DAPNIA-2004-88), *CM-P00052061*.
- [98] **Bayrak, G., & Yilmaz, A.** (2021). Detection and classification of power quality disturbances in smart grids using artificial intelligence methods, *In Artificial Intelligence (AI)* (pp. 149-170). CRC Press.
- [99] **Decanini, J. G., Tonelli-Neto, M. S., Malange, F. C., & Minussi, C. R.** (2011). Detection and classification of voltage disturbances using a fuzzy-ARTMAP-wavelet network, *Electric Power Systems Research*, 81(12), 2057-2065.
- [100] **Thirumala, K., Prasad, M. S., Jain, T., & Umarikar, A. C.** (2016). 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.
- [101] **Borrás, M. D., Bravo, J. C., & Montano, J. C.** (2016). Disturbance ratio for optimal multi-event classification in power distribution networks, *IEEE Transactions on Industrial Electronics*, 63(5), 3117-3124.
- [102] **Wang, H., Wang, P., & Liu, T.** (2017). Power quality disturbance classification using the S-transform and probabilistic neural network, *Energies*, 10(1), 107.
- [103] **Abrahart, Deokar, S. A., & Waghmare, L. M.** (2014). Integrated DWT-FFT approach for detection and classification of power quality disturbances, *International Journal of Electrical Power & Energy Systems*, 61, 594-605.
- [104] **Mishra, S., Bhende, C. N., & Panigrahi, B. K.** (2007). Detection and classification of power quality disturbances using S-transform and probabilistic neural network, *IEEE Transactions on power delivery*, 23(1), 280-287.
- [105] **Liu, H., Hussain, F., Shen, Y., Arif, S., Nazir, A., & Abubakar, M.** (2018). Complex power quality disturbances classification via curvelet

- transform and deep learning, *Electric Power Systems Research*, 163, 1-9.
- [106] **Cai, K., Cao, W., Aarniovuori, L., Pang, H., Lin, Y., & Li, G.** (2019). Classification of power quality disturbances using Wigner-Ville distribution and deep convolutional neural networks, *IEEE Access*, 7, 119099-119109.
- [107] **Wang, J., Xu, Z., & Che, Y.** (2019). Power quality disturbance classification based on compressed sensing and deep convolution neural networks, *IEEE access*, 7, 78336-78346.
- [108] **Garcia, C. I., Grasso, F., Luchetta, A., Piccirilli, M. C., Paolucci, L., & Talluri, G.** (2020) A comparison of power quality disturbance detection and classification methods using CNN, LSTM and CNN-LSTM, *Applied sciences*, 10(19), 6755.
- [109] **Bayrak, G., Yılmaz, A., & Çakmak, R.** (2023). A new Fuzzy&Wavelet-based adaptive thresholding method for detecting PQDs in a hydrogen and solar-energy powered EV charging station, *International Journal of Hydrogen Energy*, 48(18), 6855-6870.
- [110] **Zhang, C., Liu, C., Zhang, X., & Almpandis, G.** (2017). An up-to-date comparison of state-of-the-art classification algorithms, *Expert Systems with Applications*, 82, 128-150.
- [111] **Beniwal, R. K., Saini, M. K., Nayyar, A., Qureshi, B., & Aggarwal, A.** (2021). A critical analysis of methodologies for detection and classification of power quality events in smart grid, *IEEE Access*, 9, 83507-83534.
- [112] **Bayrak, G., Küçüker, A., & Yılmaz, A.** (2023). Deep learning-based multi-model ensemble method for classification of PQDs in a hydrogen energy-based microgrid using modified weighted majority algorithm, *International Journal of Hydrogen Energy*, 48(18), 6824-6836.
- [113] **International Electrotechnical Commission. IEC 62116-2014-Utility-interconnected photovoltaic inverters - test procedure of islanding prevention measures.** 2014.
- [114] **UL 1741, Std 1741,** Static Inverter and Charge Controllers for Use in Photovoltaic Systems, *Underwriters Laboratories Inc.*, Northbrook. IL.
- [115] **Mishra, M.** (2019). Power quality disturbance detection and classification using signal processing and soft computing techniques: A comprehensive review, *International transactions on electrical energy systems*, 29(8), e12008.
- [116] **Oubrahim, Z., Amirat, Y., Benbouzid, M., & Ouassaid, M.** (2023). Power Quality Disturbances Characterization Using Signal Processing and Pattern Recognition Techniques: A Comprehensive Review, *Energies*, 16(6), 2685.
- [117] **Jay, F., & Goetz, J. A.** (1984). IEEE Standard Dictionary of Electrical and Electronics Terms, *The Institute of Electrical and Electronics Engineers. Inc.:* New York.

- [118] **International Electrotechnical Commission.** (2003). Electromagnetic compatibility (EMC)-Part 4-30: Testing and measurement techniques- Power quality measurement methods. *IEC 61000-4-30*.
- [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.
- [120] **Caicedo, J. E., Agudelo-Martínez, D., Rivas-Trujillo, E., & Meyer, J. (2023).** A systematic review of real-time detection and classification of power quality disturbances, *Protection and Control of Modern Power Systems*, 8(1), 3.
- [121] **IEEE Recommended Practice for Monitoring Electric Power Quality.** IEEE Std 1159-2019 (*Revision of IEEE Std 1159-2009*), vol., no., pp.1-98, 13 Aug. 2019.
- [122] **EN 50160 Standard, S. (2010).** Voltage characteristics of electricity supplied by public electricity networks, *German Institute for Standardisation: Berlin, Germany*.
- [123] **IEEE Standard for Harmonic Control in Electric Power Systems,** IEEE Std 519-2022 (*Revision of IEEE Std 519-2014*), vol., no., pp.1-31, 5 Aug. 2022.
- [124] **IEEE Standard for Measurement and Limits of Voltage Fluctuations and Associated Light Flicker on AC Power Systems,** IEEE Std 1453-2022 (*Revision of IEEE Std 1453-2015*), vol., no., pp.1-83, 27 Feb. 2022
- [125] **Shensa, M. J. (1992).** The discrete wavelet transform: wedding the a trous and Mallat algorithms, *IEEE Transactions on signal processing*, 40(10), 2464-2482.
- [126] **National Instruments, LabVIEW 2014 advanced signal processing toolkit manual (2014).** Available Online: https://zone.ni.com/reference/en-XX/help/372656C-01/lvasptconcepts/wa_uwt
- [127] **Mallat, S. G. (1989).** A theory for multiresolution signal decomposition: the wavelet representation, *IEEE transactions on pattern analysis and machine intelligence*, 11(7), 674-693.
- [128] **Brassarote, G. D. O. N., Souza, E. M., & Monico, J. F. G. (2018).** Non-decimated wavelet transform for a shift-invariant analysis, *TEMA (São Carlos)*, 19, 93-110.
- [129] **Zhang, M. L., & Zhou, Z. H. (2007).** ML-KNN: A lazy learning approach to multi-label learning, *Pattern recognition*, 40(7), 2038-2048.
- [130] **Joachims, T. (1998).** Making large-scale SVM learning practical (No. 1998, 28), *Technical report*.
- [131] **Kingsford, C., & Salzberg, S. L. (2008).** What are decision trees?, *Nature biotechnology*, 26(9), 1011-1013.
- [132] **Belgiu, M., & Drăguț, L. (2016).** Random forest in remote sensing: A review of applications and future directions, *ISPRS journal of photogrammetry and remote sensing*, 114, 24-31.

- [133] **Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., ... & Liu, T. Y.** (2017). Lightgbm: A highly efficient gradient boosting decision tree, *Advances in neural information processing systems*, 30.
- [134] **Bayrak, G., & Yilmaz, A.** (2023). A Deep Learning-Based Islanding Detection Approach by Considering the Load Demand of DGs Under Different Grid Conditions, *In Prediction Techniques for Renewable Energy Generation and Load Demand Forecasting* (pp. 61-76). Singapore: Springer Nature Singapore.
- [135] **de Oliveira, R. A., & Bollen, M. H.** (2023). Deep learning for power quality, *Electric Power Systems Research*, 214, 108887.
- [136] **Fukushima, K.** (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biological cybernetics*, 36(4), 193-202.
- [137] **Niazazari, I., Hamidi, R. J., Livani, H., & Arghandeh, R.** (2020). Cause identification of electromagnetic transient events using spatiotemporal feature learning, *International Journal of Electrical Power & Energy Systems*, 123, 106255.
- [138] **Yu, Y., Si, X., Hu, C., & Zhang, J.** (2019). A review of recurrent neural networks: LSTM cells and network architectures, *Neural computation*, 31(7), 1235-1270.
- [139] **Graves, A., Fernández, S., & Schmidhuber, J.** (2005, September). Bidirectional LSTM networks for improved phoneme classification and recognition, *International conference on artificial neural networks* (pp. 799-804). Berlin, Heidelberg: Springer Berlin Heidelberg.
- [140] **Kataria, N.** (2010). A Comparative Study of the Defuzzification Methods in an Application, *IUP Journal of Computer Sciences*, 4(4).
- [141] **Altaş, İ. H., & Çakmak, R.** (2020). A fuzzy decision maker to determine optimal starting time of shiftable loads in the smart grids, *International Journal of Reasoning-based Intelligent Systems*, 12(3), 210-216.
- [142] **Liu, H., Hussain, F., Yue, S., Yildirim, O., & Yawar, S. J.** (2019). Classification of multiple power quality events via compressed deep learning, *International Transactions on Electrical Energy Systems*, 29(6), e12010.
- [143] **Igual, R., Medrano, C., Arcega, F. J., & Mantescu, G.** (2018, May). Integral mathematical model of power quality disturbances, *18th International Conference on Harmonics and Quality of Power (ICHQP)* (pp. 1-6).
- [144] **Puliyadi Kubendran, A. K., & Loganathan, A. K.** (2017). Detection and classification of complex power quality disturbances using S-transform amplitude matrix-based decision tree for different noise levels, *International Transactions on Electrical Energy Systems*, 27(4), e2286.
- [145] **Das, S., Pradhan, A. K., Kedia, A., Dalai, S., Chatterjee, B., & Chakravorti, S.** (2018). Diagnosis of power quality events based on detrended fluctuation analysis, *IEEE Transactions on Industrial Electronics*, 65(9), 7322-7331.

- [146] **Narayanaswami, R., Sundaresan, D., & Prema, V. R.** (2020). The mystery curve: a signal processing based power quality disturbance detection, *IEEE Transactions on Industrial Electronics*, 68(10), 10078-10086.
- [147] **International Electrotechnical Commission. International Standard IEC 62196-1.** Plugs, socket outlets, vehicle couplers and vehicle inlets—Conductive charging of electric vehicles—Part 1: Charging of electric vehicles up to 250 A ac and 400 A dc.
- [148] **Van Den Bossche, P.** (2010). IEC 61851-1: Electric vehicle conductive charging system-Part 1: General requirements. In 2 (pp. 1-99). Iec.
- [149] **Pan, B., Chen, W. S., Xu, C., & Chen, B.** (2015). A novel framework for learning geometry-aware kernels, *IEEE transactions on neural networks and learning systems*, 27(5), 939-951.
- [150] **Tang, Q., Qiu, W., & Zhou, Y.** (2019). Classification of complex power quality disturbances using optimized S-transform and kernel SVM, *IEEE Transactions on Industrial Electronics*, 67(11), 9715-9723.
- [151] **Tsihrintzis, G. A., & Jain, L. C. (Eds.).** (2020). Machine learning paradigms: advances in deep learning-based technological applications (Vol. 18). *Springer Nature*.
- [152] **Shrivastava, S., Jain, S., Nema, R. K., & Chaurasia, V.** (2017). Two level islanding detection method for distributed generators in distribution networks, *International Journal of Electrical Power & Energy Systems*, 87, 222-231.
- [153] **Karimi, H., Yazdani, A., & Iravani, R.** (2008). Negative-sequence current injection for fast islanding detection of a distributed resource unit, *IEEE Transactions on power electronics*, 23(1), 298-307.
- [154] **Abd-Elkader, A. G., Saleh, S. M., & Eiteba, M. M.** (2018). A passive islanding detection strategy for multi-distributed generations, *International Journal of Electrical Power & Energy Systems*, 99, 146-155.
- [155] **Admasie, S., Bukhari, S. B. A., Haider, R., Gush, T., & Kim, C. H.** (2019). A passive islanding detection scheme using variational mode decomposition-based mode singular entropy for integrated microgrids, *Electric Power Systems Research*, 177, 105983.
- [156] **Sindi, H., Nour, M., Rawa, M., Öztürk, Ş., & Polat, K.** (2021) A novel hybrid deep learning approach including combination of 1D power signals and 2D signal images for power quality disturbance classification, *Expert Systems with Applications*, 174, 114785.
- [157] **Abdoos, A. A., Mianaei, P. K., & Ghadikolaie, M. R.** (2016). Combined VMD-SVM based feature selection method for classification of power quality events, *Applied Soft Computing*, 38, 637-646.
- [158] **Huang, N., Zhang, S., Cai, G., & Xu, D.** (2015). Power quality disturbances recognition based on a multiresolution generalized S-transform and a PSO-improved decision tree, *Energies*, 8(1), 549-572.
- [159] **Ray, P. K., Mohanty, S. R., Kishor, N., & Catalão, J. P.** (2013). Optimal feature and decision tree-based classification of power quality

disturbances in distributed generation systems, *IEEE Transactions on Sustainable Energy*, 5(1), 200-208.

- [160] **Biswal, M., & Dash, P. K.** (2013). Detection and characterization of multiple power quality disturbances with a fast S-transform and decision tree based classifier, *Digital Signal Processing*, 23(4), 1071-1083.
- [161] **Singh, U., & Singh, S. N.** (2017). Optimal feature selection via NSGA-II for power quality disturbances classification, *IEEE Transactions on Industrial Informatics*, 14(7), 2994-3002.
- [162] **Borges, F. A., Fernandes, R. A., Silva, I. N., & Silva, C. B.** (2015). Feature extraction and power quality disturbances classification using smart meters signals, *IEEE Transactions on Industrial Informatics*, 12(2), 824-833.



ÖZGEÇMİŞ

Ad-Soyad : Alper YILMAZ

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** : 2015, Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği
- **Yüksek Lisans** : 2018, Bursa Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

MESLEKİ DENEYİM VE ÖDÜLLER:

- Araştırma Görevlisi (2017 - ...)

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- Yılmaz, A., & Bayrak, G. (2019). A real-time UWT-based intelligent fault detection method for PV-based microgrids. *Electric Power Systems Research*, 177, 105984.
- Yılmaz, A., & Bayrak, G. (2019). Real-Time Disturbance Detection Using STFT Method in Microgrids. *Academic Perspective Procedia*, 2(3), 1115-1121.
- Bayrak, G., & Yılmaz, A. (2019). Assesment of power quality disturbances for grid integration of PV power plants. *Sakarya University Journal of Science*, 23(1), 35-42.
- Yılmaz, A., & Bayrak, G. (2019). Assessment of Wavelet Types in DWT-based Power Quality Disturbance Detection Method. *Academic Perspective Procedia*, 2(3), 1122-1130.
- Bayrak, G., & Yılmaz, A. (2020). Signal processing-based automated fault detection methods for smart grids. *Smart Technologies for Smart Cities*, 57-85.

- Yılmaz, A., & Bayrak, G. (2020). An improved CWT-based islanding detection method for a developed microgrid in real-time. *Mugla Journal of Science and Technology*, 6, 10-17.
- Yılmaz, A., & Bayrak, G. (2020, October). DWT-Based Islanding Detection Method for DFIG-typed WTs. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Bayrak, G., & Yılmaz, A. (2021). Detection and classification of power quality disturbances in smart grids using artificial intelligence methods. In *Artificial Intelligence (AI)* (pp. 149-170). CRC Press.
- Yılmaz, A., & Bayrak, G. (2022). A new signal processing-based islanding detection method using pyramidal algorithm with undecimated wavelet transform for distributed generators of hydrogen energy. *International Journal of Hydrogen Energy*, 47(45), 19821-19836.
- Yılmaz, A., Küçükler, A., Bayrak, G., Ertekin, D., Shafie-Khah, M., & Guerrero, J. M. (2022). An improved automated PQD classification method for distributed generators with hybrid SVM-based approach using un-decimated wavelet transform. *International Journal of Electrical Power & Energy Systems*, 136, 107763.
- Yılmaz, A., Küçükler, A., & Bayrak, G. (2022). Automated classification of power quality disturbances in a SOFC&PV-based distributed generator using a hybrid machine learning method with high noise immunity. *International journal of hydrogen energy*, 47(45), 19797-19809.
- Bayrak, G., Küçükler, A., & Yılmaz, A. (2023). Deep learning-based multi-model ensemble method for classification of PQDs in a hydrogen energy-based microgrid using modified weighted majority algorithm. *International Journal of Hydrogen Energy*, 48(18), 6824-6836.
- Bayrak, G., Yılmaz, A., & Çakmak, R. (2023). A new Fuzzy&Wavelet-based adaptive thresholding method for detecting PQDs in a hydrogen and solar-energy powered EV charging station. *International Journal of Hydrogen Energy*, 48(18), 6855-6870.
- Bayrak, G., & Yılmaz, A. (2023). A Deep Learning-Based Islanding Detection Approach by Considering the Load Demand of DGs Under Different Grid Conditions. In *Prediction Techniques for Renewable Energy Generation and Load Demand Forecasting* (pp. 61-76). Singapore: Springer Nature Singapore.

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

- Bayrak, G., Yılmaz, A., & Çalışır, A. (2023). A new intelligent decision-maker method determining the optimal connection point and operating conditions of hydrogen energy-based DGs to the main grid. *International Journal of Hydrogen Energy*.
- Bayrak, G., Yılmaz, A., & Demirci, E. (2023). Fault ride-through capability enhancement of hydrogen energy-based distributed generators by using STATCOM with an intelligent control strategy. *International Journal of Hydrogen Energy*.

- Bayrak, G., & Yılmaz, A., Karadeniz, A. (2022). Dual-axis solar tracking system providing an intelligent step changing range (SCR) approach using real-time FDM with a sensorless design., *Digital Technologies for Solar Photovoltaic Systems: From general to rural and remote installations*, IET, (Book DOI: 10.1049/PBPO228E)

