

**YÜKSEK GERİLİM DOĞRU AKIM ENERJİ İLETİMİNDE MEYDANA GELEN
ARIZALARIN SAYISAL KORUMA YÖNTEMLERİ İLE BELİRLENMESİ**

Fatih ÜNAL

**Yüksek Lisans Tezi
Enerji Sistemleri Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Sami EKİCİ
Eylül-2016**

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK GERİLİM DOĞRU AKIM ENERJİ İLETİMİNDE MEYDANA GELEN
ARIZALARIN SAYISAL KORUMA YÖNTEMLERİ İLE BELİRLENMESİ

YÜKSEK LİSANS TEZİ

Fatih ÜNAL

142135111

Tezin Enstitüye Verildiği Tarih: 31 Ağustos 2016

Tezin Savunulduğu Tarih : 23 Eylül 2016

Tez Danışmanı : Prof. Dr. Sami EKİCİ (F.Ü)

Diğer Jüri Üyeleri : Doç. Dr. Resul ÇÖTELİ (F.Ü)

Yrd. Doç. Dr. Mehmet ÜSTÜNDAĞ (B.Ü)

EYLÜL-2016

ÖNSÖZ

Bu yüksek lisans tez çalışmasında bana değerli zamanını ayırarak her türlü destekte bulunan başta danışman hocam Prof. Dr. Sami Ekici' ye ve tüm hocalarıma teşekkürlerimi ve minnetimi sunarım. Ayrıca tüm bu süreçte her zaman arkamda olan aileme ve özellikle kardeşim Furkan'a teşekkür ederim.

Fatih ÜNAL
ELAZIĞ-2016



İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	I
İÇİNDEKİLER	II
ÖZET.....	IV
SUMMARY	V
ŞEKİLLER LİSTESİ.....	VI
TABLolar LİSTESİ.....	X
SEMBOLLER LİSTESİ	XI
KISALTMALAR LİSTESİ	XII
1. GİRİŞ	1
1.1. Literatür Çalışması	4
1.2. Tezin Amacı	7
1.3. Yöntem.....	8
2. YGDA İLE ENERJİ İLETİMİ	9
2.1. GKD-YGDA İstasyon Temel Elemanları.....	10
2.2. YGDA İletim Hatları	15
2.3. YGDA Koruma Sistemleri.....	18
2.4. YGDA Sistemlerin Avantajları ve Dezavantajları	20
3. AKIM VE GERİLİM DALGA ŞEKİLLERİNDEN ÖZELLİK ÇIKARIMI	23
3.1. Dalgacık Dönüşümü	23
3.1.1. Sürekli Dalgacık Dönüşümü (SDD)	25
3.1.2. Ayırık Dalgacık Dönüşümü (ADD)	26
3.1.3. Dalgacık Entropisi.....	29
3.2. Stockwell Dönüşümü.....	30
3.2.1. Ayırık Stockwell Dönüşümü	32
3.3. Hilbert-Huang Dönüşümü (HHD).....	33
3.3.1. Deneysel Mod Ayırıştırma (DMA)	34
3.3.2. Hilbert Spektral Analizi (HSA).....	38
4. ARIZA YERİ BELİRLEMEDE KULLANILAN YÖNTEMLERİ.....	40
4.1. Yapay Sinir Ağları.....	40
4.2. Destek Vektör Makineleri.....	43
4.2.1. İkili Sınıflandırma Algoritması	44

4.2.2.	En Küçük Kareler Destek Vektör Makineleri.....	47
4.3.	Uç Öğrenme Makineleri	50
5.	BENZETİM ÇALIŞMASI	55
5.1.	Dalgacık Dönüşümü ile Özellik Çıkarımı	64
5.2.	Stockwell Dönüşümü ile Özellik Çıkarımı	66
5.3.	Hilbert-Huang Dönüşümü ile Özellik Çıkarımı	70
6.	ARIZA YERİ TAHMİNİ	75
6.1.	YSA ile Arıza Tespiti	75
6.2.	LS-SVM ile Arıza Tespiti.....	84
6.3.	ELM ile Arıza Tespiti.....	92
7.	SONUÇLAR	98
8.	TARTIŞMALAR	99
KAYNAKÇA.....		100
ÖZGEÇMİŞ		106

ÖZET

Bu çalışmada, YGDA iletim hatları üzerinde meydana gelen arızaların konumunu tahmin etmeye yardımcı olacak birbirinden farklı sinyal analiz ve makine öğrenme yöntemleri kullanılmıştır. Arıza tahmini için kullanılan arıza akım ve gerilim sinyalleri Matlab programında bulunan benzetim çalışması vasıtasıyla elde edilmiştir. Benzetim çalışmasındaki iletim hattının her bir km'sinden elde edilen arıza akım ve gerilim sinyalleri, dalgacık dönüşümü, Stockwell dönüşümü ve Hilbert-Huang dönüşümü yöntemleri kullanılarak analiz edilmiştir. Böylece, geçici arıza durumlarına ait ayırt edici özellikler elde edilmiştir. Özellik vektörlerinin boyutunu azaltmak için bu yöntemlere; enerji, entropi, standart sapma, ortalama büyüklük, anlık frekansların ve genliklerin ortalaması gibi farklı ölçütler uygulanmıştır. Arıza tahmini aşamasında ise istatistiksel öğrenme teorisine dayanan destek vektör makinaları, yapay sinir ağları ve uç öğrenme makinaları yöntemleri kullanılmıştır. Farklı sinyal analiz yöntemlerinin arıza yeri tahmini performansı üzerindeki etkileri araştırılarak en uygun arıza konumlandırma algoritması belirlenmiştir. Elde edilen sonuçlardan, önerilen yöntemin arıza tahmini aşamasında oldukça başarılı olduğu görülmüştür.

Anahtar Kelimeler: YGDA iletim hattı arızaları, ayrık dalgacık dönüşümü, Stockwell dönüşümü, Hilbert-Huang dönüşümü, destek vektör makinaları, yapay sinir ağları, uç öğrenme makinaları.

SUMMARY

Determining Faults in High Voltage Direct Current Transmission by using Numerical Protection Methods

In this study, different signal analysis and machine learning methods were used to help to predict the location of faults occurring on HVDC transmission lines. The fault current and voltage signals used for fault prediction were obtained by simulation in Matlab. The fault current and voltage signals obtained from each km of transmission line simulation were analyzed by using wavelet transform, Stockwell transform and Hilbert-Huang transform methods. Thus, the distinctive features of transients are obtained. In this methods to reduce the size of feature vectors, different criterions such as; energy, entropy, standard deviation, mean magnitude, the mean of the instantaneous frequency and amplitude are employed. In the fault estimation process, support vector machines which are based on statistical learning theory, artificial neural networks and extreme learning machines methods are used. By investigating impacts of those different signal analysis methods on fault estimation process, optimal fault location algorithm is determined. The obtained results show that the proposed approach is very successful in fault estimation and location process.

Key Words: HVDC transmission line faults, discrete wavelet transform, Stockwell transform, Hilbert-Huang Transform, support vector machines, artificial neural networks, extreme learning machines.

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1	YGDA sistemlerde farklı bağlantı şekilleri (a) tek kutuplu toprak dönüşlü (b) tek kutuplu metalik dönüşlü (c) eş kutuplu gösterim (d) çift kutuplu gösterim..9
Şekil 2.2	YGDA iletim hatlarında (a) ard-arda bağlantı (b) çok terminalli bağlantı10
Şekil 2.3	İki seviyeli dönüştürücü kullanan simetrik tek kutuplu bir GKD-YGDA iletim sistemi şeması [14].....11
Şekil 2.4	DA kesici bulunduran bir GKD dönüştürücü devresi [14].12
Şekil 2.5	YGDA sistemlerde kullanılan bir aktif filtrenin ana devresi12
Şekil 2.6	YGDA sistemde kullanılan tristörlü anahtar devresi [15].13
Şekil 2.7	Farklı gerilim kaynaklı dönüştürücü topolojileri (a) iki seviyeli GKD (b) üç seviyeli GKD14
Şekil 2.8	YGDA ve YGAA sistemleri hat uzunluğu-maliyet karşılaştırması16
Şekil 2.9	Elektrot hattı bulunan havai YGDA iletim hattı (a) çift kutuplu YGDA iletim hattı (b) koruma iletkeni olarak kullanılan elektrot hat [15].17
Şekil 2.10	Denizaltı YGDA iletim hatlarında kullanılan farklı kablo çeşitleri (a) selüloz bazlı kütlemendirilmiş kablo (b) petrol bazlı kablo (c) gaz izolasyonlu iç basınçlı kablo (d) ekstürde polietilen kablo [18].17
Şekil 2.11	AA ve DA iletim hatlarının mesafe-maliyet karşılaştırması [15].22
Şekil 3.1	Fourier dönüşümü ve dalgacık dönüşümü arasındaki ilişki (a) zaman-büyüklik dönüşümü23
Şekil 3.2	Dalgacık dönüşümünde kullanılan farklı dalgacık çeşitleri (a) Haar dalgacık (b) Meyer dalgacık (c) Gauss dalgacığı (d) Morlet dalgacık [26].24
Şekil 3.3	ADD yöntemi işlem basamakları28
Şekil 3.4	HHD işlem basamakları33
Şekil 3.5	DMA yönteminin işlem basamakları36
Şekil 4.1	YSA işlem basamakları.....40
Şekil 4.2	Çok katmanlı algılayıcı ağ yapısı42
Şekil 4.3	En uygun ayırıştırıcı düzlem ve destek vektörleri44
Şekil 4.4	Fisher diskriminant analizi [60].....48
Şekil 4.5	LS-SVM ile Fisher diskriminant analizi arasındaki ilişki [60].49

Şekil 5.1	Doğrultucu ve evirici elemanlarının kararlı durum karakteristikleri	56
Şekil 5.2	VDAOL karakteristisi; $I_{d_ref}=f(V_{dL})$	57
Şekil 5.3	Benzetim çalışmasında kullanılan YGDA sistem ve ekipmanları.....	58
Şekil 5.4	YGDA sistemin doğrultucu elemanının başlangıçtaki akım, gerilim, alfa ve kontrol modu değerleri.....	59
Şekil 5.5	YGDA sistemin evirici elemanının başlangıçtaki akım, gerilim, alfa, kontrol modu ve gama değerleri.....	60
Şekil 5.6	DA iletim hattının 50. km'sinde meydana gelen örnek tek faz-toprak arızası gerilim, akım, alfa R (doğrultucu kısım).....	61
Şekil 5.7	DA iletim hattının 50. km'sinde meydana gelen örnek tek faz-toprak arızası gerilim, akım, alfa ve arıza akımı (evirici kısım)	62
Şekil 5.8	YGDA iletim hattının 15. ve 285. km'lerindeki tek faz-toprak arızanın akım ve gerilim değişimleri.....	63
Şekil 5.9	15.km'deki arıza akım sinyalinin ADD' sinin ilk 5 seviyesi	65
Şekil 5.10	15.km'deki arıza gerilim sinyalinin ADD' sinin ilk 5 seviyesi.....	65
Şekil 5.11	Gürültü eklenmiş örnek bir sinüs dalgasının S-dönüşümü	67
Şekil 5.12	15.km'ye ait arıza gerilim sinyalinin S-dönüşümü	68
Şekil 5.13	15.km' ye ait arıza akım sinyalinin S-dönüşümü.....	68
Şekil 5.14	285. km'ye ait arıza gerilim sinyalinin S-dönüşümü	69
Şekil 5.15	285.km'ye ait arıza akım sinyalinin S-dönüşümü.....	69
Şekil 5.16	15.km' deki gerilim sinyalinin HHD analizinden elde edilen ilk 5 IMF	71
Şekil 5.17	Arıza gerilim sinyalinin HHD analizinden elde edilen ilk 4 IMF'nin büyüklük ve frekans değişimleri	72
Şekil 5.18	15.km' deki akım sinyalinin HHD analizinden elde edilen ilk 5 IMF	72
Şekil 5.19	Arıza akım sinyalinin HHD analizinden elde edilen ilk 4 IMF'nin büyüklük ve frekans değişimleri.....	74
Şekil 5.20	15. km'ye ait arıza akım ve gerilim sinyallerinin Hilbert enerji spektrumları: (a) gerilim (b) akım.....	75
Şekil 6.1	S-dönüşümü-YSA uygulamasında kullanılan YSA' nın yapısı.....	77
Şekil 6.2	S-dönüşümü-YSA uygulaması regresyon değerlerinin program çıktısı	77
Şekil 6.3	S-dönüşümü-YSA uygulamasının ortalama karesel hata (mse) fonksiyonunun program çıktısı.....	78

Şekil 6.4	S-dönüşümü-YSA uygulamasının test aşamasından elde edilen gerçek ve tahmini km'ler.....	78
Şekil 6.5	ADD-YSA uygulamasında kullanılan YSA' nın yapısı.....	79
Şekil 6.6	ADD-YSA uygulaması regresyon değerlerinin program çıktısı	80
Şekil 6.7	ADD dönüşümü-YSA uygulamasının ortalama karesel hata (mse) fonksiyonunun program çıktısı.....	80
Şekil 6.8	ADD-YSA uygulamasının test aşamasından elde edilen gerçek ve tahmini km'ler	81
Şekil 6.9	HHD-YSA uygulamasında kullanılan YSA' nın yapısı	82
Şekil 6.10	HHD-YSA uygulaması regresyon değerlerinin program çıktısı	82
Şekil 6.11	HHD dönüşümü-YSA uygulamasının ortalama karesel hata (mse) fonksiyonunun program çıktısı.....	83
Şekil 6.12	HHD-YSA uygulamasının test aşamasından elde edilen gerçek ve tahmini km'ler	83
Şekil 6.13	S-dönüşümü-LS-SVM uygulamasının (a) eğitim ve (b) test aşamalarında elde edilen tahmini km'ler	86
Şekil 6.14	S-dönüşümü-LS-SVM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı.....	87
Şekil 6.15	ADD-LS-SVM uygulamasının (a) eğitim ve (b) test aşamalarında elde edilen tahmini km'ler.....	88
Şekil 6.16	ADD-LS-SVM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı.....	89
Şekil 6.17	HHD-LS-SVM uygulamasının eğitimi aşamasında elde edilen tahmini km' ler .	89
Şekil 6.18	HHD-LS-SVM uygulamasının test aşamasında elde edilen tahmini km'ler.....	90
Şekil 6.19	HHD-LS-SVM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı.....	90
Şekil 6.20	S-dönüşümü-ELM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı.....	93
Şekil 6.21	S-dönüşümü-RELM uygulamasının test aşamasından elde edilen regresyon fonksiyonunun program çıktısı.....	94
Şekil 6.22	S-dönüşümü-ELM ve RELM uygulamasının test aşamasından elde edilen gerçek ve tahmini km' ler	94

Şekil 6.23	ADD-ELM ve RELM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı.....	95
Şekil 6.24	ADD-ELM ve RELM uygulamasının test aşamasından elde edilen gerçek ve tahmini km' ler.....	96
Şekil 6.25	HHD-RELM uygulamasının test aşamasından elde edilen gerçek ve tahmini km' ler.....	96
Şekil 6.26	HHD-RELM uygulamasının test aşamasından elde edilen regresyon fonksiyonunun program çıktısı.....	97



TABLÖLER LİSTESİ

	<u>Sayfa No</u>
Tablo 2.1 AA kısım koruma algoritmaları ve kullanım amacı	19
Tablo 2.2 DA kısım koruma algoritmaları ve kullanım amacı	20
Tablo 3.1 Hilbert-Huang dönüşümünde IMF'lerin elde edilmesi	36
Tablo 5.1 Benzetim çalışmasında yer alan DA iletim hattının özellikleri.....	55
Tablo 5.2 Fourier dönüşümü, dalgacık dönüşümü ve Hilbert-Huang dönüşümü yöntemlerinin karşılaştırması	73
Tablo 6.1 HHD-YSA uygulamasında kullanılacak özellikler	81



SEMBOLLER LİSTESİ

A	: Sinyalin genliği
b_j	: YSA nöronu eşik değeri
E	: Sinyalin enerjisi
E_{jk}	: j ölçeğindeki sinyalin dalgacık enerji spektrumları
e_k	: Hata fonksiyonu
f_s	: Örnekleme frekansı
$f(x)$	: Sınıflandırma işlemi için tanımlanmış aşırı düzlem
$H(S)$	: Sinyalin Shannon entropisi
H	: En uygun ayrıştırıcı düzlem
$K(x_i, x)$	: Doğrusal olmayan çekirdek fonksiyon
$H^\dagger$	: H matrisinin Moore-Penrose ters matris dönüşümü
L^p	: Hilbert özellik uzayı
$\tilde{N}$	: Ara katman nöron sayısı
p_i	: i . örneğin (A, p) uzayında olma olasılığı
$S(\tau, f)$	: $h(t)$ fonksiyonunun Stockwell dönüşümü
w_j	: Ağırlık katsayıları
X_i	: i . giriş değeri
Y_i	: i . çıkış değeri
$\psi(x)$	: Dalgacık fonksiyonu
$\psi_{s,\tau}^*(t)$	: Ana dalgacık
τ	: Öteleme faktörü
$\varphi_{j,k}(t)$	: Ölçekleme fonksiyonu
$\lambda_j(k)$	: Yaklaşık katsayılar
$\gamma_j(k)$	: Detay katsayılar
ϕ	: Sinyalin faz açısı
ω	: Anlık frekans
φ	: Aktivasyon fonksiyonu
α_i, α_j	: Lagrange çarpanları
β_i	: i . gizli katman ve çıkış katmanı arasındaki ağırlık vektörü
η	: Öğrenme oranı
α	: Gecikme açısı
γ	: Sönümleme açısı
μ	: Komutasyon açısı
σ	: Standart sapma
σ^2	: Gauss çekirdek fonksiyonun varyansı

KISALTMALAR LİSTESİ

DA	: Doğru Akım
YGDA	: Yüksek Gerilim Doğru Akım
AA	: Alternatif Akım
FACTS	: Flexible AC Transmission System
IGBT	: Insulated Gate Bipolar Transistor
LCC	: Line Commutated Converter
SCC	: Self Commutated Converter
HHD	: Hilbert Huang Dönüşümü
HSA	: Hilbert Spektral Analiz
DMA	: Deneysel Mod Ayırıştırma
GKD-YGDA	: Gerilim Kaynaklı Dönüştürücülü YGDA
DVM	: Destek Vektör Makinaları
ADD	: Ayrık Dalgacık Dönüşümü
SDD	: Sürekli Dalgacık Dönüşümü
GKD	: Gerilim Kaynaklı Dönüştürücü
YGAA	: Yüksek Gerilim Alternatif Akım
KZFD	: Kısa Zamanlı Fourier Dönüşümü
DEE	: Dalgacık Enerji Entropi
SD	: Stockwell Dönüşümü
AF	: Anlık Frekans
HFD	: Hızlı Fourier Dönüşümü
AFD	: Ayrık Fourier Dönüşümü
IMF	: İçsel Mod Fonksiyonu
YSA	: Yapay Sinir Ağları
LS-SVM	: Least Squares Support Vector Machine
RKHS	: Reproducing Kernel Hilbert Space
KKT	: Karush-Kuhn-Tucker Sistemler
ELM	: Extreme Learning Machines
RELM	: Regularized Extreme Learning Machine
MSE	: Mean Squared Error

1. GİRİŞ

Bir ülkenin ekonomik olarak gelişmişlik düzeyi o ülkenin tükettiği elektrik enerjisi ve bu enerji ihtiyacını nasıl sağladığıyla alakalıdır. Günümüzde medeniyetlerin ayakta kalabilmesi, endüstriyel teşebbüslerin devamı ve sosyal yapıların hizmetlerini sağlıklı bir şekilde yerine getirebilmeleri için düşük maliyetli ve devamlılık arz edebilen enerji kaynaklarına ve enerji ağlarına ihtiyaçları vardır. Modern Dünya’da artık yaşamımızın vazgeçilmez bir parçası haline gelmiş enerji ihtiyacı her geçen gün artan enerji santralleri, elektrik şebekeleri, elektronik kontrol sistemleri v.s. sayesinde karşılanmaktadır. Herhangi bir insan gücüne ve elle kontrol şartına bağlı kalmaksızın oluşturulan sistemler güç sistemlerini de içine alan kocaman tek bir sisteme doğru atılan ilk adımlar olarak düşünülebilir. Böylelikle elektrik güç sistemleri gelişmiş ülkelerin bel kemiği ve en önemli kısmı olarak düşünülmelidir.

Bu çalışmada elektrik şebekelerinde verim artırımına yönelik alt başlıklardan bir tanesi olan Doğru Akım (DA) ile iletim yöntemlerinden ve arıza konumlandırma işlemlerinden bahsedilmiştir. Enerjinin üretilmesinde son tüketiciye kadar tüm sistem üzerinde etkili olan enerji verimliliği kavramı mevcut sistemlerin optimizasyonu, yeni teknolojiler, daha güçlü yazılım ve donanım alt yapıları sayesinde geliştirilmeye başlanmıştır.

Yenilenebilir enerji santrallerinin enerji piyasasında her geçen gün artan bir grafik çizmesi ve küresel iklim değişikliğinin toplumlar üstündeki gözle görülür etkileri sadece enerjinin üretim aşamasını değil iletiminden dağıtımına kadar olan tüm aşamalarda farklı bakış açılarının kazanılmasına da yardımcı olmuştur.

Yüksek Gerilim Doğru Akım (YGDA) iletim sistemleri enerji verimliliği kavramı gibi sonradan hayatımıza girmiş ve gelişmekte olan bir teknolojidir. Uzak mesafelere yüksek güç seviyelerinin taşınmasında YGDA sistemlerin kullanılması hızlı gelişim gösteren yüksek gerilim dönüştürücülerinin ve diğer yüksek gerilim cihazların önemi büyüktür. YGDA sistemler günümüzde uzun mesafelerde yüksek güç seviyelerinin iletilmesinde etkili ve verimli bir sistem olarak tanınmaktadır.

Alternatif Akım (AA)’a kıyasla DA ile iletimin birçok avantajı bulunmaktadır. Bunlardan bazıları uzun mesafeler için düşük net kayıplar, iletken başına daha fazla güç iletimi ve dönüş yolu olarak toprak altından iletimin gerçekleştirilebilmesi gibi farklı

görevlerdir. Toprak altında iletimin bir başka avantajı ise her bir iletkenin bağımsız bir devre olarak düşünülebilmesidir. Herhangi bir yük akımı ve yüzey etkisi gibi dış etkenlere maruz kalmadığı için reaktif güç ihtiyacı yoktur. Sistem senkronizasyonu ve kararlılık problemlerini ortadan kaldırması, daha basit iletim direkleri, farklı frekanslardaki AA sistemleri birbirine bağlaması gibi birçok farklı görevi de yerine getirebilmektedir. YGDA sistemler özellikle deniz altı ve toprak altı bağlantı uygulamalarında oldukça fazla kullanılmaktadır. YGDA sistemlerin güvenilirlik değerlendirme aşamasında ise iletim hattı ekipmanları ve istasyonlar birinci derece önem arz etmektedir.

Basit bir YGDA istasyonunda birçok farklı yapıda ekipman ve alt sistemler bulunmasına karşılık, sistem güvenilirliğini en çok etkileyen bileşenler iletim hatları ve dönüştürücü-transformatör bölümleridir. Dönüştürücü-transformatör bölümleri iletim hattının her iki ucunda da bulunmaktadır. YGDA sistemin en önemli bileşenlerinden olan dönüştürücü-transformatör grupları güç iletimindeki kararlılık ve güvenilirlik parametrelerini doğrudan etkilemektedir. Dönüştürücü-transformatörde meydana gelen arızanın başlangıç aşamasında teşhis edilmesi, transformatörlerdeki elektriksel izolasyonun bozulmasından kaynaklı ciddi güç çıkışlarını da engellemede önemli bir role sahiptir. Sonuç olarak transformatörlerin periyodik olarak gözden geçirilmesi başlangıç aşamasındaki arızanın sistemden en kısa sürede uzaklaştırılması için oldukça önemlidir.

Dönüştürücü-transformatörlerde operasyon esnasında arızalar farklı şekillerde gerçekleşebilir. Bunlar iletim hattı kaynaklı, yıldırım düşmesi, anahtarlama problemleri, kesicilerin yanlışlıkla yeniden açılması, sistemin aşırı yüklenmesi veya rezonans gibi nedenlerden dolayı olabilir.

YGDA iletim hatlarının maliyet analizi dikkate alındığında genel olarak şu sonuç çıkarılabilir:

- AA iletim yapan sistemlerde mesafe arttıkça reaktif güç ihtiyacı, ara kompanzasyon merkezleri, gerilim düşüşleri artmakta, bu ise sistem verimini olumsuz yönde etkilemektedir.
- DA iletim sistemlerinde ise iletim hattının kendisinin reaktif güç ihtiyacının bulunmamasına karşılık dönüştürücü istasyonlarının reaktif güç ihtiyacı, çok kutuplu istasyonların kontrol zorluğu, işletme masrafları v.s. gibi nedenlerden dolayı olumsuz yönde etkilenmektedir.

- Başa baş mesafe göz önünde bulundurulduğunda maliyet açısından DA iletim hatları büyük avantajlara sahipken, geleneksel AA iletim hatlarının yoğun şekilde kullanılması ve son yıllardaki güç elektroniği ekipmanlarında meydana gelen hızlı değişim sonucunda Esnek Alternatif Akım İletim Sistemler (FACTS)'in rağbet görmesi sonucunda DA ile iletimin şimdilik sadece özel uygulamalarda, kara-deniz bağlantılarında ve daha çok asenkron bağlantılarda kullanılacağı sonucu çıkarılabilir.

YGDA sistemlerin gelişmesine yön veren parametrelerden bazıları ise anahtarlama elemanları ve dönüştürücü-doğrultucu gruplarında kaydedilen gelişmelerdir. Tristörlü geleneksel akım kaynaklı dönüştürücülerin yerine IGBT (Insulated Gate Bipolar Transistor) kullanan gerilim kaynaklı dönüştürücülerin kullanılmaya başlanması güç ve gerilim seviyelerinde ciddi artışlara neden olmuştur. Günümüzde yaygın olarak kullanılan YGDA sistemler gerilim kaynaklı dönüştürücülerdir. Bunun nedeni ise güç akış yönünün değiştirebilmesidir. Gerilim kaynaklı dönüştürücülerde IGBT' lerin dışında farklı anahtarlama elemanları olarak (GTO, MOSFET, PWM v.s.) kullanılmaktadır. Bunların dışında akım kaynaklı dönüştürücüler hat komutasyonlu (LCC) ve gerilim kaynaklı dönüştürücüler ise kendinden komutasyonlu (SVC) olarak adlandırılmaktadır.

YGDA sistemlerde kullanılan dönüştürücü-doğrultucu gruplarının dışında iletim hattının topolojisi de önem arz etmektedir. Bu bağlantı şekilleri uygulama alanlarına göre farklılıklar gösterebilmektedir. Örneğin; deniz-kara bağlantılarında kullanılan çoğunlukla tek kutuplu toprak dönüşlü sistemler iken, birden fazla istasyonun birbiriyle bağlantılarının yapılmasında çift kutuplu metalik dönüşlü hat topolojisi en iyi çözümdür. Bunların dışında deniz üstü petrol-doğal gaz platformlarında ve rüzgar çiftliklerinde tercih edilen gerilim kaynaklı dönüştürücüler birbirleri ile tek kutuplu olarak bağlanmakta ve böylece tek bir hat üzerinde farklı istasyonların birleştirilmesi sağlanmaktadır.

Koruma ekipmanları ve kullanılan arıza tespit yöntemleri AA sistemlerle benzerlik göstermesine karşılık hattın akım ve gerilim karakteristikleri YGDA sistemlerde tamamen farklıdır.

YGDA iletim hatlarında arıza tespit yöntemleri genel olarak empedans ölçümü, akım ve gerilimlerin yüksek frekanslı spektrumlarından faydalanılarak geliştirilmiş sinyal analiz yöntemleri, akıllı şebeke uygulamaları ve klasik yürüyen dalga yöntemidir.

1.1. Literatür Çalışması

YGDA sistemler AA iletim hatlarına kıyasla daha uzak mesafelere daha büyük kapasitelerde güç iletimi gerçekleştirilebilmektedir. Bunun sonucu olarak geniş coğrafi alanlarda ve farklı frekanslarda çalışan büyük şebekelerin birbirleriyle bağlantısının yapılmasında en ekonomik tercih olarak görülmektedir. YGDA sistemlerde son zamanlarda popülerlik kazanan çok terminalli bağlantı şekilleri hatta meydana gelebilecek muhtemel arızaların tespit edilmesini zorlaştırmaktadır. Bu durum ise sistem güvenliği ve kararlılığını en çok etkileyen parametrelerden biri olan iletim hatları için geliştirilen arıza tespiti ve arıza konumlandırma algoritmalarına büyük önem kazandırmaktadır.

Son yıllarda yapılan literatür çalışmalarına bakıldığında YGDA iletim hatlarında arıza tespit yöntemleri genel olarak yürüyen dalga yöntemi, sinyal ayrıştırma yöntemleri, akıllı şebeke uygulamaları gibi alanlarda yoğun olarak sürdürülmektedir.

(Schweitzer, 2013)'te yaptığı çalışmada 117 km iletim hattı uzunluğuna sahip ve 161 kV' luk 3 fazlı bir AA sistemin her iki ucuna yürüyen dalga detektörü yerleştirmiş ve gerçek zamanlı olarak arıza durumun ve normal operasyon durumunun akım ve gerilim bilgilerini kaydetmiştir. Bu akım ve gerilim bilgilerinden yararlanarak yürüyen dalga detektörünün bulduğu km'leri ve gerçek km'leri karşılaştırmıştır. 0.2 μ s arıza tespit süresi ve 60 metreye kadar düşen doğruluk oranıyla yürüyen dalga yönteminin empedans temelli yöntemlere kıyasla üstünlüklerin bahsetmiştir [1].

(Abdel-Salam v.d., 2013) yaptığı çalışmada arıza akımının yüksek frekanslı bileşenlerinden faydalanmanın yürüyen dalga arıza konumlandırma algoritmasının güvenilirliğini artırdığından bahsetmiştir. Bu yüksek frekanslı sinyallerin çözülmesi ve analizi aşamasında dalgacık dönüşümü yönteminden faydalanmıştır. Bu yöntemin ise arıza empedansı ve arıza başlangıç açısından bağımsız olarak birçok avantajlara sahip olduğundan bahsetmiştir. Benzetim çalışmasında Matlab/Simulink programından faydalanmıştır [2].

(Liu v.d., 2007) çalışmasında YGDA sistemlerin hat koruma algoritmalarında yeni bir yaklaşım olan sürekli dalgacık dönüşümü yöntemini kullanmıştır. Sistemin doğrultucu tarafından elde edilen DA gerilim sinyallerinin dalgacık dönüşümünün modül maksimumlarından yararlanarak daha kullanışlı yürüyen dalga sinyalleri elde edilmiştir.

Bunların dışında sistem performansını olumsuz etkileyen sınır bölge bozulmaları ve gürültü azaltma gibi problemlere de değinmiştir. Çalışmada bahsedilen koruma algoritmasının AA tarafında meydana gelebilecek geçici arızaları DA tarafındaki tek faz-toprak arızalarından ayırt edebilecek ve yüksek dirençli toprak arızaları gibi durumlarda kullanılabileceğinden bahsetmiştir [3].

(Zhang v.d., 2010) çalışmasında YGDA sistemlerde sınır koruma algoritmalarında farklı bir yaklaşım olan ve sürekli olmayan geçici arıza sinyallerin analizinde kullanılan Hilbert-Huang Dönüşümü (HHD)'den faydalanmıştır. Hilbert Spektral Analizi (HSA) ve Deneysel Mod Ayırıştırma (DMA) yönteminin birleşimi olarak önerilen bu yeni sinyal ayırıştırma yöntemi sayesinde hattın kendisinde veya dışında meydana gelebilecek arızaları tespit edebilmesi kolaylaşmaktadır. Sınır bölge ve eşik değer belirleme aşamasında ise yüksek frekanslı geçici arıza gerilim sinyallerinden faydalanılmıştır [4].

(Yi-ning v.d., 2011) çalışmasında yürüyen dalga yönteminde genellikle sabit bir değer olarak kabul edilen yürüyen dalga hızının değişken olması durumundaki deneysel varsayımlardan bahsetmiştir. Özellikle çok uzak mesafelerde arıza dalgasının büyüklüğünde meydana gelebilecek azalmaların arıza konumlandırma yöntemlerinde hata meydana getirdiğinden bahsetmiştir [5].

(Burek v.d., 2015) çalışmasında sinyal işleme yöntemleri arasında yer alan genetik algoritma yöntemini geçici arıza durumlarında akım değerlerindeki azalan ve periyodik olmayan bileşenlerin tahmini aşamasında kullanmıştır. Yürüyen dalga yönteminin zaman çözümlemesi aşamasındaki verimsizlikleri kaldırabilmesi için algoritmanın başlangıç şartı için (5-100 kHz' a kadar ki) düşük örnekleme frekansı kullanılmıştır. Ayrıca önerilen yöntemin avantajlarından ve dezavantajlarından bahsedilmiştir [6].

(Liu v.d., 2009) çalışmasında yürüyen dalga koruma ve sınır koruma prensibinin her ikisini de kullandığı hibrit bir algoritma kullanmıştır. Tek kutuplu YGDA hattından elde edilen DA sinyalleri sürekli dalgacık dönüşümü yöntemiyle analiz edilmiştir. Yürüyen dalga yönteminde kullanılmak üzere modül maksimumları elde edilmiştir. Sürekli dalgacık dönüşümünün sınır koruma prensibi ve yürüyen dalga yöntemi korumanın birlikte kullanılmasıyla sistem kaynaklı ve dış ortam kaynaklı arızaların birbirinden ayrılması sağlanmıştır. Çalışmada aynı zamanda sınır bölge bozulmaları, gürültü, yüksek arıza

direnci, yıldırım çarpması veya terminal istasyonlarından kaynaklanabilecek farklı durumlar v.s. göz önünde bulundurulmuştur [7].

(GuoBing v.d., 2011) çalışmasında Gerilim Kaynaklı Dönüştürücülü YGDA sistemler (GKD-YGDA)'deki dağıtılmış parametrelili iletim hatlarında yürüyen dalgaların geri yansıma (reflection process) aşamasında elde edilen doğal frekansının kullanıldığı bir yöntem önermiştir. İletim hattının tek bir terminali kullanılmış ve her bir terminalde bulunan büyük şönt kapasitörlerin varlığından dolayı yüksek frekanslı yürüyen dalgaların terminallerden büyük oranda yansıdığı varsayılmıştır. Bu varsayımdan yola çıkılarak iletim hattının doğal frekansının sadece arıza noktası, arıza direnci ve yürüyen dalga hızıyla ilişkili olduğu gösterilmiştir [8].

(Liu v.d., 2014) çalışmasında DA iletim hatlarının terminallerinde tespit edilen belirli akım değerlerinin yön karakteristiklerinden yola çıkarak yeni bir YGDA iletim hattı pilot koruması önermektedir. Önerdiği bu pilot korumada belirli frekans aralığındaki akım değerleri DA filtrelerden spektrum analizi yardımıyla elde edilmiştir. Bu elde edilen akımların yönlerinden faydalanılarak arızanın iletim hattında mı yoksa başka bir kısımda mı olduğuna karar verilmiştir. Ayrıca çalışmada YGDA iletim hatlarında arka plan koruma olarak kullanılabilecek gerilim türevi kriteri ve yürüyen dalga yönteminden bahsedilmiştir. Benzetim çalışmalarından elde edilen sonuçlar yorumlanmış ve yüksek dirençli arızaları ayırt edebilmedeki kabiliyetlerinden bahsedilmiştir [9].

(Triveno v.d., 2015) çalışmasında arıza dalgasının yönünü belirleme aşamasında morfolojik filtreler kullanmıştır. Akım ve gerilim sinyallerinin üst üste bindirilmesiyle oluşturulmuş morfolojik filtre ve yapısal element sayesinde arıza konumunun tahmin edilmesi sağlanmıştır. Örnek veri setlerinin oluşturulması aşamasında hattın hem tek terminali hem de çift terminali ayrı ayrı kullanılmıştır. Önerilen yaklaşımda analizi yapılan sinyal, morfolojik filtre, yapısal elementin boyutu ve tipi, örnekleme oranı, arıza direnci ve arıza konumu gibi birden fazla parametrenin etkileri değerlendirilmiştir. Ayrıca arıza noktasının belirlenmesi aşamasında daha az hesaplama, basitlik ve sabit örnekleme hızı gibi avantajlardan da bahsedilmiştir [10].

(Livani ve Evrenosoğlu, 2013) yaptıkları çalışmada hem havai hattın hem de yer altı kablosunun kullanıldığı YGDA iletim hatlarındaki arızaların tespiti aşamasında Destek Vektör Makinaları (DVM) ve yürüyen dalga yönteminin her ikisinin de kullanıldığı bir

yaklaşımından faydalanmışlardır. Tek terminalden elde edilen akım ve gerilim sinyallerinin analizi aşamasında Ayrık Dalgacık Dönüşümü (ADD) kullanılmıştır. Bu akım ve gerilim sinyallerinin verileri tek bir özelliğe indirgenmiş ve bu özellik ise dalgacık enerjisi olarak belirlenmiştir. İlk aşama olarak DVM' nin sınıflandırma işlemi sayesinde arızanın hattın hangi bölgesinde olduğu belirlenmiş, ikinci aşamada ise yürüyen akım dalgasının polaritesi ve gerilim dalgasının değerleri sayesinde terminale ilk ulaşan arıza dalgası ve ikinci arıza dalgası arasındaki zaman farkından faydalanılarak arızanın yeri tahmin edilmiştir. Farklı arıza senaryoları test edilerek önerilen algoritmanın doğruluğu test edilmiştir [11].

(Cui ve Tu, 2015) çalışmasında YGDA iletim hatlarındaki arızaların tespiti aşamasında genelleştirilmiş regresyon yapay sinir ağları yöntemi ve tekil değer ayrıştırma yöntemini kullanmıştır. Yürüyen arıza dalgasının özelliklerinin çıkartılması aşamasında tekil değer ayrıştırma kullanılmıştır. Daha sonraki aşamada ise yürüyen arıza dalgası ile arıza konumu arasındaki ilişkilerden faydalanarak yapay sinir ağı eğitilmiş ve test edilmiştir. Özellik çıkartma aşamasında sadece gerilim bilgilerinden faydalanılmış ve MATLAB/Simulink ortamında arıza kayıtları oluşturulmuştur. Tek faz-toprak arızaları ağın eğitiminden sonra arıza km'sini yaklaşık olarak 0.05 km hassasiyetle tespit edilebilmiştir [12].

(Nanayakkara v.d., 2012) çalışmasında hem havai hat hem de yer altı kablосundan oluşan klasik bir YGDA sistemde meydana gelebilecek arızaların tespiti aşamasında sadece terminal bilgilerinin kullanıldığı bir algoritma önermektedir. Dönüştürücü istasyonundan kaydedilen gerilim sinyallerine ve iletim hattıyla bağlantılı dalga kapasitörlerinden elde edilen akım sinyallerine Sürekli Dalgacık Dönüşümü (SDD) uygulanmış ve yürüyen arıza dalgasının varış zamanları elde edilmiştir. İletim hattının her iki ucundan elde edilen bilgilerden faydalanılarak oluşturulmuş bu yöntemde test ortamında ± 400 m kadar arıza konumu belirlenebilmektedir [13].

1.2. Tezin Amacı

Bu tez çalışmasında amaç, YGDA sistemlerde meydana gelen arızaları tespit etmeye yardımcı olacak yeni arıza konumlandırma algoritmaları geliştirmektir. Yürüyen dalga koruma ve empedans ölçümü gibi klasik arıza konumlandırma algoritmaları yerine son yıllarda güç sistemlerinde yaygın olarak kullanılmaya başlayan makine öğrenme yöntemleri ve sinyal analiz yöntemleri tezin genel yapısını oluşturmaktadır.

Sinyal analizi ve özellik çıkarımı aşamasında kullanılacak yöntemler; dalgacık dönüşümü, Hilbert-Huang dönüşümü ve Stockwell dönüşümüdür. Bu çalışmada, bu birbirinden farklı yöntemlerin avantajlarından ve dezavantajlarından bahsedilerek, makine öğrenme algoritmaları ile en uygun kombinasyonu belirlenecektir. Matlab programından faydalanarak oluşturulmuş YGDA benzetim çalışmasının doğru akım iletim hattı üzerinde farklı km'lerde meydana gelen tek faz-toprak arızaları incelenecektir.

Arıza konumlandırma ve tahmini aşamasında ise yapay sinir ağları, destek vektör makinaları ve uç öğrenme makinaları gibi farklı yaklaşımlar kullanılarak birbirleri arasındaki performans farklılıkları incelenecektir.


1.3. Yöntem

Bu tez çalışmasında, Matlab/Simulink/Simpowersystem ara yüzünde bulunan tek kutuplu YGDA sistemden faydalanılarak DA iletim hattı üzerindeki tek faz-toprak arızaları incelenmiştir. Benzetim çalışmasından elde edilen arıza akım ve gerilim sinyalleri farklı sinyal işleme yöntemleri kullanılarak analiz edilmiştir. Arıza süresi, büyüklüğü, frekans bileşenleri vs. gibi pek çok veriden faydalanarak sistemin genelini en doğru şekilde ifade edebilecek özellik vektörleri elde edilmiştir. Elde edilen bu özellik vektörleri normalizasyon işleminden sonra makine öğrenme yöntemlerinde arıza tahmini için kullanılmıştır.

Arıza akım ve gerilim sinyallerinin ön işleme aşamasında dalgacık dönüşümü, Hilbert-Huang dönüşümü, Stockwell dönüşümü kullanılmıştır. Özellik çıkarımı ve normalizasyon işlemlerinden sonra ise bu özellik vektörleri yapay sinir ağları, destek vektör makinaları, aşırı öğrenme makine yöntemlerinde eğitim, test ve doğrulama aşamalarında kullanılmıştır.


2. YGDA İLE ENERJİ İLETİMİ

YGDA sistemler yüksek gerilim seviyelerinin uzak mesafelere taşınmasında, farklı şebeke frekanslarına sahip iletim hatlarının bağlantısında veya deniz üstüne kurulmuş platformların kara ile bağlantılarının yapılmasında kullanılmaktadır. 1950'lerden itibaren hayatımıza giren bu sistemler günümüzde elektrik enerjisinin uzak mesafelere iletilmesinde başa baş mesafeler göz önünde bulundurulduğunda en ekonomik tercih olarak karşımıza çıkmaktadır. YGDA sistemler başa baş mesafe dikkate alındığında yer altı kabloları için 70 km üzeri ve havai hatlarda ise 600-800 km üzerinde AA sistemlere göre daha ekonomiktir [14]. YGDA sistemlerin iletim hatları farklı bağlantı şekillerine sahiptir. Bu farklı bağlantı şekilleri sırasıyla; tek kutuplu, çift kutuplu, eş kutuplu ve çok terminalli bağlantı olarak isimlendirilmektedir. Dönüş hattı metalik veya toprak dönüşlü olabilmektedir [14-16-17]. Çift kutuplu ve eş kutuplu bağlantı şeklinde dönüş yolu tek bir hat üzerinden veya birbirinden ayrı hatlar üzerinden yapılabilir. Şekil 2.1' de tek kutuplu, çift kutuplu, eş kutuplu ve çok terminalli hat bağlantı şekilleri gösterilmiştir.




Şekil 2.1 YGDA sistemlerde farklı bağlantı şekilleri (a) tek kutuplu toprak dönüşlü (b) tek kutuplu metalik dönüşlü (c) eş kutuplu gösterim (d) çift kutuplu gösterim

YGDA sistemlerde bulunan farklı bağlantı şekilleri sayesinde yenilenebilir enerji santrallerinin şebekeyle bağlantıları ve enterkonnekte bağlantılar yapmak mümkün olmaktadır. Şekil 2.2’ de ard-arda ve çok terminalli bağlantı yöntemleri gösterilmiştir.




2.1. GKD-YGDA İstasyon Temel Elemanları

10



Şekil 2.4 DA kesici bulunduran bir GKD dönüştürücü devresi [14].

GKD-YGDA sistemlerde AA filtreler, akım kaynaklı dönüştürücü kullanan YGDA sistemlere göre daha düşük kullanım oranına sahiptirler [15]. Alçak geçiren LC filtre kullanılarak yüksek frekanslı harmonik bileşenlerin yok edilmesi ve temel frekans bileşenleri ile etkileşimi önlenmektedir. Modüler çok seviyeli dönüştürücülerde ise AA filtreler ihtiyacı duyulmamaktadır [14-15]. Şekil 2.5’ te YGDA sistemlerde kullanılan aktif filtrenin ana devresi gösterilmiştir.




Şekil 2.5 YGDA sistemlerde kullanılan bir aktif filtrenin ana devresi

DA kapasitör blokları, GKD sistemlerin enerji depolayan birimleridir. Anlık açılıp kapanan anahtarlama elemanları sayesinde kare dalga üretilmektedir. DA kapasitörler aynı


DA filtrelerde aynı DA kapasitörler gibi DA iletim hattında meydana gelmesi muhtemel harmonikler için kullanılmaktadır. DA kapasitörler ile paralel bağlanarak DA eşdeğer devrenin toplam empedansını azaltmaktadır. Bazı GKD-YGDA sistemlerde özel olarak DA taraftaki harmonik rezonansların engellenmesi için yüksek frekanslı DA filtreler kullanılabilmektedir [14-16]. Aynı zamanda DA kapasitör boyutlarının azalmasına da yardımcı olmaktadır.

Modüler çok seviyeli anahtar bloklarında ise hücreler genel olarak iki gruba ayrılmaktadırlar. Bunlardan birincisi; kümelenmiş ve bir blok içerisine sıkıştırılmış şekilde

duran sıkışık, kelepçeli ve birbirinin aynısı tristörlerden oluşan bir yapıdır. Bu anahtar bloklarında aynı zamanda büyük arıza akımlarına müsaade edebilen anti paralel diyotlar bulunmaktadır. Tüm iki seviyeli gerilim kaynaklı dönüştürücü anahtarlarda bu dizayn kullanılmaktadır [15]. İkinci yöntem ise; standart ve ticari olarak kullanılan IGBT' lerin kullanıldığı şekildedir. Her bir anahtarlama elemanının üstünde diyotlarla paralel olacak şekilde dış tarafına bir tristör eklenmesiyle oluşturulmaktadır. Bu şekilde birleştirilmeleri ise DA arıza esnasında arıza akımı için yarı iletim ortamı oluşturmaktadır. Şekil 2.7' de YGDA sistemlerde kullanılan iki seviyeli ve üç seviyeli gerilim kaynaklı dönüştürücü topolojileri verilmiştir.



(a) İki Seviyeli GKD



(b) Üç Seviyeli GKD

Şekil 2.7 Farklı gerilim kaynaklı dönüştürücü topolojileri (a) iki seviyeli GKD (b) üç seviyeli GKD

AA reaktörler genellikle dönüştürücü tarafında dönüştürücü-transformatör ile seri olacak şekilde bağlanmaktadır. AA reaktörlerin temel amacı iki grupta toplanabilmektedir. Bunlardan birincisi; DA arıza akımını azaltarak diyotlardaki akım seviyesinin aşırı yükselmesini engellemektir. Bunun alternatifi olarak diyotların oranlarının artırılması ise maliyet, boyut ve kapladığı alanın artmasına neden olmaktadır. İkinci olarak ise; AA arıza durumunda anahtarlama akımının tepe noktasını azaltmasıdır [15]. AA arızalar dönüştürücü kontrol birimleri tarafından yönetilir ve kontrol gecikmeleri gibi durumlar göz önünde bulundurularak IGBT'lerin çalışma oranları içerisinde geçici arızaların tepe değerlerini engelleyebilmek için en düşük AA reaktans bu şekilde sağlanır.


DA reaktörler, GKD-YGDA sistemlerde DA kapasitörlerden sonra bağlanmaktadır. Genel olarak; serbest dolaşım diyotları ve kapasitörleri korumak için DA arıza akımını azaltarak DA havai hatlarda ve kablolarda harmonik akım düşümü ve DA devrede kritik rezonans frekansını değiştirme gibi farklı görevleri yerine getirebilmektedir.

2.2. YGDA İletim Hatları

YGDA sistemlerde iletim hattının türüne ve bağlantı şekline karar verme aşamasında bazı parametreler göz önünde bulundurulmaktadır. Bunlar genel olarak; maliyet, coğrafi koşullar, frekans farklılıkları, ihtiyaç duyulan enerji miktarı, mesafe v.s. gibi faktörlerdir.

YGDA iletim hatları AA iletim hatlarıyla karşılaştırıldığında daha düşük iletim hattı sayısı, direk boyutları ve ekipmanlara sahiptir. Diğer taraftan daha pahalı istasyon ekipmanlarına, koruma sistemlerine ve çok terminalli istasyon bağlantılarında ise daha karmaşık işletme koşullarına sahiptir.


Baş baş mesafe göz önünde bulundurulduğunda yer altı kabloları için 40 km, havai iletim hatları düşünüldüğünde ise 400 km üzerinde YGDA iletim hatları daha verimli bir yöntemdir [16]. Şekil 2.8' de YGDA ve Yüksek Gerilim Alternatif Akım (YGAA) sistemlerin hat uzunluğu-maliyet karşılaştırılması verilmiştir.



Şekil 2.8 YGDA ve YGAA sistemleri hat uzunluğu-maliyet karşılaştırması

YGDA sistemlerin güç devrelerinde aşırı gerilim koruma ve temel izolasyon işlemleri için toprak elektrotu bulunmaktadır. Çift kutuplu YGDA sistemlerde bu elektrot dönüştürücü-transformatörün iletim hattı tarafındaki yıldız bağlantıyla birleştirilmiş şekilde toprak dönüşlü olabilmektedir. Fakat YGDA sistemin her iki kutbunun doğru akım seviyesi birbirine eşit olamayacağından dolayı, akım dengeleme kontrolüne rağmen istasyonun nötr noktasından toprağa sürekli bir diferansiyel bir akım akmaktadır.

Tek kutuplu sistemlerde ise toprak elektrotunun iletim hattıyla beraber taşınması gerekmektedir. Toprak elektrotun tüm sistemin akım seviyesini taşıyacak bir şekilde tasarlanmaktadır. Böylelikle herhangi bir kutupta aksaklık oluşması durumunda toprak elektrotu vasıtasıyla iletilecek gücün yaklaşık yarısı oranında bir enerji iletimi yapılabilmektedir. Bu işlem ise çift kutuplu uygulamaların kullanılmasına büyük bir avantaj sağlamaktadır. Şekil 2.9’ da elektrot hattı bulunan çift kutuplu YGDA iletim hattı gösterilmiştir.



Şekil 2.9 Elektrot hattı bulunan havai YGDA iletim hattı (a) çift kutuplu YGDA iletim hattı (b) koruma iletkeni olarak kullanılan elektrot hat [15].

YGDA kablo iletim hatlarının yapısı YGAA sistemlerdeki tek çekirdek bulunduran kablo yapısına teorik olarak benzemektedir. Yeraltı ve deniz altı bağlantılarda kullanılan bu gibi kablo sistemlerin nem ve aşındırıcı dış etkenlere karşı dayanıklı birden fazla tabakadan oluşan farklı tasarımları bulunmaktadır. YGDA kablo çeşitleri genel olarak 4 gruba ayrılmaktadır. Bunlar; selüloz bazlı kütle emdirilmiş kablo, gaz izolasyonlu iç basınçlı kablo, petrol bazlı ve ekstürde polietilen kablolardır [18]. Şekil 2.10' da denizaltı YGDA iletim hatlarında kullanılan farklı kablo çeşitleri verilmiştir.



Şekil 2.10 Denizaltı YGDA iletim hatlarında kullanılan farklı kablo çeşitleri (a) selüloz bazlı kütle emdirilmiş kablo (b) petrol bazlı kablo (c) gaz izolasyonlu iç basınçlı kablo (d) ekstürde polietilen kablo [18].

Selüloz bazlı kablolar YGDA sistemlerde en sık kullanılan kablo çeşitlerinden bir tanesidir. Bu kablolarda genellikle viskoz bileşenlerden oluşan çok katmanlı izolasyon içeren bir yapı kullanılmaktadır. Deniz altında 500 m'ye kadar sorunsuz bir şekilde kullanılabilir [16-18].

Selüloz bazlı kütle emdirilmiş kablolarda, sıcaklık değişimlerinden kaynaklanan dielektrik alanda kavitasyonlar oluşabilmektedir. Bu kavitasyonlar yük boşalmalarına ve bunun sonucunda ise kabloda deformasyonlara neden olabilmektedir. Bu tarz problemler ise gaz izolasyonlu iç basınçlı kabloların kullanılmasıyla birlikte büyük oranda çözülebilmektedir. Özellikle belirli bir basınç değerinde tutulan nitrojen gazlı kablolar tercih edilmektedir.

Selüloz bazlı kabloların kalitesi düşük viskoziteye sahip petrol bazlı bileşenlerin kullanılmasıyla beraber artırılabilir. Belirli bir gerilim değeri altında en düşük kalınlığa sahip izolasyon işlemi en verimli yöntem olarak kabul edilebilir. Petrol bazlı kablolar belirli bir izolasyon kalınlığı içerisinde ± 600 kV' a kadar çıkan gerilim seviyesini iletebilir [18].

Ekstürüde polietilen kablolar YGAA sistemlerin özellikle yer altı kablo uygulamalarında ve güç iletimi ve dağıtımı gibi işlemlerinde başarılı olarak uygulanmaktadır. Ekstürüde kablolar düşük orandaki malzeme ve işletme maliyeti, güvenilirlik, elektriksel ve mekaniksel konularda avantajlara sahip olduğundan dolayı tercih edilmektedir. Günümüzde en yaygın kullanılan YGDA kablolar selüloz ve petrol bazlı kablolar olmasına karşılık artan YGDA proje sayıları ve üreticilerin maliyetleri düşürecek yeni konseptler arayışı sayesinde ekstürüde polietilen kabloların kullanımı artmaya başlamıştır [18].

2.3. YGDA Koruma Sistemleri

YGDA sistemlerde havai iletim hatları ve yer altı kabloları dışında istasyonlar arasındaki iletişimi sağlayan, arızayı konumlandırma ve tespit aşamasına yardımcı olan iletişim hatları bulunmaktadır. Bu iletişim hatları sayesinde genellikle ard-arda bağlantıların yapıldığı YGDA istasyonlarının kontrol sistemleri bilgilendirilmektedir.

YGDA istasyonlarının kontrol odalarındaki mikro işlemcili bilgisayarlar anahtar bloklarından gelen bilgilerin değerlendirilmesi aşamasında kullanılmaktadır. Arızalı tristörlerin belirlenmesi ve yerinin kesin olarak tahmin edilebilmesi bu şekilde mümkün olmaktadır. Her bir anahtar bloğunda fazladan bulunan tristörler dönüştürücü istasyonunda arıza olması durumunda sistemin devam etmesini sağlamaktadırlar.

Koruma sistemleri temel olarak sistemde herhangi bir nedenden dolayı arıza meydana gelmesi durumunda istasyon ekipmanlarının zarar görmesini engelleyerek, arıza süresi ve şiddetini göz önünde bulundurarak arızalı kısmı izole edecek şekilde tasarlanmaktadır. Koruma sistemleri aynı zamanda arızanın konumu, şiddeti ve süresi hakkında yorum yapabilmeye imkan sağlayacak kullanışlı sinyal verilerini toplamaktadır.

YGDA koruma sistemleri genel olarak iki gruba ayrılmaktadır. Bunlardan birincisi ana koruma, ikincisi ise arka plan korumadır. YGDA sistemler ana koruma algoritması olarak yürüyen dalga korumasını kullanırken, arka plan koruma olarak ise genellikle diferansiyel koruma, türetilmiş koruma, aşırı akım ve düşük gerilim koruma gibi farklı algoritmalar kullanmaktadır. Bu yöntemler arka plan korumada düşük seviyeli bir koruma sağlamasına karşın ana koruma elemanlarının arızalanması durumunda sistem elemanlarının hasar görmesini engellemektedir [15-20].

YGDA istasyonun AA kısımda bulunan cihazların korumaları dönüştürücü-transformatörler bölümü için geleneksel transformatör koruma yöntemleri ve AA filtreler ve şönt kapasitörler için özel olarak tasarlanmış filtre ve kapasitör blokları ile sağlanmaktadır. Tablo 2.1.'de AA kısım koruma algoritmaları ve kullanım amaçlarından bahsedilmiştir.

Tablo 2.1 AA kısım koruma algoritmaları ve kullanım amacı

Koruma algoritması	Kullanım Amacı
Transformatör Diferansiyel Koruma	Transformatör içerisinde meydana gelebilecek arızaları engellenmesi
AA Aşırı Akım Koruma	Transformatör diferansiyel koruma ile yedek koruma sistemi
AA Filtre Aşırı Yük Koruma	Aşırı yük akımlarının temel ve harmonik bileşenlerinin tespit edilmesi
AA Filtre ve Şönt Kapasitör Koruma	Arızalı kapasitör ünitelerinin tespit edilmesi

Tablo 2.2.'de YGDA sistemlerin DA koruma algoritmaları ve kullanım amacı verilmiştir.

Tablo 2.2 DA kısım koruma algoritmaları ve kullanım amacı

Koruma Algoritması	Kullanım Amacı
DA Aşırı Akım Koruma	Anahtar bloklarındaki aşırı yüklenmelerin tespit edilmesi ve kısa devre koruma yanında yedek koruma olarak çalışma
DA Harmonik Koruma	Komutasyon arıza koruma yanında yedek koruma
DA Toprak Arıza Koruma	Dönüştürücü istasyonunun doğru akım kısmındaki toprak arızaların tespiti
DA Aşırı Gerilim Koruma	Doğru akım iletim hattındaki aşırı gerilim seviyelerinin tespiti
DA Düşük Gerilim Koruma	Kalıcı gerilim çöküşlerin tespiti
DA Hat Koruma	Doğru akım iletim hattı üzerinde meydana gelen toprak arızaların tespiti

2.4. YGDA Sistemlerin Avantajları ve Dezavantajları

Klasik YGDA sistemler genellikle uzak mesafelere yüksek güç seviyelerini iletebilmek gibi görevlerde kullanılırlar. Bunun başlıca nedeni ise AA sistemlere kıyaslandığında uzak mesafelerde daha düşük kayıplara sahip olması ve iletim hattı koridoru üzerinde kullanılan ekipmanların azalmasıdır. DA ile iletimin tercih edilmesindeki bir başka neden ise iletim mesafesinin uzunluğunun transfer edilen güç seviyesine veya kararlılık limitine olumsuz yönde bir etkisinin olmamasıdır. YGDA sistemlerin tercih edilmesindeki bazı nedenler aşağıdaki maddelerde açıklanmıştır [14-16]:


- Uzak mesafelere yüksek güç seviyelerinin daha az kayıpla taşınabilmesi
- Daha düşük iletim hattı koridoru ve ekipmanları
- Farklı şebeke frekansına sahip sistemlerin bağlantısının yapılması
- Deniz üstü platformların kara ile bağlantılarının yapılabilmesi
- Daha düşük korona ve yüzey kayıpları
- DA iletim hattı boyunca reaktif güç ihtiyacının olmaması
- Çok terminalli bağlantıların her iki yönlü enerji ticaretine imkan sağlayabilmesi

- Birbirlerinden uzakta bulunan yenilenebilir enerji santrallerinin bağlantılarının yapılabilmesi
- Çevreyi olumsuz etkileyecek faktörlerin (görsel etki, iletim hattı koridoru genişliği, gürültü seviyesi, manyetik alan etkisi ve emisyon v.s.) AA sistemlere kıyasla daha az olması.

Yukarıda bahsedilen faydalara rağmen AA sistemlere göre daha pahalı istasyon ekipmanlarına sahip olması YGDA sistemlerin en büyük dezavantajları olarak değerlendirilmektedir. Özellikle kalıcı arıza durumlarında güç iletim kapasitesinin yarı değerlerine kadar düşmesi, çok terminalli yapılarda anahtarlama elemanlarının arızayı beslemesi, YGDA istasyonlarında bulunan ekipmanların AA alternatiflerine göre daha düşük performanslara sahip olması dezavantajları olarak görülebilir [15]. Aşağıda YGDA sistemlerin öne çıkan bazı dezavantajlarından bahsedilmiştir:

- Doğrultucu-dönüştürücü istasyonlarının reaktif güç ihtiyacı
- Pahalı anahtarlama ve istasyon ekipmanları
- Arıza tespit ve konumlandırma algoritmalarının gelişmekte olması
- Çok terminalli istasyonları işletme zorluğu
- İletilen gerilim ve güç seviyelerini değiştirebilmekte karşılaşılan zorluklar
- YGDA sistemlerin istasyon ekipmanlarının iletim hattı ve koridorlarına göre daha pahalı olması.

Bir enerji iletim tesisinin maliyeti genel olarak; anapara yatırımı, işletme sırasında oluşan masraflar, istasyon ve enerji iletim hattı ve koruma sistemleridir. YGDA sistemlerin maliyet analizi hakkında detaylı bilgilere [15-21] numaralı referanslardan ulaşılabilir. Şekil 2.11’ de AA ve DA iletim hatlarının mesafe-maliyet karşılaştırması verilmiştir.



Şekil 2.11 AA ve DA iletim hatlarının mesafe-maliyet karşılaştırması [15].

Şekil 2.11’ da görüldüğü üzere aynı miktarda enerji iletimi yapılması durumunda YGDA sistemler daha düşük kayıplara sahiptir. Aynı şekilde 450 km’den daha düşük mesafelerde YGAA sistemler daha çok tercih edilmektedir.


3. AKIM VE GERİLİM DALGA ŞEKİLLERİNDEN ÖZELLİK ÇIKARIMI

Sinyal işleme yöntemleri, YGDA sistemlerde arıza akım ve gerilim sinyallerinin işlenmesi ve özellik çıkarımı aşamasında kullanılmaktadır. Günümüzde Fourier Dönüşümünden yola çıkılarak oluşturulmuş matematiksel tanımlamalar arıza konumlandırma algoritmalarının temelini oluşturmaktadır.

Bu çalışmadaki arıza sinyallerinin bileşenlerine ayrılması aşamasında yaygın olarak kullanılan dalgacık dönüşümünün dışında Hilbert-Huang dönüşümü ve Stockwell dönüşümü (S-dönüşümü) yöntemleri kullanılmıştır. Bu birbirinden farklı yaklaşımların özellik çıkarımı aşamalarına, matematiksel gösterimlerine, birbirleri arasındaki üstünlüklere ve dezavantajlarına yer verilmiştir

3.1. Dalgacık Dönüşümü


Fourier dönüşümü herhangi bir sinyalin içerdiği frekansları gösterirken, hangi zaman aralığında hangi frekansların olduğunu gösteremez. Fourier dönüşümü frekansı zamana göre değişmeyen sinyallerin analizinde oldukça iyi bir yaklaşımdır. Fakat geçici durum analizlerinde istenilen sonuçları verememektedir [22-23]. Şekil 3.1’ de Fourier dönüşümü ve dalgacık dönüşümü arasındaki ilişki gösterilmiştir.



Şekil 3.1 Fourier dönüşümü ve dalgacık dönüşümü arasındaki ilişki (a) zaman-büyüklik (b) Fourier dönüşümü (c) Kısa zamanlı Fourier dönüşümü (d) dalgacık dönüşümü

Dalgacık dönüşümü durağan olmayan sinyallerin analizinde oldukça etkilidir. Zaman-frekans bölgesinde sinyallerin çözünürlüğü optimum olarak elde edilebilmektedir. Dalgacık dönüşümü veya dalgacık analizi Fourier dönüşümünün genelleştirilmiş hali olarak düşünülebilir. Dalgacık dönüşümünde, sinyal süresince ötelenebilen, sinyalin genliğine ve büyüklüğüne göre ölçeklenebilen ve belirli fonksiyon kalıpları ile ifade edilebilen en uygun ayrıştırma işlemi gerçekleştirilebilmektedir [2-23-25]. Dalgacık dönüşümünün bazı kullanım alanları; zaman-frekans analizleri, filtreleme, geçici durum analizleri, sinyal ve görüntü işleme v.s. gibi konulardır.

Sinyal analizi aşamasında kullanılan birden çok dalgacık ailesi bulunmaktadır. Bunlardan bazıları; Daubechies, Gabor-Malvar, Grossman-Morlet, Mexikan Hat, Quadratic, Polynom-Spline, Chirps v.s. gibi dalgacık fonksiyonlarıdır. Şekil 3.2’ de yaygın olarak kullanılan bazı dalgacıklar gösterilmiştir.



Şekil 3.2 Dalgacık dönüşümünde kullanılan farklı dalgacık çeşitleri (a) Haar dalgacık (b) Meyer dalgacık (c) Gauss dalgacığı (d) Morlet dalgacık [26].

Fourier dönüşümünde eşit zaman aralıklarında işlem yapılırken dalgacık dönüşümünde düşük frekanslı bileşenler için geniş zaman aralığı, yüksek frekanslı bileşenlerde ise dar zaman aralığı kullanılmaktadır. Böylelikle zaman-frekans diyagramından faydalanılarak yüksek ve alçak geçişli bileşenlerin tespiti ile filtreleme işlemi gerçekleştirilebilmektedir [26].

Kısa Zamanlı Fourier Dönüşümü (KZFD)'nde sabit bir pencere fonksiyonu bulunurken, dalgacık analizinde tanımlanan bir dalgacık fonksiyonu $\psi(x)$ kullanılmaktadır [26-27]. Sinyal analizi aşamasında farklı ölçeklendirme boyutları ve zaman bölgesinde kaydırma (öteleme) gibi farklı işlemlerden faydalanılmaktadır. Aşağıdaki maddelerde dalgacıkların bazı temel özelliklerinden bahsedilmiştir:

- ψ' nin integrali sıfırdır.

$$\int_{-\infty}^{+\infty} \psi(x) dx = 0 \quad (3.1)$$

- ψ' nin karesinin integrali 1'e eşittir.

$$\int_{-\infty}^{+\infty} \psi^2(x) dx = 1 \quad (3.2)$$

Yukarıdaki eşitlikleri sağlayan her $\psi(x)$ fonksiyonu dalgacık olarak tanımlanmaktadır. Dalgacık dönüşümünde yapılan bir diğer genelleme ise sürecin sürekli veya ayrık olması durumudur. Bu şekilde öteleme ve ölçeklendirme yapılan ana dalgacık fonksiyonunun ayrık veya sürekli olarak örneklenmesi sağlanabilmektedir. Ayrıca dalgacık dönüşümü yönteminde zaman-frekans bölgesi yerine zaman-ölçeklendirme gösteriminden faydalanılmaktadır.

3.1.1. Sürekli Dalgacık Dönüşümü (SDD)

Klasik Fourier dönüşümü sinyalin bileşenlerine ayrıştırılması aşamasında tüm sistemi sinüslerin ve kosinüslerin toplamı olarak ifade etmektedir. Buna benzer şekilde SDD yöntemi ise belirli ölçeklendirme ve öteleme parametrelerinin toplamı olarak ifade etmektedir [27]. SDD' nin matematiksel gösterimi denklem 3.3' de gösterilmiştir.

$$SDD(s, \tau) = \int_{-\infty}^{+\infty} f(t) \psi_{s,\tau}^*(t) dt \quad (3.3)$$

Yukarıdaki denklemdeki; $\psi_{s,\tau}^*(t)$ ana dalgacık, τ öteleme faktörü, s ölçeklendirme katsayısı, $f(t)$ ise dalgacık dönüşümü yapılan sinyali temsil etmektedir. Sürekli dalgacık

dönüşümü, $f(t)$ sinyali ile $\psi_{s,\tau}^*(t)$ ' nin çarpımı olarak tanımlanmaktadır. Ana dalgacık fonksiyonu ise denklem 3.4' de gösterilmiştir.

$$\psi_{s,\tau} = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (3.4)$$

Bu denklemdeki $\left(\frac{1}{\sqrt{s}}\right)$ faktörü farklı ölçeklere sahip enerji normalizasyon faktörüdür. SDD' nin en genel denklemi ise denklem 3.5' te verilmiştir.

$$SDD(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (3.5)$$

Sürekli dalgacık dönüşümü yönteminde detay ve yaklaşık katsayıların elde edilmesi aşamasında örnekleme sayısı sabit tutulurken, ayrık dalgacık dönüşümü yönteminde her seferinde örnekleme sayısı yarıya düşer. Bu sayede her bir seviyedeki detay ve yaklaşık katsayılar daha az işlem yüküyle halledilmiş olur [27-29]

SDD' nin uygulanma aşamasında karşılaşılan bazı zorluklar bulunmaktadır. Bunlardan bazıları, hesaplama işlemlerinin fazla olması ve analitik çözümünün olmamasıdır. SDD yönteminde meydana gelen bu tarz problemlerinin üstesinden gelebilmek için ADD yöntemi kullanılmaktadır [29].

3.1.2. Ayrık Dalgacık Dönüşümü (ADD)

ADD yönteminde öteleme ve ölçeklendirme işlemleri ayrık adımlar uygulanarak yapılmaktadır. Bu işlem ise mesafeye bağlı olarak ayrık nümerik değerler çevresinde ötelenir veya ölçeklendirilir. Genlik değişimi matematiksel olarak $\psi(2^k t + l)$ şeklinde gösterilmektedir. Burada; l öteleme faktörü, k ise ölçeklendirme faktörü olarak düşünülebilir. Ayrık dalgacık dönüşümünde kullanılan ana dalgacık fonksiyonu denklem 3.6' da verilmiştir.

$$\psi_{j,k}(t) = \frac{1}{\sqrt{s_0^j}} \psi\left(\frac{t - k\tau_0 s_0^j}{s_0^j}\right) \quad (3.6)$$

Buradaki j ve k birer tamsayı, $s_0 > 0$ olacak şekilde genleşme katsayısı, τ_0 ise genleşme katsayısına bağlı olan öteleme faktörüdür. Ayırık dalgacık dönüşümünde bahsedilmesi gereken bir diğer parametre ise ölçekleme fonksiyonudur. Bu fonksiyon ise detay ve yaklaşık katsayıların belirlenmesi aşamasında yardımcı olmaktadır. Ölçekleme ne kadar küçük olursa detay katsayıları o kadar fazla olur. Ölçekleme fonksiyonu denklem 3.7' de verilmiştir.

$$\varphi(t) = \sum_{j,k} \gamma(j,k) \psi_{j,k}(t) \quad (3.7)$$

Ölçekleme fonksiyonu ile dalgacık fonksiyonun çarpımı sonucunda bir önceki fonksiyonu da kapsayan yeni bir ölçek fonksiyonu elde edilir. Bu işlem çoklu çözünürlük formülasyonu olarak adlandırılmaktadır. Çoklu çözünürlük formülasyonu herhangi bir seviyedeki ölçekleme fonksiyonunun bir alt kümesinde yer alan ölçekleme fonksiyonuyla ilişkili olduğu anlamına gelmektedir [27]. Çoklu çözünürlük formülasyonu denklem 3.8' de verilmiştir.

$$\varphi(2^j t) = \sum_k h_{j+1}(k) \varphi(2^{j+1} t - k) \quad (3.8)$$

Denklem 3.7' de bahsedilen ölçekleme fonksiyonu yerine herhangi bir dalgacık seti yerleştirilirse, ölçeklendirme ve öteleme işlemlerine bağlı olarak denklem 3.9' da gösterildiği şekilde ifade edilebilir.

$$\psi(2^j t) = \sum_k g_{j+1}(k) \varphi(2^{j+1} t - k) \quad (3.9)$$

Analizi yapılan $f(t)$ sinyalinin $j - 1$ ölçeğine kadar genişletilen ve ötelenen bir dalgacık ailesine bağlı olarak ifade edilebileceği için, denklem 3.10' da gösterildiği şekilde genişletilebilir.

$$f(t) = \sum_k \lambda_j(k) \varphi(2^j t - k) \quad (3.10)$$


Bu denklemde yalnızca ölçekleme fonksiyonunun ayırık şekilde ötelenmesinden ve genleşmesinden bahsedilebilir. Bu denkleme bir dalgacık fonksiyonu eklenir ve $j - 1$ ölçeği ile ifade edilirse denklem genel olarak 3.11' de gösterildiği şekilde yazılır.

$$f(t) = \sum_k \lambda_{j-1}(k) \varphi(2^{j-1}t - k) + \sum_k \gamma_{j-1} \psi(2^{j-1}t - k) \quad (3.11)$$

Ölçekleme fonksiyonu $\varphi_{j,k}(t)$, dalgacıklar $\psi_{j,k}(t)$ ve ortonormal ise $\lambda_{j-1}(k)$ ve $\gamma_{j-1}(k)$ katsayılarını ifade etmektedir. Herhangi bir ölçekteki ölçekleme fonksiyonu katsayısı (λ) ve dalgacık fonksiyonu katsayıları (γ) bir önceki ölçekteki katsayıların ağırlıklı toplamıdır [29-30]. Denklem 3.12' de ortonormal katsayıların matematiksel gösterimi verilmiştir.

$$\begin{aligned} \lambda_{j-1}(k) &= \sum_k h(m - 2k) \lambda_j(m) \\ \gamma_{j-1}(k) &= \sum_k g(m - 2k) \gamma_j(m) \end{aligned} \quad (3.12)$$

Yukarıdaki denklemde $\lambda_j(k)$ katsayıları ayrıştırılmış sinyal spektrumunun alçak geçiş bandını temsil ettiği için $h(k)$ düşük geçişli filtre görevi görmektedir. Denklemde bahsedilen diğer dalgacık fonksiyonu katsayısı $\gamma_j(k)$ ayrıştırılmış sinyal spektrumunun yüksek geçiş bandını temsil ettiği için $g(k)$ yüksek geçişli filtre görevi görmektedir. Şekil 3.3' de ADD yönteminin işlem basamakları gösterilmiştir.



Şekil 3.3 ADD yöntemi işlem basamakları

Sonuç olarak ayırık dalgacık dönüşü yapılan sinyallerin analizinde $\lambda_j(k)$ yaklaşık katsayıları, $\gamma_j(k)$ ise detay katsayılarını temsil etmektedir. $h(k)$ ölçekleme fonksiyonunu $g(k)$ dalgacık fonksiyonunu içermektedir.

3.1.3. Dalgacık Entropisi

Dalgacık entropisi, dalgacık teoremi ve entropi teoreminin birleşimi olan ve sinyallerin farklı seviyelerdeki frekans bileşenlerinin dağılımını gösteren bir ifadedir. Entropi, sistem durumu ile ilişkilidir. Dalgacık entropisi ise hem entropi hem de kontrol kararlarıyla ilişkilidir. Dalgacık entropi teorisi ve uygulamaları arıza tespiti aşamasında ve sistem durumu tanımlama gibi farklı aşamalarda kullanılabilmektedir [30].

Ayrık dalgacık dönüşümü yapılan sinyal $x(n)$, yüksek geçişli filtrelerden elde edilen detay katsayıları $d_j(k)$, alçak geçişli filtrelerden elde edilen yaklaşık katsayılar $a_j(k)$ olarak tanımlandığında k anındaki ve j ölçeğindeki frekans bandının bilgilerini içeren bileşenler $D_j(k)$ ve $A_j(k)$ olarak tanımlanmaktadır [30-32]. $D_j(k)$ ve $A_j(k)$ sinyal bileşenlerinin matematiksel gösterimi denklem 3.12' de gösterilmiştir.

$$\begin{aligned} D_j(k) &: [2^{-(j+1)}F_s, 2^{-j}F_s] \\ A_j(k) &: [0, 2^{-(j+1)}F_s] \end{aligned} \quad (j = 1, 2, 3, \dots, m) \quad (3.12)$$

Yukarıdaki denklemde f_s örnekleme frekansıdır. Orijinal sinyal dizisi $x(n)$, tüm bileşenlerin toplamı olarak düşünülebilir ve denklem 3.13' de gösterildiği şekilde yazılabilir.

$$\begin{aligned} x(n) &= D_1(n) + A_1(n) = D_1(n) + D_2(n) + A_2(n) \\ &= \sum_{j=1}^J D_j(n) + A_j(n) \end{aligned} \quad (3.13)$$

Denklem 3.13' deki $D_j(n)$, $x(n)$ sinyalinin her bir ölçekteki (frekans bandındaki) bileşenlerini temsil etmektedir. Bu ifade aynı zamanda alt küme gruplandırması olarak da ifade edilebilen sinyalin çoklu çözünürlük gösterimidir. Yaygın olarak kullanılan birçok entropi hesaplama yöntemi bulunmaktadır. Bunlardan bazıları; Shannon, Eşik, Norm, Logaritmik Enerji ve Sure kriterleridir [31-33]. Analizi yapılan dalgacık entropilerin genel olarak j ölçeğindeki dalgacık spektrumları (E_j) ve dalgacık enerji spektrumları (E_{jk}) denklem 3.14' de gösterilmiştir.

$$\begin{aligned} E_{jk} &= \|D_j(k)\|^2 \\ E_j &= \sum_k E_{jk} \end{aligned} \quad (3.14)$$

$x(n)$ sinyalinin m ölçeğindeki dalgacık spektrumları ($E = E_1, E_2, E_3, \dots, E_j$) şeklinde gösterilebilir. Buradaki E , sinyalin enerjisinin ölçek bölgesindeki bölümünü ifade eder. Ortonormal dalgacık dönüşümü kullanılarak, toplam sinyal enerjisi E , j ölçeğindeki her bir bileşenin enerjilerinin toplamı E_j ve ($p_j = E_j/E$ ve $\sum_j p_j = 1$) olarak kabul edildiğinde Dalgacık Enerji Entropi (DEE) değerinin matematiksel ifadesi denklem 3.15' te gösterilmiştir.

$$DEE = - \sum_j p_j \log p_j \quad (3.15)$$

3.2. Stockwell Dönüşümü

Stockwell dönüşümü, sürekli dalgacık dönüşümünün üstesinden gelemediği bazı problemleri aşmak üzere geliştirilmiş bir yöntemdir. İlk olarak (Stockwell, vd, 1996)' da öne sürülmüş ve jeofizik alanı başta olmak üzere birçok bilim dalında veri analizi aşamasında kullanılmaktadır [33]. Stockwell Dönüşümü (SD) ötelenebilen ve ölçeklenebilen Gauss pencerelerinden oluşan, Fourier spektrumuyla doğrudan ilişkili zaman-frekans tabanlı bir gösterime sahip sinyal analiz yöntemidir. Sinyaller, S-dönüşümünde sinüs ve kosinüs dalgalarını zaman ekseninde modüle etmek yerine, ölçeklenebilir Gauss pencereleriyle genişletilebilir veya dönüştürülebilir [34-35].

S-dönüşümü, SDD' nin faz doğrultma işleminden türetilmiş olarak düşünülebilir. SDD uygulanan herhangi bir $h(t)$ fonksiyonunun dalgacığı $W(\tau, d)$ olarak tanımlandığında bu dalgacığın matematiksel formülü denklem 3.16' da gösterildiği şekliyle yazılabilir.

$$W(\tau, d) = \int_{-\infty}^{+\infty} h(t) w(t - \tau, d) dt \quad (3.16)$$

Burada $w(t, d)$ ana dalgacığın farklı ölçeklerdeki değeri, d : $w(t, d)$ 'nin genişleme parametresi, τ spektral konumlandırıcıdır. $h(t)$ fonksiyonun SD' si, SDD analizindeki spesifik bir ana dalgacık ile faz değerinin çarpımı sonucu elde edilir. Bu tanımın matematiksel gösterimi Denklem 3.17' de verilmiştir.

$$S(\tau, d) = e^{i2\pi f\tau} W(\tau, d) \quad (3.17)$$

Yukarıdaki denklemde tanımlanan ana dalgacık denklem 3.18' te gösterilmiştir.

$$w(t, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{t^2 f^2}{2}} e^{-i2\pi ft} \quad (3.18)$$

S-dönüşümündeki ana dalgacığın sıfır ortalama değere sahip olması gerekmektedir. Bu şekilde SDD' den elde edilen dalgacıklara en yakın değerlere sahip dalgacıklar elde edilebilmektedir. S-dönüşümünün en genel ifadesi denklem 3.19' da gösterilmiştir [33].

$$S(\tau, f) = \int_{-\infty}^{+\infty} h(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2 f^2}{2}} e^{-i2\pi ft} dt \quad (3.19)$$

S-dönüşümünde, bölgesel spektrum gösterimi yerine Fourier dönüşümünden elde edilen zamana göre ortalama değere sahip spektrum gösterimi de elde edilebilmektedir [35]. Bu işlemler ise denklem 3.20 ve denklem 3.21' de gösterilmiştir.

$$\int_{-\infty}^{+\infty} S(\tau, f) d\tau = H(f) \quad (3.20)$$

Yukarıdaki denklemde $H(f)$, $h(t)$ fonksiyonunun Fourier dönüşümünü temsil etmektedir. $h(t)$ fonksiyonu, $S(\tau, f)$ ' nin iki kez integralinin alınmasıyla tekrardan elde edilebilir ve bu özelliğiyle SDD analizinden farklılık göstermektedir. $h(t)$ fonksiyonu denklem 3.21' de gösterilmiştir.

$$h(t) = \int_{-\infty}^{+\infty} \left\{ \int_{-\infty}^{+\infty} S(\tau, f) d\tau \right\} e^{i2\pi ft} df \quad (3.21)$$

S-dönüşümünde bahsedilmesi gereken bir başka ifade ise SDD analizinde olduğu gibi bir çatı fonksiyon tanımlanabilmesidir. Tek boyutlu fonksiyonun değişkenlerinin τ ve f_1 olduğu varsayıldığında $S(\tau, f_1)$ çatı fonksiyonu denklem 3.22' de gösterildiği şekilde yazılabilir [34-36].

$$S(\tau, f_1) = A(\tau, f_1) e^{i\phi(\tau, f_1)} \quad (3.22)$$

Denklem 3.22' deki A ve ϕ ifadeleri sırasıyla büyüklük ve faz açısı değerleridir. Çatı fonksiyonunun belirli bazı bileşenleri izole etmesi durumunda, Anlık Frekans (AF) değerleri Bracewell' in denklem 3.23' te tanımladığı şekliyle (ϕ) faz açısı değerleri kullanılarak hesaplanabilir.

$$AF(\tau, f_1) = \frac{1}{2\pi} \frac{\partial}{\partial \tau} \{2\pi f_1 \tau + \phi(\tau, f_1)\} \quad (3.23)$$

S-dönüşümü, Fourier spektrumları yardımıyla $H(f)$ ve $h(t)$ ' nin birleşimi şeklinde yazılabilir. Bu şekildeki bir gösterim, Hızlı Fourier Dönüşümü (HFD) ve konvolüsyon teoremi gibi farklı analiz yöntemlerinin avantajlarından da faydalanarak ayrık S dönüşümünün ayrık analog değerlerini hesaplama aşamasında kullanılabilir [34-37]. Başka bir ifadeyle, kosinüs fonksiyonlarının birleşimi şeklinde değil de, büyüklük (A) ve faz (ϕ) spektrumlarının konumlandırılmasını analiz aşamasında elde edilen spektrumların gerçel ve imajiner kısımlarını ayrık olarak hesaplayarak gerçekleştirebilmektedir [36-38]. S-dönüşümünün frekans ve zaman bileşenlerini içeren genel denklemi denklem 3.24' te gösterilmiştir.

$$S(\tau, f) = \int_{-\infty}^{+\infty} H(\alpha + f) e^{-\frac{2\pi^2 \alpha^2}{f^2}} e^{i2\pi \alpha \tau} d\alpha \quad (f \neq 0) \quad (3.24)$$

3.2.1. Ayrık Stockwell Dönüşümü

S-dönüşümü, Fourier dönüşümünde olduğu gibi $h(t)$ ' nin ayrık zaman serileri $h[kT]$, ($k = 0, 1, 2, \dots, N - 1$) şeklinde yazılabilir. S-dönüşümü ayrık durumda, $h[kT]$ zaman serilerinde tanımlanmış ve vektör dizileri üzerine yayılmış iz düşüm vektörleri olarak tanımlanmaktadır [36-38]. Buradaki yayılmış vektörler dik değildir ve S-dönüşümünden elde edilen bileşenler bağımsız değişken değildir. Genel anlamda ayrık Stockwell dönüşümü aşağıdaki maddeler yardımıyla tanımlanabilir [35]:

- Her bir vektörün o vektörü oluşturan elementleri, N kadar ötelenen ve N katmanlı vektör bölgelerine paylaştırılır.
- N katmana yayılmış bu vektörlerin toplamı orijinal vektörün kendisine eşittir.
- Örnekleme periyodu, sonlu uzunluk, zaman ve frekans bölgesinde bağımsız değişkenler yardımıyla periyodikliğinin tanımlanamaması dezavantajlarıdır.

Ayrık zaman serilerine sahip $h[kT]$, benzer olarak Ayrık Fourier Dönüşümü (AFD)'nde tanımlandığı şekliyle ($f \rightarrow n/NT$ ve $\tau \rightarrow jT$) olarak tekrar düzenlendiğinde ayrık Stockwell dönüşümü denklem 3.25' te belirtildiği şekilde yazılabilir.


$$S\left[jT, \frac{n}{NT}\right] = \sum_{m=0}^{N-1} H\left[\frac{m+n}{NT}\right] e^{-\frac{2\pi^2 m^2}{n^2}} e^{\frac{i2\pi m j}{N}} \quad (n \neq 0) \quad (3.25)$$

Ters Ayırık Stockwell dönüşümünün matematiksel gösterimi ise denklem 3.26' da gösterilmiştir.

$$h[kT] = \sum_{n=0}^{N-1} \left\{ \frac{1}{N} \sum_{j=0}^{N-1} S\left[jT, \frac{n}{NT}\right] \right\} e^{\frac{i2\pi n k}{N}} \quad (3.26)$$

3.3. Hilbert-Huang Dönüşümü (HHD)

HHD, deneysel gözlemlere dayalı bir sinyal işleme yöntemidir. HHD yöntemi istenen duruma adapte edilebilen ve tek bir matematiksel formüle dayanmayan bir yapıdadır. Bu özelliği ile lineer durağan olmayan sistem verilerinden fiziksel ve anlamlı çıkarımlar yapmaya imkan sağlayabilmektedir [39]. HHD temelde iki kısımdan oluşmaktadır. Birinci kısım DMA, ikinci kısım ise HSA' dır. Bu iki farklı yaklaşım kullanılarak lineer ve durağan olmayan sistemlerin zaman-frekans-enerji gösterimleri elde edilebilmektedir. Şekil 3.4' te Hilbert-Huang yöntemi işlem basamakları gösterilmiştir.



Şekil 3.4 HHD işlem basamakları

Lineer olmayan sistemlerin genel özelliklerinden bir tanesi, salınım döngüsü içerisindeki anlık frekans değişimleridir. Anlık frekans bilgilerinden faydalanılarak sistem

dinamiklerine ve fiziksel-anlamalı özelliklerine ulaşılmaktadır. Anlık frekans bilgisine Hilbert dönüşümü sayesinde kolaylıkla ulaşılabilmektedir. L^p uzayında yer alan ve gerçel kısmı $x(t)$, imajiner kısmı $y(t)$ olan fonksiyonun Hilbert dönüşümü denklem 3.27’ de verilmiştir.

$$H[x(t)] = \frac{1}{\pi} PV \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (3.27)$$

Yukarıdaki denklemdeki PV değeri tekil integralin ilk değeridir. Hilbert dönüşümünün analitik gösterimi denklem 3.28’ de gösterilmiştir.

$$z(t) = x(t) + iy(t) = a(t)e^{i\theta(t)} \quad (3.28)$$

Denklem 3.28’ de gösterilen; $a(t)$ anlık büyüklük değeri ve θ faz fonksiyonudur. Anlık frekans değeri (ω) ise basit olarak denklem 3.29’ da gösterilmiştir.

$$\omega = \frac{d\theta}{dt} \quad (3.29)$$

Hilbert dönüşümü bu haliyle frekans bilgisini bölgesel olarak gösterse de anlık hassas frekans bilgisine ulaşmak bu formüllerle oldukça zordur. Bundan dolayı HDD dönüşümüne DMA dahil edilerek Hilbert dönüşümünün gerçek avantajları ortaya çıkarılmış olmaktadır.

3.3.1. Deneysel Mod Ayırıştırma (DMA)

DMA yönteminin diğer adı eleme süreci (sifting process)’dir. Bu eleme süreci lineer ve durağan olmayan sistemler için zorunlu bir işlem basamağıdır. Diğer bahsedilen yöntemlerin aksine bu yöntem, sistem verilerinden ve ayırıştırma yönteminden türetilerek oluşturulmuş sezgisel, doğrudan ve adaptif özelliklere sahiptir [40]. Burada bahsedilen ayırıştırma yöntemi, salınımlardan elde edilen ve birbirinden farklı gerçek modları temsil etmektedir. Her bir gerçek mod lineer olsun veya olmasın basit bir salınımı ifade eder ve aynı sayıda ekstremuma ve sıfır geçişlere sahiptir. Bu salınım modlarının her biri içsel mod fonksiyonu (IMF) olarak tanımlanır ve aşağıdaki maddelerde belirtilen özellikleri taşır:


- Tüm veri setinde, tüm ekstremumların ve sıfır geçişlerin sayısı ya birbirlerine eşit olmalı ya da en fazla bir fark olmalıdır.

- Herhangi bir noktadaki lokal maksimumları ve lokal minimumları çevreleyen çerçeve fonksiyonlarının ortalama değeri sıfır olmalıdır.

IMF, basit harmonik fonksiyonlara benzer şekilde basit salınım modları gösterir fakat daha genel bir ifadeyle; basit harmonik bileşenlerdeki sabit büyüklük ve frekans değerleri yerine zaman fonksiyonuna bağlı olarak farklı büyüklük ve frekans değerlerine sahiptir. Bu işlem mantığı göz önünde bulundurularak ve aşağıdaki işlem basamakları uygulanarak her türlü fonksiyon bileşenlerine ayrıştırılabilmektedir [39]:

- Analizi yapılacak sinyallerin veri setlerinin elde edilmesi
- Tüm lokal ekstremum noktalarının belirlenmesi
- Lokal maksimum değerlerini birleştirecek şekilde üst kısımdan geçen ve kübik fonksiyon eğrisinin kullanıldığı bir üst çerçeve fonksiyonunun belirlenmesi
- Lokal minimum değerlerini birleştirecek şekilde alt kısımdan geçen ve kübik fonksiyon eğrisinin kullanıldığı bir alt çerçeve fonksiyonunun belirlenmesi
- Alt ve üst çerçeve fonksiyonunun tüm veri setini kapsayacak şekilde olmasının sağlanması
- Alt ve üst çerçeve fonksiyonlarının ortalama değerlerinin hesaplanarak m_1 şeklinde bir ortalama değer fonksiyonunun elde edilmesi
- Veri setleri ile ortalama değer fonksiyonu birbirinden çıkartılarak ilk h_1 bileşeninin elde edilmesi, ($h_1 = x(t) - m_1$)
- Bu işlem basamaklarının her bir seviye bileşenleri için tekrar edilmesi.

Yukarıda bahsedilen işlem basamaklarının grafiksel olarak gösterimi Şekil 3.5' te gösterilmiştir.



Şekil 3.5 DMA yönteminin işlem basamakları

Eleme sürecinin kullanılmasının iki ana nedeni bulunmaktadır. Birinci neden üst üste binmiş dalgaları birbirinden ayırmak, ikinci neden ise daha simetrik dalga profilleri elde etmektir. Birinci amaca ulaşabilmek için Hilbert dönüşümünden elde edilen anlık frekans değerlerinin kullanılması, ikinci amaca ulaşabilmek için ise komşu dalgaların birbirleri arasındaki farkın çok büyük olması gibi durumlarından faydalanılmaktadır.

Tablo 3.1 Hilbert-Huang dönüşümünde IMF'lerin elde edilmesi

	IMF 1	IMF 2	...	IMF n
	$X(t)$	$X(t) - c_1 = r_1$	...	$r_{n-2} - c_{n-1} = r_{n-1}$
0	$X(t) - m_1 = h_1$	$r_1 - m_2 = h_2$	...	$r_{n-1} - m_n = h_n$
1	$h_1 - m_{11} = h_{11}$	$h_2 - m_{21} = h_{21}$	...	$h_n - m_{n1} = h_{n1}$
2	$h_{11} - m_{12} = h_{12}$	$h_{21} - m_{22} = h_{22}$	...	$h_{n1} - m_{n2} = h_{n2}$
3	$h_{12} - m_{13} = h_{13}$	$h_{22} - m_{23} = h_{23}$	...	$h_{n2} - m_{n3} = h_{n3}$
...	...	...	...	...
k	$h_{1(k-1)} - m_{1k} = h_{1k}$	$h_{2(k-1)} - m_{2k} = h_{2k}$	...	$h_{n(k-1)} - m_{nk} = h_{nk}$
IMF	$h_{1k} = c_1$	$h_{2k} = c_2$	...	$h_{nk} = c_n$

Bu işlem basamaklarından elde edilen ilk IMF fonksiyonu h_1 , bir sonraki aşamada veri kümesi olarak değerlendirilir. En uygun IMF değerine kadar bu işlemler tekrarlanır. Denklem 3.30' da DMA yöntemi işlem basamaklarının k. seviyeye kadar ayrıştırılmasının genel matematiksel gösterimi verilmiştir.

$$\begin{aligned} h_1 &= x(t) - m_1 \\ h_{11} &= h_1 - m_{11} \\ &\vdots \end{aligned} \quad (3.30)$$

$$h_{1k} = h_{1(k-1)} - m_{1k}$$

$$c_1 = h_{1k}$$

DMA işlem basamaklarının doğru şekilde gerçekleştirilmesi için algorithmada tanımlanmış bir durdurma kriteri bulunmaktadır. Durdurma kriteri (Huang vd, 1998) bahsedildiği üzere iki farklı yöntemle yapılabilmektedir [41]. Bunlardan birincisi Cauchy yakınsama prensibinden faydalanılarak oluşturulmuştur, ikincisi ise yoğun test çalışmaları ve gözlemlerden yola çıkılarak oluşturulmuş ve belirtilen seviyeye kadar ayrıştırma yapan alternatif yöntemdir. Çoğunlukla tercih edilen durdurma kriteri Cauchy yakınsama prensibi olmasına karşılık (Huang ve Wu, 2008)' de bahsedilen bazı dezavantajlardan dolayı ikinci yöntem de sıkça tercih edilmektedir [40]. Cauchy yakınsama prensibi kullanılarak elde edilen durdurma kriterinin matematiksel gösterimi denklem 3.31' de verilmiştir.

$$SD_k = \frac{\sum_{t=0}^T |h_{k-1}(t) - h_k(t)|^2}{\sum_{t=0}^T h_{k-1}^2(t)} \quad (3.31a)$$

$$SD_k = \frac{\sum_{t=0}^T |m_{1k}(t)|^2}{\sum_{t=0}^T |h_{1k}(t)|^2} \quad (3.31b)$$

İkinci yöntem olarak kabul edilen ve S durdurma kriteri olarak tanımlanmış deneysel mod ayrıştırma aralıkları bulunmaktadır. Bu optimum aralık seçimi ise (Huang v.d., 2003)' te bahsedildiği şekliyle 3 ile 8 aralığıdır [42] .

Durdurma kriteri aynı zamanda $x(t)$ fonksiyonunun ilk IMF' sinden elde edilen c_1 ile arasındaki farktan faydalanılarak da belirlenebilmektedir. Kalan bu fark değer fonksiyonu r_1 olarak tanımlandığında algoritmayı durdurma basamağı r 'nin j 'inci

seviyesinde kolaylıkla yapılabilmektedir [40-43]. Bu işlem basamakları ise tıpkı denklem 3.30' da olduğu gibi ilk kalan r_1 fonksiyonunun bir sonraki aşamada veri kümesi olarak değerlendirilmesine benzer şekilde ilerlemektedir. Denklem 3.32' de durdurma kriterinin matematiksel gösterimi verilmiştir.

$$\begin{aligned} r_1 &= x(t) - c_1 \\ r_2 &= r_1 - c_2 \\ &\vdots \\ r_n &= r_{n-1} - c_n \end{aligned} \quad (3.32a)$$

$$x(t) = \sum_{j=1}^n c_j + r_n \quad (3.32b)$$

3.3.2. Hilbert Spektral Analizi (HSA)

IMF yöntemiyle elde edilen fonksiyon bileşenlerine Hilbert dönüşümü uygulandığında anlık frekans bilgilerine ulaşılabilmektedir. Denklemde yer alması gereken fakat monotonik veya sabit sayı olması gibi nedenlerden dolayı r_n değeri denklemden çıkarılmaktadır. Bunun birinci nedeni; uzun periyottaki belirsizlikler, ikinci neden ise; düşük periyotlardaki dikkate değer salınımlı bileşenlerin içerdiği bilgileri kaybetmemek için son IMF olmayan bileşen denklemden çıkarılmaktadır. Burada dikkat edilmesi gereken nokta ise fiziksel çıkarımlarını etkilemeyecek şekilde olmasıdır [40-44]. Denklem (3.27)-(3.29) arasındaki matematiksel formüller kullanılarak gerçek verilerin reel kısmı ($\Re$) denklem 3.33' de gösterildiği şekilde yazılmaktadır.

$$x(t) = \Re \left\{ \sum_{j=1}^n a_j(t) \exp \left[i \int \omega_j(t) dt \right] \right\} \quad (3.33)$$

Denklem 3.33 kullanılarak zaman fonksiyonu üzerinde her bir bileşenin büyüklük ve frekansına ulaşılmaktadır. Fourier gösterimi kullanılarak ise veriler daha genel bir ifadeyle denklem 3.34' te gösterildiği şekilde yazılabilmektedir.

$$x(t) = \Re \left[\sum_{j=1}^n a_j e^{i\omega_j(t)t} \right] \quad (3.34)$$

Denklem (3.33) ve (3.34)' de belirtilen a_j ve ω_j değerleri sırasıyla genlik ve açısal frekanstır. Bu iki denklemden de anlaşılacağı üzere IMF' ler Fourier dağılımının genelleştirilmiş halini temsil etmektedir. Değişken büyüklük ve frekans değerleri, daha geniş bir perspektifte veri kümeleri analizini sağlamanın yanı sıra lineer ve durağan olmayan verilerin de ilişkilendirilmesine kolaylık sağlamaktadır.

Büyüklik değerlerinin zaman-frekans bölgesindeki dağılımlarını ifade eden parametreye 'Hilbert Büyüklik Spektrumu' $H(\omega, t)$ veya kısaca 'Hilbert Spektrumu' adı verilmiştir. Aynı şekilde büyüklüğün karesiyle ifade edilen enerji yoğunluğu parametresi 'Hilbert Enerji Spektrumu' olarak ifade edilebilmektedir [40-44]. Hilbert spektrumu sayesinde marjinal spektrum $h(\omega)$ denklem 3.35' te gösterildiği şekilde yazılabilmektedir.

$$h(\omega) = \int_0^T H(\omega, t) dt \quad (3.35)$$


Marjinal spektrum, her bir frekans bileşeninden elde edilen büyüklük veya enerji seviyesini ifade etmektedir. Bu spektrum sayesinde tüm veri kümesi üzerindeki tahmini toplam büyüklük değerleri elde edilebilmektedir.

4. ARIZA YERİ BELİRLEMEDE KULLANILAN YÖNTEMLERİ

4.1. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA) yöntemi analitik yöntemler kullanılarak çözülemeyen karmaşık ve doğrusal olmayan problemlerin çözümünde kullanılan bir iterasyon yöntemidir. YSA iletim hatlarında arıza yeri belirleme, yük tahmini vs. gibi birçok farklı görevde tercih edilen ve akıllı öğrenme algoritmaları içerisinde diğer yöntemlere kıyasla daha uzun bir geçmişe sahiptir [44].

YSA insan beyinde bulunan nöronların çalışma mantığına benzer bir şekilde verileri analiz ederek, bu bilgilerden anlamlı ve yorumlanabilir sonuçlar çıkarmaktadır. Her bir nöron olarak adlandırılan işlem elemanı bir giriş değerine karşılık bir çıkış değeri üretir. Daha sonrasında elde edilen bu çıkış değerleri bir sonraki nöronun giriş değeri olur. İnsan sinir sisteminde bulunan hücrelerdeki, nöronlar YSA’ da işlem elemanı, dendritler toplam fonksiyonunu (Σ), hücre gövdesi aktivasyon (transfer) fonksiyonunu, aksonlar işlem elemanının çıkışını, sinapslar ise ağırlıkları ifade etmektedir [24-46]. YSA, insan beynine bezer şekilde hatırlama, öğrenme ve genelleme yeteneğine sahiptir. YSA’ nın işlem sırası ilk olarak giriş değerlerin ağırlıklarla çarpılmasıyla başlar. Bu çarpım sonucunda elde edilen değerler toplanarak ikinci aşamada bir aktivasyon fonksiyonundan geçirilir. Son işlem basamağında ise aktivasyon fonksiyonlarından elde edilen bu değerler sayesinde çıkış değerleri üretilir. Şekil 4.1’ de YSA’ nın işlem basamakları gösterilmiştir.



Şekil 4.1 YSA işlem basamakları

YSA' da kullanılan birçok aktivasyon fonksiyonu bulunmaktadır. Bu aktivasyon fonksiyonlarının temel amacı ise toplama işleminin değişimine imkan sağlayacak zaman tanımaktır. En çok kullanılan aktivasyon fonksiyonları; doğrusal, adım, logaritmik sigmoid, hiperbolik tanjant sigmoid vs.'dir. Bir yapay nöronun ağırlıklara, toplama ve aktivasyon fonksiyonlarına bağlı olarak giriş-çıkış ilişkisi denklem 4.1' de verilmiştir.

$$N_j = \sum_{j=1}^n w_j x_j$$

$$y_j = \varphi \left(\sum_{j=1}^n w_j x_j + b_j \right) \quad j = 1, 2, 3, \dots, n \quad (4.1)$$

Buradaki N_j toplam işlevini, w_j ağırlıkları, x_j giriş değerleri, y_j çıkış değerleri, φ aktivasyon fonksiyonu ve b_j ise j . ' inci işlem elemanının eşik değerini temsil etmektedir.


YSA' nın kullanım alanlarından bazıları; zaman serilerinin analizi, sinyal işleme ve kontrol, örüntü tanıma, modelleme vs.' dir. YSA güç sistemlerinde birçok değişik probleme uygulanmaktadır. Yük tahmini [46], arıza analizi [47], sistem tanımlama [48], işletme, koruma ve gözlemleme [49], YSA' nın kullanıldığı bazı uygulamalarıdır. YSA enerji iletim hatlarında meydana gelen arızaların analizinde de kullanılmaktadır. Bu arıza konularından bazıları ise; arıza konumlandırma, yüksek empedanslı arızalar, seri kompanzasyonlu iletim hatlarında koruma, arıza tipi sınıflandırma vs. olarak sınıflandırılabilir.

YSA' nın en önemli işlem basamağı öğrenme algoritmasıdır. YSA' da öğrenme algoritmaları eğitici ve eğitici olmak üzere iki kategoride toplanmaktadır [50]. Eğitici öğrenmede giriş ve çıkış değerleri bilinmektedir. Beklenen çıkış değerleri ise yapay sinir ağının eğitimi aşamasında kullanılır. Buradan elde edilen çıkış değerleri en düşük hata oranına ulaşıncaya kadar eğitim devam eder. Eğitim aşaması bittiğinde ise yapay sinir ağının daha öncesinden bir bilgiye sahip olmadığı giriş ve çıkış değerlerini ne kadar doğrulukta tahmin ettiği kontrol edilir. Eğitici öğrenme yönteminde amaç, doğru ağırlık katsayılarına ulaşıncaya kadar ağırlıkları yenilemektir. Eğitici öğrenmede ise çıkış değerleri belirtilmeden temel gruplandırma işlemleri yardımıyla veri kümeleri arasındaki ortak özellikler bulunmaya çalışılır.

En çok bilinen yapay sinir ağı; tek katmanlı, çok katmanlı, radyal tabanlı, temel bileşenler analizi, SOM ve ART ağıdır. Tek katmanlı algılayıcı ağı, 1958 yılında Rosenblatt tarafından önerilen ilk eğitici öğrenme yöntemidir. YSA’ da en çok tercih edilen ağ ise çok katmanlı algılayıcı ağıdır. Bu ağ yapısında birden fazla gizli katman kullanılarak karmaşık ve doğrusal olmayan problemlerin çözümünde etkili bir yöntemdir [51].

YSA ağ topolojilerine göre ileri ve geri beslemeli olmak üzere iki grupta incelenmektedir [51]. İleri beslemeli ağ topolojisinde giriş ve çıkış değerleri arasında bir döngü olmazken, geri beslemeli ağ yapısında çıkış değerleri ikinci döngüde ağın eğitime tekrar sunulur. Bu şekilde başlangıçta rastgele belirlenen ağırlık değerleri geri besleme sayesinde istenen en yakın ağırlık katsayısına en kısa zamanda ve en az iterasyon işlemiyle ulaşılmış olur.

YSA eğitimi aşamasında değişik öğrenme algoritmaları kullanılmaktadır. 1986 yılında Rumelhart ve McClelland, çok katmanlı algılayıcı ağların eğitimi için geri yayılım algoritmasını geliştirmişlerdir [50]. Geri yayılım algoritmasının temelinde ağdan beklenen çıkış değeri ile hesaplanan çıkış değeri arasındaki hata değeri ağırlıklara eşit oranda yansıtılarak yeniden eğitilmesi prensibi yatmaktadır. İleri beslemeli çok katmanlı bir yapay sinir ağının yapısı Şekil 4.2’ de gösterilmiştir.



Şekil 4.2 Çok katmanlı algılayıcı ağ yapısı

Radyal tabanlı fonksiyon kullanan ağ yapısı, gizli ara katmanında yerel olarak ayarlanabilen düğümlere sahip iki katmanlı bir ağ yapısıdır. Bu ağ yapısında tek bir gizli katmanın olması ve çok katmanlı ağ yapısındakine benzer geri besleme olmaması gibi nedenlerden dolayı geri yayılım algoritmasıyla kıyaslandığında oldukça hızlıdır [49].

Geri yayımlı çok katmanlı algılayıcı ağları literatürde en yaygın olarak kullanılan YSA tipi olmalarına rağmen eğitim sürelerinin uzun olması, kullanılacak gizli katman nöron sayısının ve uygun öğrenme oranının belirsizliği, yerel minimuma takılma gibi dezavantajlara sahiptir [51, 52].

YSA' nın eğitim süreci içerisinde bahsedilmesi gereken diğer konu başlıkları ise veri kümelerinin normalizasyonu ve ağırlık değerlerinin optimizasyonudur. Ayrık değerlere sahip veri kümelerinin belirli bir değer aralığında normalizasyonu sayesinde YSA' nın veriler arasında daha mantıklı bağlantılar kurması sağlanmış olur. Ağırlık değerlerinin optimizasyonu ise eğitim sürecinin başlangıcında rastgele seçilen ağırlık katsayı değerlerinin geri yayılım sonunda lokal minimumlara takılmasını engellemek için kullanılmaktadır. Uygulamada ağırlık değerlerinin optimizasyonu için kullanılan dört farklı yöntem bulunmaktadır. Bunlar; eğim düşümü (gradient descent), eşlenik gradyan, quasi-newton ve Levenberg-Marquardt' dır [52].

4.2. Destek Vektör Makineleri

DVM istatistiksel öğrenme teorisi, optimizasyon teorisi ve Vapnik-Chervonenkis boyut teorisine dayanan bir sınıflandırma yöntemidir [53]. DVM yönteminde orijinal giriş uzayı verileri en uygun şekilde oluşturulmuş ayrıştırıcı bir düzlem sayesinde doğrusal özellik gösterebileceği çok boyutlu özellik uzayına taşınması olarak tanımlanmaktadır. DVM, veri çiftlerini tek bir iç çarpım olarak değerlendirilerek örnek uzayda konumlandırılmasını sağlamaktadır.

DVM yöntemi diğer makine öğrenme yöntemlerinden farklı olarak bazı avantajlara sahiptir [54, 55]. Bu avantajlar genel olarak;

- Veri sayısını azaltmak için özellik çıkartma işlemine gerek duymaz.
- Yerel minimum noktaları bulunmaz.
- Çok az giriş verisi ile öğrenebilir.


- Veri sınıflandırma riskini en aza indirgeyecek şekilde çok seviyeli sınıflandırma yapılabilir.

DVM, Vapnik tarafından 1990' lar da ileri sürülen ve makine öğrenme yöntemleri arasında yer alan yöntemlerden bir tanesidir [53]. DVM yöntemi birçok farklı alana uygulanabilmektedir. Bunlardan bazıları; resim ve nesne tanımlama, biyoinformatik, finans ve ekonomi, iletim hatlarında arıza tespiti vs.' dir.

DVM yöntemi temelde ikili sınıflandırma için geliştirilmiş olmasına rağmen, birden fazla ikili DVM' nin kullanıldığı çok sınıflı yöntemler de bulunmaktadır. Bu şekilde doğrusal olarak sınıflandırılmayan örnek uzayı verilerini parabolik ve üstel fonksiyonlar yardımıyla çok sınıflı olarak ayırmak mümkündür.

4.2.1. İkili Sınıflandırma Algoritması

DVM yönteminde, N tane gözlemden oluşan ve n boyutlu uzayda her biri tek bir veri çiftinden oluşan veri vektörü $x_i \in R^n$ ve $i = 1, 2, 3, \dots, N$ olmak üzere, bu veri vektörüne karşılık gelen sınıf etiketi $y_i \in \{-1, +1\}$ olarak tanımlanmaktadır. Bu sınıflandırma işlemi için seçilen herhangi bir $f(x)$ aşırı düzlemi kullanılarak pozitif sınıfa ait giriş verileri $y_i = +1$ ve negatif sınıfa ait giriş verileri ise $y_i = -1$ sınıfa dahil edilerek gruplama yapılmaktadır [55]. Burada bahsedilen $y_i = +1$ ve $y_i = -1$ tanımlamaları verilerin I. Gruba veya II. Gruba ait olması olarak düşünülebilir. DVM' nin genel gruplama işlemini nasıl yaptığı Şekil 4.3' te gösterilmiştir.



Şekil 4.3 En uygun ayırıcı düzlem ve destek vektörleri

Şekil 4.3' te gösterilen en uygun ayırıştırıcı düzlem H ve maksimum aralık m olarak ifade edilmektedir. Sınıflandırma işlemi için tanımlanan $f(x)$ aşırı düzleminin matematiksel gösterimi denklem 4.2 ve 4.3' de verilmiştir.

$$f(x) = w^T \cdot x + b = \sum_{j=1}^N w_j x_j + b \quad (4.2)$$

$$y_i f(x_i) = y_i (w^T \cdot x_i + b) \geq 0 \quad i = 1, 2, 3, \dots, N \quad (4.3)$$

Buradaki; w , n boyutlu bir vektör, b ise eşik değeridir. Bunun yanı sıra w ve x ' in $1/|w|$ uzaklığındaki aşırı düzleme en yakın olma koşulu yerine getirildiğinde denklem 4.4'de olduğu şekliyle yeniden yazılabilir.

$$y_i (w^T \cdot x + b) \geq 1, \quad i = 1, 2, 3, \dots, N \quad (4.4)$$

DVM yöntemindeki temel amaç destek vektörler sayesinde en geniş ayırıştırma aralığını tespit etmektir. DVM' nin genelleme kabiliyeti bu ayırıştırıcı düzlemi maksimize etmekle sağlanmaktadır [56].

m aralığının maksimum olabilmesi için $\|\bar{w}\|$ değerinin minimum değeri alması gerekmektedir. $\|\bar{w}\|$ ifadesi matematiksel olarak denklem 4.5' de gösterildiği şekliyle yeniden yazılabilir.

$$\min \|\bar{w}\| = \min \left[\frac{1}{2} (\|\bar{w}\|)^2 \right] \quad (4.5)$$

m aralığının maksimum olabilmesi için Lagrange çarpanları kullanılarak yeniden denklem düzenlendiğinde denklem 4.6 elde edilmektedir.

$$L = \frac{1}{2} (\|\bar{w}\|)^2 - \sum_{i=1}^N \alpha_i [y_i (\bar{w}_i x_i + b) - 1] \quad (4.6)$$

Lagrange ikilik problemine dönüştürülmüş bu haliyle denklem 4.6, w ve b ' ye göre kısmi türevleri alındığında denklem 4.7 ve 4.8' deki eşitlikler elde edilir.

$$\bar{w} = \sum_{i=1}^N \alpha_i y_i \bar{x}_i \quad (4.7)$$

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (4.8)$$

Denklem 4.7 ve 4.8' den elde edilen eşitlikler denklem 4.6' da yerine yazıldığında ise denklem 4.9 elde edilmektedir. Denklem 4.9' da ifade edilen L değeri aynı zamanda optimizasyon için gerekli noktasal değerlerin çift olarak değerlendirildiği ve özellik uzayında çekirdek (kernel) bir fonksiyonla ifade edilebilen yeni bir bakış açısı da kazandırmış olmaktadır [57].

$$L = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i x_j \quad (4.9)$$

Buradaki $(\alpha_1, \alpha_2, \alpha_3, \dots \alpha_i)$ Lagrange çarpanlarıdır. Karush-Kuhn-Tucker teoremine göre denklem 4.9' da ki giriş-çıkış çifti (x_i, y_i) için sadece $\alpha_i > 0$ şartını sağladığı sürece devam ettirilir. Bu koşula uyan giriş verileri (x_i) ise destek vektörler olarak adlandırılır [54, 55].

α 'nın ikili problem için en uygun çözümünün α^* olduğu varsayıldığında w ve b 'nin en uygun çözümleri denklem 4.10 ve 4.11' de gösterilmiştir.

$$w^* = \sum_{i=1}^N \alpha_i^* y_i x_i \quad (4.10)$$

$$b^* = 1 - w^* \cdot x_i \quad (x_i = 1 \text{ ve } y_i = 1 \text{ için}) \quad (4.11)$$

Sınıflandırıcı, eğitimden sonra herhangi bir x bilinmeyenini sınıflandırmak için denklem 4.12' de gösterilen bir karar fonksiyonu kullanmakta ve $f(x)$ fonksiyonunun değeri $+1$ ise x ' i I. Gruba, -1 ise II. Gruba eklemektedir.

$$f(x) = \text{sign}(w^* \cdot x + b) \quad (4.12)$$

DVM yöntemi daha önce de bahsedildiği üzere orijinal giriş uzayı verilerini özellik uzayına çekirdek (kernel) fonksiyon ve aşırı düzlem etrafında belirlediği destek vektörler yardımıyla yerleştirmektedir. Doğrusal olmayan bir vektör fonksiyonu $(\phi(x) = \phi_1(x), \dots, \phi_L(x))$ kullanarak x ' i, L boyutlu F özellik uzayına taşıyan ikili formdaki doğrusal karar fonksiyonu denklem 4.13' de verilmiştir.

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i^* y_i \phi^T(x_i) \phi(x) + b^* \right) \quad (4.13)$$

Bu denklemde bahsedilen iç çarpım $\phi^T(x_i) \phi(x)$ yerine $K(x_i, x) = \phi^T(x_i) \phi(x)$ olarak yeniden düzenlendiğinde doğrusal karar fonksiyonunun en genel ifadesi elde edilmiş olur.

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i^* y_i K(x_i, x) + b^* \right) \quad (4.14)$$

Doğrusal olmayan bir çekirdek fonksiyonu kullanılarak çözümlenen denklem (4.14) eşitliği sonucunda, herhangi x eğitim örneğinin hangi sınıfa ait olduğunu belirlemek için sınır şartları [55, 59];

$$x \in \begin{cases} f(x) = +1 & \text{I. Grup} \\ f(x) = -1 & \text{II. Grup} \end{cases} \quad (4.15)$$

olarak yazılır.

Çekirdek fonksiyon sınıflandırma işleminin farklılığına ve karmaşıklığına göre farklı formlarda olabilmektedir. Polinomal, radyal tabanlı veya sigmoid çekirdek fonksiyonları DVM sınıflandırma işleminde tercih edilenlerden bazılarıdır [54].


4.2.2. En Küçük Kareler Destek Vektör Makineleri

LS-SVM regresyon yöntemi; regularizasyon ağırları, Gauss süreci, Fisher diskriminant analizi, Hilbert uzayında yeni çekirdek fonksiyon türetilmesi (RKHS) gibi farklı yaklaşımların bir araya getirilmesiyle oluşturulmuş, standart DVM' nin yeniden düzenlenmiş halidir. Ayrıca LS-SVM yöntemi çözümlemesi zor optimizasyon problemleri için ilkel-ikincil gösterim sayesinde sınıflandırma ve en uygun ayrıştırma düzleminin belirlenmesi gibi işlem basamaklarına yardımcı olmaktadır. Sınıflandırma ve doğrusal olmayan regresyon işlemlerinde kullanılan LS-SVM modelleri ise doğrusal Karush-Kuhn-Tucker (KKT) sistemlerinden faydalanılarak oluşturulmuştur [60, 61].


Hilbert uzayında çekirdek fonksiyon türetilmesi fikri başlangıçta ikinci dereceden ve rastgele-olasılık süreçlerinin gösterimine yardımcı olması için kullanılmıştır. Daha sonra istatistiksel problemlere, zaman serileri, kontrol teorisi ve yaklaşık (approximation) teorisi

gibi farklı yaklaşımların birbirleri arasındaki bağlantıyı açıklamak için kullanılmıştır [60, 62] . Ayrıca Gauss süreci kullanılarak, Hilbert uzayda türetilmiş çekirdek fonksiyonun (H_K) varyasyon problemlerine çözüm bulunmaktadır. RKHS' de bulunan her bir çekirdek fonksiyon (H_K)' a karşılık sıfır ortalama değere sahip Gauss olasılıksal sürecinde bir kovaryans $K(s, t)$ değeri bulunmaktadır. Bu sayede; olasılıksal olarak Hilbert uzayına yayılmış veri çiftleri ile H_K çekirdek fonksiyonlar arasında bire bir eşleşen bir ilişki ortaya çıkmaktadır.

Fisher diskriminant analizinde temel amaç, grupların dağılımları arasındaki uzaklığı maksimum yaparak kesişim bölgelerini en aza indirmektir. Fisher diskriminant analizi $x_k \in \mathbb{R}^n$ orijinal giriş uzayındaki verileri tek değişkenli bir boyutta $z_k \in \mathbb{R}$ verilerin iz düşümünü oluşturarak ve bu iz düşüm fonksiyonlarının değişkenlerinden faydalanarak ayırıştırma işlemi yapmaktadır. Şekil 4.4 ve 4.5' te Fisher diskriminant analizi ve LS-SVM ile arasındaki ilişki verilmiştir.



Şekil 4.4 Fisher diskriminant analizi [60].



Şekil 4.5 LS-SVM ile Fisher diskriminant analizi arasındaki ilişki [60].

Fisher diskriminant analizinde sınıflandırma işlemi ise tek değişkenin tanımlandığı düzlemin orta noktası belirlenerek iz düşüm fonksiyonlarının hangi bölgede olduğu tespit edilmekte ve en uygun sınıflandırma yapılmaktadır. Özellik uzayında ise ayrıştırma işlemi yüksek boyutlarda aynı işlem basamakları tekrarlanarak yapılmaktadır.

LS-SVM’ de Vapnik’ in formülasyonları iki noktadan yeniden düzenlenmiştir [54, 60]. Bunlardan ilki, eşitsizlik ifadesinin yerini eşitlik ifadesi almıştır. Böylelikle eşitliğin sağ tarafında bulunan 1 değeri eşik değer olmaktan çıkarak hedef değer olmuştur. Bu hedef değer ise e_k hata değerinin belirlendiği aralığa kadar iz düşüm fonksiyonlarının yayılımlarının kesişim bölgelerinden kaynaklanan yanlış sınıflandırmalara müsaade etmektedir. İkinci düzenleme ise, bu hata değişkenin LS-SVM’ de karesel bir ifade olarak (e_k^2) kullanılmasıdır [59].

Suykens’ in önerdiği bu düzenlemelerin matematiksel ifadeleri denklem 4.16’ da verilmiştir [59].

$$\min_{w,b,e} J_P(w, e) = \frac{1}{2} w^T w + \gamma \frac{1}{2} \sum_{k=1}^N e_k^2 \quad (4.16)$$

LS-SVM yönteminin ilkel-ikincil gösterimi ise denklem 4.17’ de verilmiştir.

$$\begin{aligned} \text{İlkel} : y_k[w^T\phi(x_k) + b] &= 1 - e_k \quad (k = 1, 2, 3, \dots, N) \\ \text{İkincil} : y(x) &= \text{sign} \left[\sum_{k=1}^N \alpha_k y_k K(x, x_k) + b \right] \end{aligned} \quad (4.17)$$

Doğrusal sınıflandırma problemlerinde ilkel çözüm yaklaşımı kullanılarak işlem yapılabilir fakat genel olarak w sonsuz boyutta olabileceğinden, bu problemi çözebilmek için LS-SVM' nin doğrusal olmayan sınıflandırma formülasyonu için ikincil problem çözümü kullanılmaktadır. LS-SVM sınıflandırıcı aşağıdaki maddelerde bahsedilen özelliklere sahiptir [60, 63]:

- Seçilen çekirdek fonksiyon sonlu pozitif değere sahip olmalı ve Mercer şartını yerine getirebilmelidir.
- Doğrusal ve doğrusal olmayan LS-SVM' ler için ikincil çözüm KKT sistemin doğrusal çözümüne karşılık gelmektedir. Böylece SVM sınıflandırıcıların çözümlenmesi yinelemeli olarak yeniden çözülen KKT sistemler olarak düşünülebilir.
- LS-SVM sınıflandırıcıda her bir veri noktası destek vektördür. Böylelikle hiçbir α_k değeri tam olarak sıfır olamaz.
- LS-SVM' de eğitilen tüm veri noktaları modele dahil edilmektedir. $|\alpha_k|$ noktaları büyüklüklerine göre karar sınırından uzağa veya yakına konumlandırılmaktadır.
- İlkel ağırlık uzayında problem sabit boyut vektörlü parametrik bir yapıdadır. İkincil ağırlık uzayında ise problem parametrik değildir ve çözüm vektörlerinin boyutu $\alpha \in \mathbb{R}^N$ eğitilen veri setlerinin miktarıyla (N) birlikte artar.
- Parametre ayarlama işlemleri (γ, σ); eğitim, doğrulama ve test aşamalarından elde edilen tecrübelerden faydalanılarak oluşturulmaktadır.

4.3. Uç Öğrenme Makineleri

Son yıllarda özellikle ileri beslemeli yapay sinir ağları uygulamalarında eğitim düşümü (gradient-descent) yöntemi sıklıkla tercih edilmesine rağmen lokal minimum noktalarına takılma, işlem süresini uzatacak ara basamaklar vs. gibi bazı nedenlerden dolayı uygulamalarda problemler çıkarabilmektedir. Ayrıca en iyi öğrenme performansını elde edebilmek için birçok ara iterasyon basamağına ihtiyaç duyulmaktadır [63].

Huang'ın önerdiği Extreme Learning Machine (ELM) yöntemi, uygulamada karşılaşılan bu gibi problemlere çözüm bulabilmek ve en az işlem basamağıyla en iyi öğrenme performansı elde edebilmek üzere önerilmiş tek katmanlı bir sinir ağıdır [64]. ELM yöntemi, ağırlık katsayıları (w) ve eşik değeri (b)'nin, gizli katmanda bulunan aktivasyon fonksiyonunun (g) sonsuz türevlenebilir olduğu kabul edildiğinde rastgele seçilebileceği teorisinden yola çıkılarak oluşturulmuştur. ELM' nin bu tek katmanlı ileri beslemeli ağ yapısı doğrusal sistem olarak düşünüldüğünde çıkış ağırlıkları gizli katmanın çıkış matrisinin tersinin alınması gibi basit analitik yöntemlerle hesaplanabilmektedir.

N tane örnek çiftinden oluşan bir veri matrisinde herhangi ayrık iki örnek (x_i, t_i) çifti; $x_i = [x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}]^T \in R^n$, $t_i = [t_{i1}, t_{i2}, t_{i3}, \dots, t_{im}]^T \in R^m$, $\tilde{N}$ tane ara katman ve aktivasyon fonksiyonu $g(x)$ kullanılarak tek katmanlı sinir ağının matematiksel modeli denklem 4.18' deki gibi gösterilebilir.

$$\sum_{i=1}^{\tilde{N}} \beta_i g_i(x_j) = \sum_{i=1}^{\tilde{N}} \beta_i g(w_i x_j + b_i) = y_j \quad j = 1, 2, 3, \dots, N \quad (4.18)$$

Bu denklemde gösterilen ; $w_i = [w_{i1}, w_{i2}, w_{i3}, \dots, w_{in}]^T$ i.'nci giriş katmanı ile gizli katmanı birbirine bağlayan ağırlık vektörünü, $\beta_i = [\beta_{i1}, \beta_{i2}, \beta_{i3}, \dots, \beta_{im}]^T$ ise i.'nci gizli ara katman ile çıkış katmanını birbirine bağlayan ağırlık vektörünü temsil etmektedir. Ayrıca b_i değeri ise i.'nci katmanın eşik değerini temsil etmektedir.

Burada standart tek katmanlı ileri beslemeli ağ kullanılarak $\tilde{N}$ tane gizli katmandan oluşan ve aktivasyon fonksiyonu $g(x)$ olan N tane örnek teorik olarak $\sum_{j=1}^N \|y_j - t_j\| = 0$ sıfır hatayla tahmin edebilmektedir. Bu son haliyle denklem 4.18 yeniden düzenlenerek denklem 4.19'da yeniden verilmiştir.

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i x_j + b_i) = t_j, \quad j = 1, 2, 3, \dots, N \quad (4.19)$$

ELM yönteminde ağın matematiksel gösterimi başka bir açıdan bakıldığında veri matrislerinin çarpımı ($H\beta = T$) şeklinde düşünülebilir. Bu vektör çarpımları kare matrisi veya $n \times m$ boyutundaki bir veri matrisini kolaylıkla çözümlemeye imkan sağlayacak şekilde ELM yönteminde kullanılmaktadır [64, 65].

Tek katmanlı ileri beslemeli sinir ağının gizli katmanının çıkış matrisini H , ağırlık vektörünü β ve gerçek çıkış verilerini T matrisinin ifade ettiği varsayıldığında, bu veri matrislerinin matematiksel gösterimleri denklem 4.20 ve denklem 4.21’de verilmiştir.

$$H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}, x_1, \dots, x_N) = \begin{bmatrix} g(w_1x_1 + b_1) & \dots & g(w_{\tilde{N}}x_1 + b_{\tilde{N}}) \\ \vdots & \dots & \vdots \\ g(w_1x_N + b_1) & \dots & g(w_{\tilde{N}}x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}} \quad (4.20)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m} \quad (4.21)$$

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

Tek katmanlı ileri beslemeli bir ağı eğitebilmek için spesifik $\hat{w}_i, \hat{b}_i, \hat{\beta}$ ($i = 1, 2, 3, \dots, \tilde{N}$) değerlerini belirlemek gerekmektedir [64]. ELM yönteminde gizli katman ile çıkış katmanı arasında elde edilen H matrisinin giriş ağırlıkları (w_i) ve eşik değerleri (b_i) başlangıçta rastgele seçilmektedir. Burada seçilen sabit w_i ve b_i değerleri kullanılarak tek katmanlı sinir ağının eğitimi aynı zamanda $H\beta = T$ doğrusal denklemindeki $\hat{\beta}$ değerinin en küçük kareler çözümlerini bulmakla aynı anlama gelmektedir. Ağı eğitiminde kullanılan bu en küçük karesel çözümler aynı zamanda eğim düşümü (gradient-descent) ve geri yayılım (back propagation) algoritmasını kullanan klasik tek katmanlı ileri beslemeli ağların öğrenme oranlarını (η) elde etmekte kullanılmaktadır.

En küçük kareler çözümleri ifade eden değer fonksiyonu (E)’nin matematiksel gösterimi denklem 4.22’de verilmiştir.

$$E = \sum_{j=1}^N \sum_{i=1}^{\tilde{N}} \beta_i g((w_i x_j + b_i) - t_j)^2 \quad (4.22)$$

Eğim düşümü (gradient-descent) yöntemini kullanan sinir ağlarında H bilinmeyişi genellikle $\|H\beta - T\|$ denkleminin minimum değerinin bulunmasıyla elde edilebilmektedir. En küçük değere indirgeme işlem basamakları ise ağırlık vektörlerinin (w_i, β_i) ve eşik değeri (b_i) kümesini ifade eden W vektörünün iteratif olarak hesaplanmasıyla sağlanmaktadır. W vektörünün matematiksel gösterimi denklem 4.23’te verilmiştir.

$$W_k = W_{k-1} - \eta \frac{\partial E(W)}{\partial E} \quad (4.22)$$

Bu denklemde yer alan η değeri öğrenme oranını ifade etmektedir. ELM yönteminde klasik ileri beslemeli ağ yapılarından farklı olarak başlangıçta belirlenen w_i ve b_i değerleri rastgele seçildikten sonra gizli ara katman ile çıkış katmanı arasında elde edilen H matrisi elde edilmektedir [65, 66]. ELM yönteminde de tıpkı klasik ileri beslemeli geri yayımlımlı ağlarda olduğu gibi $\hat{\beta}_i$ 'nin en küçük kareler çözümü ağın eğitimi için geçerlidir. En küçük değere indirgeme işlem basamağı matematiksel olarak denklem 4.23' te gösterildiği şekilde yazılabilir.

$$\|H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}})\tilde{\beta} - T\| = \min_{\tilde{\beta}} \|H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}})\tilde{\beta} - T\| \quad (4.23)$$

Ara katman sayısının ($\tilde{N}$) eğitim için kullanılan ayrık örnek sayısı (N)'e eşit olması durumunda ($N = \tilde{N}$), H matrisi kare matristir ve tersi alınabilir. Böylelikle giriş ağırlık vektörleri (w_i) ve eşik değerler (b_i) rastgele seçilebilir ve eğitilen ileri beslemeli ağ örnekleri sıfır hatayla belirleyebilmektedir [64].

Ancak çoğu durumda ara katman sayısı ayrık örnek sayısından oldukça küçük ($\tilde{N} \ll N$) olduğu için H kare matris olmaz ve $H\beta = T$ gibi bir eşitlikten yararlanılarak (w_i, β_i, b_i) ($i = 1, 2, 3, \dots, \tilde{N}$) değerleri elde edilemez. Bu problemi aşmak için Huang, ELM yönteminde genelleştirilmiş Moore-Penrose ters matris dönüşümünü kullanarak $H\beta = T$ denklemini yeniden düzenlemiştir. Doğrusal olmayan $H\beta = T$ matrisinin ters dönüşüm işlem basamağı denklem 4.24' te verilmiştir.

$$\hat{\beta} = H^+T \quad (4.24)$$

Denklem 4.24' te ifade edilen $\hat{\beta} = H^+T$ ifadesi aynı zamanda genelleştirilmiş $H\beta = T$ doğrusal sistemin en küçük kareler çözümünün bir tanesidir. Diğer bir ifadeyle en düşük öğrenme hatası bu özel çözüm sayesinde elde edilebilmektedir. Minimum eğitim hatası formülü matematiksel olarak denklem 4.25' te verilmiştir.

$$\|H\hat{\beta} - T\| = \|HH^+T - T\| = \min_{\tilde{\beta}} \|H\tilde{\beta} - T\| \quad (4.25)$$

Böylelikle tek katmanlı ileri beslemeli ağın gelişmiş bir versiyonu olan ELM yöntemi 3 ara işlem basamağı kullanılarak uygulanmaktadır [64]. Verilen herhangi bir

eđitim seti $\mathfrak{K} = ((x_i, t_i) | x_i \in \mathbb{R}^n, t_i \in \mathbb{R}^m, i = 1, 2, 3, \dots, N)$, aktivasyon fonksiyonu $g(x)$ ve gizli katman sayısı $\tilde{N}$ kabulleri yapılarak ařađıdaki maddelerde bu iřlem basamakları sırasıyla aıklanmıřtır.

- w_i ađırlık katsayılarının ve b_i ($i = 1, 2, 3, \dots, \tilde{N}$) eřik deđerlerinin rastgele belirlenmesi.
- Gizli katman ıkıř matrisi H' ın hesaplanması.
- ıkıř ađırlıkları β deđerleri belirlenerek ve $\beta = H'^T T$ denkleminde yerine yazılarak $T = [t_1, t_2, \dots, t_N]^T$ deđerlerinin hesaplanması.



5. BENZETİM ÇALIŞMASI

Benzetim çalışmasında, 1000 MW (500 kV, 2 kA) DA enterkonnekte sistem kullanılarak 500 kA, 5000 MVA, 60 Hz iletim hattının 345 kV, 10000 MVA, 50 Hz'lik iletim hattıyla bağlantı yapılmıştır. AA iletim hattı kısımları temel frekans bileşenine (60 Hz veya 50 Hz' lik) 80°'lik gömülü L-R eşdeğer devresi ve üçüncü harmonik bileşenleri kullanılarak oluşturulmuştur. Doğrultucu ve evirici kısımlarında 12 kutuplu dönüştürücüler kullanılmaktadır. Dönüştürücüler iletim hattının her iki ucuna yerleştirilmiş 0.5 H düzeltme reaktörleri ve 300 km uzunluğa sahip DA iletim hattıyla birbirlerine bağlanmıştır. Dönüştürücü-Transformatörler (W_g, W_{ye}, Δ) üç faz transformatör blokları kullanılarak oluşturulmuştur. Kademe değiştirici dönüştürücü-transformatörlerin (doğrultucu tarafında 0.90, evirici tarafında ise 0.96) temel nominal gerilimine bir çarpım faktörü uygulanarak hesaplanmıştır.


AA kısmında bakıldığında ise, YGDA dönüştürücüler harmonik akım kaynağı olarak davranmaktadır. DA kısmından bakıldığında ise harmonik gerilim kaynağı olmaktadır. Buradaki karakteristik harmoniklerin sıralaması dönüştürücü konfigürasyonunda kullanılan p kutup sayısı ile alakalıdır (Alternatif akım için $n = kp \mp 1$ ve doğru gerilim için $n = kp$; k, herhangi bir katsayı). 12 kutuplu dönüştürücünün AA tarafa enjekte ettiği harmonikler 11, 13, 23, 25 ve DA kısmına ise 12, 24' tir. Tablo 5.1' de benzetim çalışmasında kullanılan DA iletim hattının özellikleri verilmiştir.

Tablo 5.1 Benzetim çalışmasında yer alan DA iletim hattının özellikleri

İletim Hattı	Özellik
Uzunluğu	300 km
Sınıfı	Dağıtılmış parametreli
Devre Yapısı	Seri RLC
Bağlantı Şekli	Tek faz-toprak
Düzeltilme Reaktörleri	0.5 H (2 Adet)
Birincil Gerilim	0.90 (doğrultucu tarafı) 0.96 (dönüştürücü tarafı)
Örnekleme Süresi	50×10^{-6} s
DA hat gerilimi	500 kV
DA hat akımı	2 kA
Arıza Direnci R_d	Ron (1 ohm)
Şebeke Frekansı	50 / 60 Hz
Çoğaltma Faktörü	1:100
Km başına düşen; Direnç İndüktans Kapasitans	0.015 ohm/km $0.792 \cdot 10^{-3}$ H/km $14.4 \cdot 10^{-9}$ F/km

AA filtreler harmonik akımların iletim hattı boyunca yayılmasını engellemek için kullanılmaktadır. Bu filtreler iki alt sistemde gruplandırılmaktadır. Aynı zamanda bu filtreler temel frekansa sahip büyük kapasitörler gibi davranarak, tetikleme açısı (α)' dan kaynaklanan doğrultucunun tükettiği reaktif güç kompanzasyonunu sağlamak için de kullanılmaktadır. Örneğin; ($\alpha = 30^\circ$) için dönüştürücünün reaktif güç ihtiyacı tam yükte iletilen gücün yaklaşık olarak % 60' ına karşılık gelmektedir. AA filtrelerin alt sistemlerinde 11. ve 13. harmonikler de yüksek Q(100) ayarlı filtreler ve düşük Q(3), veya gömülü filtreler ise yüksek mertebeden (örneğin 23. ve daha yukarı) harmoniklerin ortadan kaldırılması için kullanılmaktadır. Fazladan reaktif güç ihtiyacı aynı zamanda kapasitör banklarından sağlanmaktadır. Doğrultucunun hem AA kısmındaki hem de DA kısmındaki arızaların engellenebilmesi için iki adet kesici bulunmaktadır. Benzetim çalışmasında örnekleme süresi 5×10^{-5} sn olarak belirlenmiştir.

Doğrultucu ve evirici kısmın kontrol sistemi MATLAB kütüphanesinden elde edilen '12-pulse HVDC Control Blok' elemanları kullanılarak oluşturulmuştur. Bu kontrol blokları hem doğrultucu hem de dönüştürücü modunda çalışabilmektedir. Benzetim çalışmasında kullanılan kontrol bloklarının içerisinde tanımlanmış DA akım değerleri (I_{dR} ve I_{dI}) ve DA gerilim değerleri (V_{d_LR} ve V_{d_LI}) kontrollerde kullanılmadan önce birim değere çevrilmiştir. (Akım için 1 p.u.= 2 kA, gerilim için 1 p.u.= 500 kV). Şekil 5.1' de normal durumda doğrultucu ve evirici elemanların kararlı durum karakteristikleri verilmiştir.




Şekil 5.1 Doğrultucu ve evirici elemanlarının kararlı durum karakteristikleri

Benzetim çalışmasında bulunan bir diğer önemli kontrol fonksiyonu ise (VDAOL) olarak adlandırılan gerilime bağlı akım seviye sınırlandırma işlemidir. Bu kontrol sayesinde DA veya AA iletim hattında herhangi bir arıza meydana geldiğinde (VdL) değerinin düşmesi sonucunda referans akım değeri (I_{d_ref}) yeni bir noktaya taşır. Referans akım (I_{d_ref})' in düşmesi aynı zamanda AA iletim hattında ihtiyaç duyulan reaktif güç ihtiyacını da azaltmaktadır. Bu şekilde sistemi arıza durumundan en kısa sürede kurtarmak için yardımcı olmaktadır. VDOL kontrol fonksiyonunun karakteristiği Şekil 5.2' de verilmiştir.




57




Şekil 5.3 Benzetim çalışmasında kullanılan YGDA sistem ve ekipmanları

Benzetim çalışmasında kullanılan doğrultucu elemanın; akım, gerilim, alfa ve kontrol modu değerleri Şekil 5.4' te verilmiştir.



Şekil 5.4 YGDA sistemin doğrultucu elemanın başlangıçtaki akım, gerilim, alfa ve kontrol modu değerleri


Benzetim çalışmasında kullanılan evirici elemanın; akım, alfa, kontrol modu ve gama değerleri Şekil 5.5’ te verilmiştir.



Şekil 5.5 YGDA sistemin evirici elemanın başlangıçtaki akım, gerilim, alfa, kontrol modu ve gama değerleri

Benzetim çalışmasında, referans akım değeri sıfırdan 2 kA değerine başlangıçtan 0.4 saniye sonra ulaşmıştır. DA iletim hattının akım ve gerilim değerleri referans değerlere yaklaşık 0.5 saniye içerisinde ulaşmaktadır. Doğrultucu eleman akımı ve evirici eleman ise


gerilimi kontrol etmektedir. Sistem denge durumuna geldiğinde (α) tetikleme açısı doğrultucu tarafında 18° , evirici tarafında ise 142° ’ dir. Eviricideki gama ölçüm bloğu her bir 6 kutuplu tristör köprü için (γ) sönümleme açısını gözlemlemektedir. Denge durumunda gama ortalama değeri 24.5° ’ dir. Şekil 5.6 ve Şekil 5.7’ de DA iletim hattı üzerinde ve AA iletim hattı üzerinde 0.6-0.7 sn arasındaki gerçekleşen örnek tek faz-toprak arızaları gösterilmiştir.



Şekil 5.6 DA iletim hattının 50. km’sinde meydana gelen örnek tek faz-toprak arızası gerilim, akım, alfa R (doğrultucu kısım)

Benzetim çalışmasında, evirici ve doğrultucu ekipmanların her ikisinin de kontrol sistemleri Simulink/SimPowerSystems kütüphanesinde bulunan ‘Discrete HVDC Controller block’ kullanılarak oluşturulmuştur. Bu kontrol bloğu hem doğrultucu hem de evirici modunda çalışabilmektedir. Kontrol sistemi içerisinde bulunan alfa (α) değeri


regulator komutuyla tetiklenen gecikme açısıdır. Kontrol modu, dönüştürücünün kontrol modunun gerçek konumunu veya tetikleme darbesinin bir göstergesidir.



Şekil 5.7 DA iletim hattının 50. km’inde meydana gelen örnek tek faz-toprak arızası gerilim, akım, alfa ve arıza akımı (evirici kısım)

Gama (γ) kontrol, komutasyon hatalarını önlemek ve eviricide alfa (α) açısını sınırlandırmak gibi görevlerde kullanılmaktadır ($\gamma = \text{sönümlleme açısı} = 180^\circ - \alpha - \mu$, $\mu = \text{komutasyon açısı}$). Gama ortalama değeri, 12 kutuplu dönüştürücünün ölçülen (γ) sönümlleme açılarının ortalamasıdır. Diğer bir ifadeyle tek bir döngü içerisinde ölçülen son 12 sönümlleme açısının ortalamasıdır. Gama referans ise sönümlleme açısının başlangıçta belirlenen ve derece cinsinden olan değeridir. Reaktif güç tüketimini en düşük seviyede tutmak için benzetim çalışmasında 18° olarak belirlenmiştir.

Benzetim çalışmasından elde edilen örnek tek-faz toprak arızası DA iletim hattının 50. km' sinde (doğrultucu kısımdan bakıldığında) meydana gelmiş ve 0.1 saniye kadar devam etmiştir. Hattın akım değeri 2.3 pu' ya yükselirken gerilim seviyesi doğrultucuda sıfıra düşmüştür. Hattın akımı arıza süresi boyunca salınım yapmaya devam ederken ($t = 0.65$ sn) de doğrultucu tetikleme açısını (α) 165° getirilerek evirici moduna geçer. DA hattın gerilimi negatif olduğunda hatta depolanan enerji AA kısma geri dönerken arıza akımında çok hızlı bir sönümlleme meydana gelmektedir. Daha sonra (α) tetikleme açısının ($t = 0.7$ sn) de tekrar referans değerine dönmesiyle birlikte yaklaşık olarak 0.5 saniye içerisinde akım ve gerilim değerleri normal seviyesine geri döner. Şekil 5.8' de YGDA sistemin 15. km ve 285. km'sindeki arızanın akım ve gerilim değişimleri verilmiştir.




Şekil 5.8 YGDA iletim hattının 15. ve 285. km'lerindeki tek faz-toprak arızanın akım ve gerilim değişimleri


Benzetim çalışmasında arıza akım ve gerilim değerleri her 1 km' de kaydedilmiştir. Bu elde edilen akım ve gerilim sinyallerinin ayrıştırma ve özellik çıkartma aşamalarından sonra Bölüm 6' da bahsedildiği üzere YSA, LS-SVM, ELM gibi farklı makine öğrenme yöntemleri kullanılarak gerçek arıza km'sini ne kadar doğrulukla tespit ettiğine karar verilecektir.

5.1. Dalgacık Dönüşümü ile Özellik Çıkarımı

ADD yöntemi, sinyal boyunca ayırık katsayılarla ötelenen ve ölçeklenen bir dalgacık yardımıyla sinyale ait yüksek frekans bileşenlerini tespit edebilmektedir. ADD ile analiz yapılırken orijinal sinyal ilk olarak yüksek ve düşük geçişli süzgeçten geçirilir ve bu çıkış verileri ayrıştırılarak yaklaşık ve detay katsayıları elde edilir. Daha sonra yaklaşık katsayılar, bir önceki seviyede uygulanan işlemlerin tekrarlanabilmesi için ikinci seviyeye gönderilir. Bu işlem basamakları istenen ayrıştırma seviyesine kadar aynı şekilde devam ettirilir. Şekil 5.9 ve 5.10' da 15. km' de kaydedilen arıza akım ve gerilim sinyallerinin ADD' lerin ilk beş seviyesi gösterilmiştir.



Şekil 5.9 15.km'deki arıza akım sinyalinin ADD' sinin ilk 5 seviyesi



Şekil 5.10 15.km'deki arıza gerilim sinyalinin ADD' sinin ilk 5 seviyesi

ADD yöntemi kullanılırken kullanılan örnekleme frekansının yüksek olması sinyali hakkında daha detaylı bilgi verirken, ayrıştırma seviyesinin de artmasına neden olmaktadır. Bu durum ise büyük bir hesaplama yükü doğururken aynı zamanda sınıflandırıcılar için kullanılacak giriş verisinin artmasına da neden olmaktadır.

Bu tez çalışmasında kullanılan akım ve gerilim sinyallerine ADD yöntemi uygulanmış ve 12 detay ve 1 yaklaşık katsayı olmak üzere toplamda 13 özellik vektörü elde edilmiştir. Güç sistemlerinde arıza tespiti, yer tahmini ve sınıflandırma gibi alanlarda yaygın olarak kullanılan Daubechies (db4) dalgacık ailesi kullanılmıştır. Örnekleme frekansı 20 kHz' dir.

Benzetim çalışmasından elde edilen arıza sinyallerinin ADD analizi arıza başladıktan sonraki ilk 20 ms' lik kısımdır. Bu aralık ise akım ve gerilim sinyallerinin veri kümesinin [14000 – 14400] arasındaki verilerini kapsamaktadır. Şekil 5.9 ve Şekil 5.10' da ADD analizin ilk 5 seviyesi gösterilmiştir fakat ayrıştırma seviyesi 12 olarak belirlenmiştir.

ADD yönteminden elde edilen özellikler Bölüm 6' da bahsedilen YSA, LS-SVM, ELM gibi farklı sınıflandırıcılarda kullanılmıştır. Bu haliyle veri seti çok büyük olduğundan özelliklerde hiçbir değişiklik olamayacak şekilde veri kümelerinin daha küçük boyutlara indirgenmesi sağlanmıştır. Bunun için dalgacık dönüşümü katsayılarının Shannon entropi değerleri hesaplanmıştır. 12. Seviyedeki yaklaşık katsayılar düşük frekanslı bileşenler içerdiği için ayırt edici bir özellik olarak değerlendirilmemiş ve veri setinden çıkarılmıştır. Böylece her bir km'deki arıza noktası için akım ve gerilim değerlerinden toplamda 22 özellik elde edilmiştir.

5.2. Stockwell Dönüşümü ile Özellik Çıkarımı


S-dönüşümü, SDD ve KZFD yöntemlerinden faydalanılarak oluşturulmuş bir zaman-frekans analiz yöntemidir. S-dönüşümünde kullanılan Gauss penceresinin genişliği ve frekans aralığı arasındaki ters orantı sayesinde en uygun frekans çözünürlüğü elde edilebilmektedir. S-dönüşümünden elde edilen $k \times n$ boyutundaki matrisin satırları frekans bilgilerini, sütunları ise zaman bilgilerini içermektedir. S matrisinin tüm bileşenleri kompleks değerlerden oluşmaktadır. DD yaklaşımından farklı olarak, bu yöntemde

doğrudan Fourier dönüşümünden elde edilen kompleks spektrum değerlerini zaman eksenine dikey bölgesel spektral alan çizgileri olarak paylaşmaktadır.

Benzetim çalışmasından elde edilen arıza akım ve gerilim sinyallerine S-dönüşümü uygulanmış ve zaman-frekans, zaman-maksimum büyüklük, zaman-frekans eşyükselti gibi farklı gösterimler elde edilmiştir. Bölüm 5.1’ de bahsedilen ADD analiz yönteminde olduğu gibi arıza başladıktan sonraki ilk 20 ms’ lik kısma S-dönüşümü uygulanmıştır. Arıza sinyalinin tümünün analizinin yapılamamasının nedenlerinden bir tanesi analiz sonrasında elde edilen S matrisin boyutlarının çok büyük olmasıdır. S-dönüşümünün dezavantajlarından biri olarak da değerlendirilebilecek bu durum, tüm sinyalin analizine imkan verecek büyüklükte karmaşık değerleri ve genliklerini $k \times n$ boyutundaki matrise yerleştirememesine neden olmaktadır. Örnekleme süresi 5×10^{-5} sn olarak belirlenmiştir.


S-dönüşümünden elde edilen her bir arıza sinyali için standart sapma, enerji, entropi ve ortalama maksimum büyüklük değerleri hesaplanmıştır. Böylelikle her bir arıza durumu için toplamda arıza akım ve gerilim değerlerinden 8 ayırt edici özellik belirlenmiştir. Bu özellikler ise YSA, LS-SVM, ELM gibi farklı makine öğrenme yöntemlerinin eğitimi ve test aşamasında kullanılacaktır.

Şekil 5.11’de 5 periyot, 20 dB’ lik gürültü eklenmiş örnek bir sinüs dalgasının S-dönüşümü gösterilmiştir.




Şekil 5.11 Gürültü eklenmiş örnek bir sinüs dalgasının S-dönüşümü

Şekil 5.12 ve Şekil 5.13’ te 15.km’ de kaydedilen arıza gerilim ve akım sinyallerinin S-dönüşümleri verilmiştir.




Şekil 5.12 15.km'ye ait arıza gerilim sinyalinin S-dönüşümü




Şekil 5.13 15.km' ye ait arıza akım sinyalinin S-dönüşümü

Şekil 5.14 ve Şekil 5.15'te 285.km' de kaydedilen arıza akım ve gerilim sinyallerinin S dönüşümleri verilmiştir.



Şekil 5.14 285. km'ye ait arıza gerilim sinyalinin S-dönüşümü



Şekil 5.15 285.km'ye ait arıza akım sinyalinin S-dönüşümü


5.3. Hilbert-Huang Dönüşümü ile Özellik Çıkarımı

HHD analizi yönteminde arıza sinyalleri ilk olarak DMA yöntemi kullanılarak IMF'lerine ayrıştırılmış, daha sonra ise HSA kullanılarak anlık frekans ve büyüklük değerleri elde edilmiştir. HHD yöntemi ADD yönteminden farklı olarak sinyallerin IMF'lerini zaman bölgesinde incelediği için zaman bölgesi üzerinde yer alan sinyal verilerinin tümünü kullanmaktadır.

HHD yönteminden elde edilen DMA' lar, ADD yöntemine benzer şekilde düşük frekans ve yüksek frekans bileşenlerini içeren en uygun IMF'ler elde edilinceye kadar devam etmektedir ($DMA = IMF1 + IMF2 + IMF3 + \dots$). Her bir IMF' nin elde edilmesi için 10 iterasyon basamağı kullanılmış ve analizi yapılan sinyalin trende girmesi halinde HHD yöntemi otomatik olarak analizi bitirmiştir. HHD' nin örnekleme süresi benzetim çalışmasında da olduğu gibi 5×10^{-5} sn olarak belirlenmiştir. HHD sinyal analizinin toplam süresi 1.6 sn' dir.


HHD yöntemi, Bölüm 3.3' de ayrıntılı bir şekilde bahsedildiği üzere belirli şartların sağlanması durumunda DMA' ların elde edilmesine imkan sağlamaktadır. Bunlar ise genel olarak; IMF'lerin ortalamalarının 0 olması ve DMA' ların maksimum, minimum ve sıfır geçişlerin sayısının birbirine eşit olmasıdır. DMA işleminin gerçekleşmesini sağlayan bu şartlar, analizi yapılan sinyalin başlangıç ve bitiş kısmında herhangi bir maksimum veya minimum noktasından bahsedilemeyeceği için bazı problemlere yol açabilmektedir. Uç etkisi olarak da bilinen bu hata, IMF'lerin başlangıç ve bitiş noktalarındaki dalga şekillerinde bozulmalara neden olmaktadır. Bu problemleri ortadan kaldırmak için ise karakteristik dalga genişletme, aynalama, veri çoğaltma ve benzerlik araştırma gibi farklı yaklaşımlar kullanılmaktadır [66].


HHD analiz yönteminden elde edilen IMF sayıları her bir arıza akım ve gerilim sinyali için aynı değildir. Bundan dolayı 12. seviyeye kadar IMF' lerin elde edilmesine karşılık arıza tahmini aşamasında kullanılacak olan IMF sayısı tüm sinyalleri kapsayacak şekilde ilk 3 IMF olarak belirlenmiştir. Şekil 5.16'de 15. km' deki arıza gerilim sinyalinin HHD analizinin IMF'lerinin ilk 5 seviyesi gösterilmiştir.



Şekil 5.16 15.km’ deki gerilim sinyalinin HHD analizinden elde edilen ilk 5 IMF


15.km’ deki arıza gerilim sinyalinin Şekil 5.17’ de HHD analizinden elde edilen IMF’lerin büyüklük ve frekans değişimleri gösterilmiştir.





Şekil 5.17 Arıza gerilim sinyalinin HHD analizinden elde edilen ilk 4 IMF'nin büyüklük ve frekans değişimleri

Şekil 5.18'de 15. km' deki arıza akım sinyalinin HHD analizinin IMF'lerinin ilk 5 seviyesi gösterilmiştir.




Şekil 5.18 15.km' deki arıza akım sinyalinin HHD analizinden elde edilen ilk 5 IMF


HHD yönteminden elde edilen IMF'lerde sinyalin büyüklüğü anlık frekans bileşenlerine kıyasla arıza hakkında daha belirgin özellikler taşımaktadır. HHD yöntemi diğer yöntemlerle karşılaştırıldığında doğrusal ve durağan olmayan verilerin zaman-frekans gösterimi için oldukça üstün özelliklere sahiptir. HHD yöntemi adaptif özellikler taşır ve frekans bileşenleri Hilbert dönüşümü kullanılarak elde edilir. Ayrıca HHD yöntemi doğrusal olmayan sistemlerin gösteriminde dalgacık temelli yöntemlerde olduğu gibi yapay harmoniklere ihtiyaç duymaz. Tablo 5.2' de HHD dönüşümünün Fourier ve dalgacık dönüşümü yöntemleri ile karşılaştırması verilmiştir.

Tablo 5.2 Fourier dönüşümü, dalgacık dönüşümü ve Hilbert-Huang dönüşümü yöntemlerinin karşılaştırması

	Fourier dönüşümü	Dalgacık dönüşümü	Hilbert-Huang dönüşümü
Temeli	A priori	A priori	Adaptif
Frekans	Global-belirsiz	Bölgesel-belirsiz	Yerel-belirli
Gösterim	Enerji-frekans	Enerji-zaman-frekans	Enerji-zaman-frekans
Doğrusal olmayan	Yok	Yok	Var
Durağan olmayan	Yok	Var	Var
Özellik çıkarımı	Yok	Ayrık: Yok Sürekli: Var	Var
Teorik temeli	Tamamen teorik	Tamamen teorik	Deneyisel



Şekil 5.19'da 15.km'deki arıza akım sinyalinin HHD analizinden elde edilen IMF'lerin büyüklük ve frekans değişimleri gösterilmiştir.





Şekil 5.19 Arıza akım sinyalinin HHD analizinden elde edilen ilk 4 IMF'nin büyüklük ve frekans değişimleri

Şekil 5.20' de 15.km' deki arıza akım ve gerilim sinyallerinin HSA' ları verilmiştir.



Şekil 5.20 15. km'ye ait arıza akım ve gerilim sinyallerinin Hilbert enerji spektrumları: (a) gerilim (b) akım

6. ARIZA YERİ TAHMİNİ

6.1. YSA ile Arıza Tespiti


Bölüm 5' te, arıza akım ve gerilim sinyalleri farklı sinyal işleme yöntemleri kullanılarak bileşenlerine ayrıştırılmıştır. S-dönüşümünden elde edilen verileri ifade

edebilecek akım ve gerilim için toplamda 8 özellik vektörü elde edilmiştir. Bu özellik vektörleri sırasıyla, standart sapma, enerji, entropi ve ortalama büyüklüktür. Özellik vektörleri içerisinde bahsedilen ortalama büyüklük, veri matrisinin her bir sütunun en büyük değerleri dikkate alınarak oluşturulmuş bir ortalamayı ifade etmektedir. Standart sapma, sinyalin enerjisi ve Shannon entropi ifadelerinin matematiksel ifadeleri ise denklem 6.1’ de verilmiştir.

$$\begin{aligned} \text{Standart Sapma : } \sigma &= \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \\ \text{Sinyalin enerjisi : } E &= \frac{1}{N} \sum_{i=1}^N x_i^2 \\ \text{Shannon entropi : } H(S) &= - \sum_{i=1}^n p_i \log_2 p_i \end{aligned} \quad (6.1)$$


Denklem 6.1’ de bahsedilen x_i , örnek sayısını, $\bar{x}$, tüm örneklerin aritmetik ortalamasını, p_i ise örneklerin (A, p) olasılık uzayındaki olma olasılığını ifade etmektedir.

S-dönüşümü sonrasında YSA, LS-SVM ve ELM yöntemlerinin eğitim, test ve doğrulama aşamalarında kullanılabilmesi için başlangıçtaki veri seti; %60 (eğitim), %20 (test), %20 (doğrulama) olacak şekilde paylaştırılmıştır. Bu çalışmada kullanılan YSA’ nın türü ileri beslemeli geri yayımlı tek katmanlı bir yapay sinir ağıdır. YSA’ nın oluşturulması aşamasında belirlenen aktivasyon fonksiyonu girişler için tanjant sigmoid, ara katmanda ise doğrusal olarak belirlenmiştir. Eğitim aşamasında ise literatürde sıklıkla kullanılan Levenberg-Marquardt eğitim algoritması tercih edilmiştir. Ara katman nöron sayısı ise yoğun deneme-yanılma işlemleri sonrasında S-dönüşümü için 20 olarak belirlenmiştir. Hata fonksiyonu olarak ortalama karesel hata (MSE) fonksiyonu kullanılmıştır. Şekil 6.1’ de S-dönüşümü-YSA uygulamasında kullanılan YSA’ nın yapısı gösterilmiştir.




Şekil 6.1 S-dönüşümü-YSA uygulamasında kullanılan YSA' nın yapısı

Eğitilen YSA' nın ara katmanda en uygun katsayıları bulabilmesi için ayarlanan diğer parametrelerden bazıları; iterasyon sayısı, maksimum hata değeri, minimum eğim düşümü vs.' dir. S-dönüşümü-YSA uygulamasında iterasyon sayısı 1000, maksimum hata değeri 100, minimum eğim düşümü ise 10^{-7} olarak belirlenmiştir. Eğitim aşamasında belirlenen bu sınır değerler göz önünde bulundurularak YSA'nın eğitimi gerçekleştirilmiştir. YSA'nın belirlenen sınır değerlerden herhangi bir tanesine ulaşması durumunda eğitim sonlanmıştır. Şekil 6.2 ve 6.3' te S-dönüşümü-YSA uygulamasının eğitimi sonrasında elde edilen regresyon ve ortalama karesel hata fonksiyonlarının program çıktıları verilmiştir.




Şekil 6.2 S-dönüşümü-YSA uygulaması regresyon değerlerinin program çıktısı



Şekil 6.3 S-dönüşümü-YSA uygulamasının ortalama karesel hata (mse) fonksiyonunun program çıktısı

Şekil 6.4' te S-dönüşümü-YSA uygulamasından elde edilen ağı test aşamasında tahmin ettiği km'ler ve gerçek km'ler verilmiştir.




Şekil 6.4 S-dönüşümü-YSA uygulamasının test aşamasından elde edilen gerçek ve tahmini km'ler

ADD-YSA uygulaması için arıza akım ve gerilim sinyallerine ilk aşamada Daubechies 4 (db4) ana dalgacığı kullanılarak 12 seviyeli ayrık dalgacık dönüşümü


yapılmıştır. Her bir arıza akım ve gerilim sinyali için arıza başladıktan sonraki ilk 20 ms'lik kısımdan elde edilen veriler kullanılarak 12 detay ve 1 yaklaşık katsayı olmak üzere toplamda 13 özellik vektörü elde edilmiştir. Fakat 12. seviyedeki detay katsayıları düşük frekanslı bileşenler içerdiği ve yaklaşık katsayılar ayırt edici özelliğe sahip olmadığı için veri setinden çıkarılmıştır. Akım ve gerilim sinyallerinin ADD sonrasında elde edilen veri matrisi boyutunun bu haliyle çok büyük olması ve hesaplama aşamasında karmaşıklığa neden olması gibi nedenlerden dolayı bu verileri ifade edebilecek başka özellikler türetilmiştir. Bu özellikler ise sırasıyla sinyalin enerjisi ve Shannon entropisidir. Denklem 6.1' de Shannon entropi ve sinyalin enerjisi ifadelerinin matematiksel eşitliklerinden bahsedilmiştir. Böylelikle toplamda her bir km'deki akım ve gerilim sinyalleri için $[22 \times 271]$ boyutlarında bir veri matrisi elde edilmiştir.

DD-YSA uygulamasında, S-dönüşümünde olduğu gibi veri matrisi; eğitim (% 60), test (% 20) ve doğrulama (% 20) olacak şekilde paylaştırılmıştır. Son durumda YSA' nın eğitimi için $[22 \times 163]$, test ve doğrulama aşamaları için ise $[22 \times 54]$ boyutlarında giriş veri matrisleri elde edilmiştir. Şekil 6.5' te ADD-YSA uygulamasında kullanılan ağı yapısı gösterilmiştir.




Şekil 6.5 ADD-YSA uygulamasında kullanılan YSA' nın yapısı

ADD-YSA uygulamasında kullanılan sinir ağı; ileri beslemeli-geri yayımlı ve tek katmanlıdır. S dönüşümü-YSA uygulamasında olduğu gibi ara katman nöron sayısı 20 olarak belirlenmiştir. Eğitim aşamasında ise Levenberg-Marquardt eğitim algoritması tercih edilmiştir. Hata fonksiyonu olarak ortalama karesel hata fonksiyonu kullanılmıştır. Şekil 6.6 ve 6.7' de ADD-YSA uygulamasının eğitimi sonrasında elde edilen regresyon ve ortalama karesel hata fonksiyonlarının program çıktıları verilmiştir.




Şekil 6.6 ADD-YSA uygulaması regresyon değerlerinin program çıktısı



Şekil 6.7 ADD dönüşümü-YSA uygulamasının ortalama karesel hata (mse) fonksiyonunun program çıktısı

Şekil 6.8’ de ADD-YSA uygulamasından elde edilen ağın test aşamasında tahmin ettiği km’ler ve gerçek km’ler verilmiştir.



Şekil 6.8 ADD-YSA uygulamasının test aşamasından elde edilen gerçek ve tahmini km'ler


HHD-YSA uygulamasında her bir akım ve gerilim sinyaline ait ilk 3 IMF'ye Hilbert dönüşümü uygulanarak anlık frekansların ortalaması, anlık genliklerin ortalaması, anlık frekansların standart sapması ve anlık genliklerin standart sapması kullanılarak her bir arıza için 24 özellik elde edilmiştir. Bu özelliklerin 12 tanesi akımdan, 12 tanesi de gerilim sinyallerinden elde edilmiştir. YSA' nın eğitiminde kullanılacak özellikler Tablo 6.1' de verilmiştir.

Tablo 6.1 HHD-YSA uygulamasında kullanılacak özellikler

	Arıza akım ve geriliminin ilk 3 IMF'sine ait özellik dağılımı		
Anlık frekansların ortalaması	F_1	F_2	F_3
Anlık genliklerin ortalaması	F_4	F_5	F_6
Anlık frekansların standart sapması	F_7	F_8	F_9
Anlık genliklerin standart sapması	F_{10}	F_{11}	F_{12}


HHD-YSA uygulamasında kullanılan sinir ağı, ADD ve S-dönüşümünde kullanılan sinir ağına benzer şekilde ileri beslemeli-geri yayımlı tek katmanlıdır. Eğitim aşamasında

kullanılan öğrenme algoritması Levenberg-Marquardt ve ara katmanda kullanılan nöron sayısı ise 17 olarak belirlenmiştir. Hata fonksiyonu olarak ortalama karesel hata (mse) kullanılmıştır. Transfer fonksiyonu giriş katmanı için tanjant sigmoid, çıkış katmanı için ise doğrusaldır. Şekil 6.9’ te HHD-YSA uygulamasında kullanılan ağın yapısı gösterilmiştir.




Şekil 6.9 HHD-YSA uygulamasında kullanılan YSA' nın yapısı

HHD-YSA uygulamasında, S-dönüşümünde ve ADD’ de olduğu gibi veri matrisi; eğitim (% 60), test (% 20) ve doğrulama (% 20) olacak şekilde paylaştırılmıştır. Son durumda YSA’ nın eğitimi için $[24 \times 163]$, test ve doğrulama aşamaları için ise $[24 \times 54]$ boyutlarında giriş veri matrisleri elde edilmiştir. Şekil 6.10 ve 6.11’ de HHD-YSA uygulamasının eğitimi sonrasında elde edilen regresyon ve ortalama karesel hata fonksiyonlarının program çıktıları verilmiştir.




Şekil 6.10 HHD-YSA uygulaması regresyon değerlerinin program çıktısı



Şekil 6.11 HHD dönüşümü-YSA uygulamasının ortalama karesel hata (mse) fonksiyonunun program çıktısı

Şekil 6.12’de HHD-YSA uygulamasından elde edilen ağın test aşamasında tahmin ettiği km’ler ve gerçek km’ler verilmiştir.



Şekil 6.12 HHD-YSA uygulamasının test aşamasından elde edilen gerçek ve tahmini km’ler

Eğitilen YSA' lar içerisinde gerçek km'lere en yakın değerleri veren seçenek ADD-YSA algoritmasıdır. İkinci olarak S-dönüşümü-YSA ve üçüncü olarak ise HHD-YSA algoritması gelmektedir. Bu sıralamayı etkileyen ve YSA' nın eğitim-test aşamalarında farklılıklara neden olan faktörlerden bazıları; en uygun ara katman nöron sayısı ve kullanılan özellik vektörlerinin YSA' nın eğitimi için yeterli ayırt edici özelliğe sahip olamamasıdır. HHD ve S-dönüşümü zaman-frekans bölgesinde anlık frekans ve büyüklük gibi parametreleri tanımlamada daha avantajlı olmasına rağmen, YSA' nın eğitimi aşamasında belirlenen özellik vektörlerinde ADD yöntemine kıyasla yeterli performansı gösterememiştir. Regresyon değerleri S-dönüşümü için ($R=0.99927$), ADD için ($R=0.99984$) ve HHD için ($R=0.99765$)' dir. Regresyon değerlerinin 1' e yakın olması sonuçların gerçek değerlerle çok iyi örtüştüğü anlamına gelirken, 0' a yakın olması sonuçların örtüşmediği anlamına gelmektedir.

S-dönüşümünün performansını etkileyen parametrelerden bazıları; analiz aşamasında sadece $g(t, \sigma)$ şeklinde bir Gauss penceresinin kullanılması, frekans analiz penceresinin Gauss penceresinin sadece yatay ve dikey yönde genişlemesine olanak sağlaması ve bu pencerenin zaman veya frekans bölgesinde isteğe göre ayarlanabilmesini sağlayacak herhangi bir parametrenin olmamasıdır. HHD' nin performansı etkileyen parametrelerden bazıları ise; uç etkisi, sinyalin trende girmesi ve her bir durum için aynı sayıda IMF' nin elde edilememesidir. Uç etkisi özellikle sinyalin başlangıç ve bitiş noktalarında kayda değer sapmalara neden olabilmektedir. Anlık frekans ve genlik değerlerindeki bu değişim IMF'lerden elde edilen özellikleri olumsuz yönde etkilemektedir. HHD-YSA uygulamasında sinyalin trende girmesi ve farklı IMF sayılarının elde edilmesi gibi dezavantajları ortadan kaldırmak için ilk 3 IMF' ye ait verilerden faydalanılmıştır, fakat yine de HHD-YSA uygulamasının performansını diğer yöntemlere kıyasla fazla artırmamıştır. Hata fonksiyonu olarak belirlenen ortalama karesel hata (mse) değerleri; S-dönüşümünde ($mse=33,80$), ADD yönteminde ($mse=4,64$) ve HHD için ($mse=253,44$) olarak hesaplanmıştır.

6.2. LS-SVM ile Arıza Tespiti

LS-SVM yöntemi standart DVM' nin yeniden düzenlenmiş halidir ve doğrusal Karush-Kuhn-Tucker (KKT) sistemlerden faydalanılarak oluşturulmuştur. LS-SVM

yönteminde bahsedilmesi gereken diğer bir parametre ise çekirdek fonksiyondur. Bu çalışmada LS-SVM' nin tahmin aşamasında kullanılan çekirdek fonksiyon radyal tabanlıdır. Radyal tabanlı fonksiyonun matematiksel ifadesi denklem 6.2' de verilmiştir.


$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}} \quad (6.2)$$

Denklem 6.2' de bahsedilen $K(x_i, x_j)$ parametresi çekirdek fonksiyonu, (x_i, x_j) eğitilen örnek çiftlerini, σ^2 (sigma) ise Gauss çekirdek fonksiyonun varyansını ifade etmektedir. LS-SVM' nin çıkış değerlerinden γ (gama) ifadesi ise düzenleme parametresidir. Düzenleme parametresi, eğitim hatası azaltma ve ayrıştırma yüzeyi hassasiyeti arasındaki uygunluğu denetlemektedir. Diğer bir ifadeyle çekirdek uzayda eğri uydurma işlemi için daha önceden tanımlanmış bir hata tolerans fonksiyonudur.


LS-SVM' nin eğitilen veri setleri 'leave-one-out' çapraz doğrulama yöntemi kullanılarak tekrar test edilmiştir. Bu yöntemin temelinde, her bir doğrulama döngüsü içerisinde belirli bir veri kümesi dışarıda bırakılarak model geriye kalan veri kümeleri ile doldurulur. Modelin performansı geriye kalan veri kümeleri üzerinden tahmin edilmektedir. Bu işlem basamağı her bir veri kümesi için tekrarlanır ve elde edilen birbirinden farklı performans değerlerinin ortalamaları hesaplanarak tüm modelin performansı hakkında bir sonuca ulaşılmaktadır.

LS-SVM uygulamasında veri setleri; eğitim (%60), test (%20) ve doğrulama (%20) olacak şekilde paylaştırılmıştır. Hata fonksiyonu olarak ortalama karesel hata (mse) kullanılmıştır. Bölüm 6.1' de ADD, HHD ve S-dönüşümü için belirlenen özellikler LS-SVM' nin eğitimi aşamasında da kullanılmıştır. S-dönüşümü-LS-SVM uygulaması için sinyalin enerjisi, Shannon entropisi, standart sapma ve maksimum büyüklüğü kullanılmıştır. ADD-LS-SVM uygulaması için 11 detay katsayısından elde edilen enerji ve Shannon entropi değerleri kullanılmıştır. HHD-LS-SVM uygulaması için ise ilk 3 IMF'den elde edilen anlık frekansların ortalaması-standart sapması ve anlık genliklerin ortalaması-standart sapması kullanılmıştır.

S-dönüşümü-LS-SVM uygulamasında eğitim veri setinin boyutu $[8 \times 163]$, test ve doğrulama veri setinin boyutu ise $[8 \times 54]$ olarak belirlenmiştir. Şekil 6.13’ te S-dönüşümü-LS-SVM uygulamasının eğitim ve test aşamalarında tahmin ettiği km’ ler verilmiştir.




(a)



(b)

Şekil 6.13 S-dönüşümü-LS-SVM uygulamasının (a) eğitim ve (b) test aşamalarında elde edilen tahmini km'ler


Şekil 6.14’ te S-dönüşümü-LS-SVM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı verilmiştir.




Şekil 6.14 S-dönüşümü-LS-SVM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı

S dönüşü-LS-SVM uygulamasından elde edilen regresyon değeri ($R=0,99942$)' dir. Başlangıçta sigma değeri ($\sigma^2 = 14,3179$) ve gama değeri ($\gamma = 2807,23$)' tür. LS-SVM' nin eğitim veri setinden elde edilen sigma değeri ($\sigma^2 = 59,4272$) ve gama düzenleme parametresi ise ($\gamma = 251444,198$)' dir.

ADD-LS-SVM uygulamasında eğitim veri setinin boyutu $[22 \times 163]$, test ve doğrulama veri setinin boyutu ise $[22 \times 54]$ olarak belirlenmiştir. Şekil 6.15' te ADD-LS-SVM uygulamasının eğitim ve test aşamalarında tahmin ettiği km' ler verilmiştir.




(a)




Şekil 6.15 ADD-LS-SVM uygulamasının (a) eğitim ve (b) test aşamalarında elde edilen tahmini km'ler

ADD-LS-SVM uygulamasından elde edilen regresyon değeri ($R=0,99968$)' dir. Başlangıçta sigma değeri ($\sigma^2 = 342,1249$) ve gama değeri ($\gamma = 4954,22$)' dir. LS-SVM' nin eğitim veri setinden elde edilen sigma değeri ($\sigma^2 = 623,385$) ve gama düzenleme parametresi ise ($\gamma = 244751,05$)' tir. Şekil 6.16' da ADD-LS-SVM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı verilmiştir.




Şekil 6.16 ADD-LS-SVM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı

HHD-LS-SVM uygulamasında eğitim veri setinin boyutu $[24 \times 163]$, test ve doğrulama veri setinin boyutu ise $[24 \times 54]$ olarak belirlenmiştir. Şekil 6.17 ve 6.18’de HHD-LS-SVM uygulamasının eğitim ve test aşamalarında tahmin ettiği km’ler verilmiştir.




Şekil 6.17 HHD-LS-SVM uygulamasının eğitimi aşamasında elde edilen tahmini km’ler



Şekil 6.18 HHD-LS-SVM uygulamasının test aşamasında elde edilen tahmini km'ler

Şekil 6.19’ da HHD-LS-SVM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı verilmiştir.



Şekil 6.19 HHD-LS-SVM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı

HHD-LS-SVM uygulamasından elde edilen regresyon değeri ($R=0,99749$)' dur. Başlangıçta sigma değeri ($\sigma^2 = 83,1795$) ve gama değeri ($\gamma = 411,4363$)' tür. LS-SVM' nin eğitim veri setinden elde edilen sigma değeri ($\sigma^2 = 84,7539$) ve gama düzenleme parametresi ise ($\gamma = 930,088$)' dir.

LS-SVM' nin test aşamasında tahmin ettiği km' ler ve gerçek km'ler kullanılarak elde edilen ortalama karesel hata değerleri (mse); S-dönüşümü-LS-SVM uygulamasında (mse=7,59), ADD-LS-SVM uygulamasında (mse=5,04) ve HHD-LS-SVM uygulamasında (mse=29,61) olarak hesaplanmıştır. En düşük ortalama karesel hata ADD-LS-SVM uygulamasından elde edilirken, en yüksek değer HHD-LS-SVM uygulanmasında gözlemlenmiştir.

Eğitilen LS-SVM'ler içerisinde ADD-LS-SVM yöntemi en iyi performansı gösteren algoritma olmuştur. ADD-LS-SVM uygulamasından elde edilen regresyon değeri ($R= 0,99968$)' dir. S-dönüşümü-LS-SVM uygulamasında regresyon değeri ($R=0,99942$) ve HHD-LS-SVM uygulamasında ise ($R=0,99749$) olarak hesaplanmıştır. Burada bahsedilmesi gereken diğer bir nokta ise LS-SVM yöntemi YSA yöntemine kıyasla tüm sinyal analiz yöntemlerinde en iyi performansı göstermiştir.

Sınıflandırma ve fonksiyon tahmini aşamasında LS-SVM yöntemi YSA yöntemine kıyasla bazı avantajlara sahiptir. Bunlardan birincisi YSA' da karşılaşılan lokal minimum noktalarına takılma gibi problemlerin LS-SVM yönteminde olmamasıdır. İkinci olarak ise LS-SVM yönteminde giriş ve özellik uzayının ilkel-ikincil gösteriminden faydalanılarak en uygun ayırıştırıcı yüzeyin özellik uzayının farklı boyutlarından elde edilebilmesidir. LS-SVM yöntemi bu sayede çözümlenmesi zor doğrusal olmayan sınıflandırma problemlerinin üstesinden gelebilmektedir. Son olarak LS-SVM yöntemi; standart DVM' ye kıyasla daha az sayıda destek vektörler kullanarak, Gauss süreci ve RKHS gibi farklı yaklaşımlardan faydalanarak standart DVM' nin sınıflandırma ve fonksiyon tahmini uygulamalarında daha iyi performansın elde edilmesine yardımcı olmaktadır.

6.3. ELM ile Arıza Tespiti

(Huang vd., 2006)'ın önerdiği ELM yöntemi, tek katmanlı ileri beslemeli sinir ağları arasında yeni bir yaklaşımdır. ELM yönteminde başlangıçta giriş katmanı ve ara katman arasında rastgele seçilen ağırlıklar ve eşik değerler, giriş katmanı ile çıkış katmanı arasındaki doğrusal bir ilişkiden faydalanılarak belirlenmektedir. ELM yöntemi geri yayılım algoritması kullanan sinir ağları yöntemlerine kıyasla daha kısa sürede daha az işlem basamağıyla işlem yapabilmektedir. Bölüm 4.3' te ELM yöntemi ve matematiksel denklemleri detaylı olarak bahsedilmiştir.

ELM' nin eğitiminde asıl amaç eğitim sürecindeki hatayı en aza indirmektedir. Fakat bu işlem aynı zamanda ELM' nin ezberlemesine neden olarak tahminleri olumsuz yönde etkiyebilmektedir. Bu çalışmada standart ELM yönteminin geliştirme kabiliyetini artırmak için formüle C şeklinde bir düzenleme katsayısının eklendiği bir yaklaşımda kullanılmıştır. Literatürde düzenlenmiş ELM (RELM) olarak bilinen bu yaklaşım standart ELM yöntemine kıyasla uygulamada daha verimli sonuçlar verebilmektedir. ELM ve RELM arasındaki temel fark, eğitim hatasını eş zamanlı olarak azaltmak ve düzenleme parametrelili çıkış ağırlıkları normunun olmasıdır. Denklem 6.3' te RELM yaklaşımının matematiksel gösterimi ve Denklem 6.4' te ise Lagrange karşılığı verilmiştir.

$$\min_{\beta} C\|e\|_2^2 + \|\beta\|_2^2, \quad (e = y - H\beta) \quad (6.3)$$


$$L(\beta, e, \lambda) = C\|e\|_2^2 + \|\beta\|_2^2 + \lambda^T(y - H\beta - e) \quad (6.4)$$

Denklem 6.3 ve 6.4' te bahsedilen $e = [e_1, e_2, \dots, e_N]^T$ eğitim hatasını, λ ise Lagrange çarpım vektörünü ifade etmektedir. Karush–Kuhn–Tucker (KKT) teoremine göre optimum şartlar denklem 6.5 ve 6.6' da gösterilmiştir.

$$\begin{cases} \frac{\partial L}{\partial \beta} = 0 \Rightarrow 2\beta - H^T\lambda = 0 \\ \frac{\partial L}{\partial e} = 0 \Rightarrow 2Ce - \lambda = 0 \\ \frac{\partial L}{\partial \lambda} = 0 \Rightarrow y - H\beta - e = 0 \end{cases} \quad (6.5)$$


$$\hat{\beta} = (H^TH + \frac{1}{C})^{-1}H^Ty \quad (6.6)$$

ELM yönteminde düzenleme parametresi 1×10^{-6} olarak belirlenmiştir. S-dönüşümü-ELM uygulamasında belirlenen eğitim matrisinin boyutu $[8 \times 163]$, test ve doğrulama aşamasında kullanılacak özellik matrisinin boyutu ise $[8 \times 54]$ olarak belirlenmiştir. S-dönüşümü-ELM uygulamasında kullanılan nöron sayısı ise ($n=101$) olarak belirlenmiştir. Şekil 6.20’de S-dönüşümü-ELM uygulamasının test aşamasından elde edilen regresyon değerinin program çıktısı gösterilmiştir.




Şekil 6.20 S-dönüşümü-ELM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı

Şekil 6.21’ de S-dönüşümü-RELM uygulamasının test aşamasından elde edilen regresyon değerinin program çıktısı verilmiştir.




Şekil 6.21 S-dönüşümü-RELM uygulamasının test aşamasından elde edilen regresyon fonksiyonunun program çıktısı

Şekil 6.22’ de S-dönüşümü-ELM ve RELM uygulamasının test aşamasından elde edilen gerçek ve tahmini km’ ler verilmiştir.




Şekil 6.22 S-dönüşümü-ELM ve RELM uygulamasının test aşamasından elde edilen gerçek ve tahmini km' ler

ADD-ELM uygulamasında belirlenen eğitim matrisinin boyutu $[22 \times 163]$, test ve doğrulama aşamasında kullanılacak özellik matrisinin boyutu ise $[22 \times 54]$ olarak belirlenmiştir. ADD-ELM uygulamasında kullanılan nöron sayısı ise ($n=100$) olarak belirlenmiştir. Şekil 6.23'te ADD-ELM ve RELM uygulamasının test aşamasından elde edilen regresyon değerinin program çıktısı gösterilmiştir.




Şekil 6.23 ADD-ELM ve RELM uygulamasından elde edilen regresyon fonksiyonunun program çıktısı

ADD-ELM ve RELM uygulamasının regresyon değerlerinin her ikisi de aynı çıkmıştır. ADD-(ELM-RELM) uygulamasından elde edilen regresyon değeri ise ($R=0.99432$)' dir. Şekil 6.24' te ADD-ELM ve RELM uygulamasının test aşamasından elde edilen gerçek ve tahmini km' ler verilmiştir.




Şekil 6.24 ADD-ELM ve RELM uygulamasının test aşamasından elde edilen gerçek ve tahmini km' ler

HHD-ELM uygulamasında belirlenen eğitim matrisinin boyutu $[24 \times 163]$, test ve doğrulama aşamasında kullanılacak özellik matrisinin boyutu ise $[24 \times 54]$ olarak belirlenmiştir. HHD-ELM uygulamasında kullanılan nöron sayısı ise ($n=900$) olarak belirlenmiştir. Şekil 6.25' te HHD-ELM ve RELM uygulamasının test aşamasından elde edilen gerçek ve tahmini km' ler verilmiştir.



Şekil 6.25 HHD-RELM uygulamasının test aşamasından elde edilen gerçek ve tahmini km' ler

Şekil 6.26’da HHD-RELM uygulamasının test aşamasından elde edilen regresyon değerinin program çıktısı gösterilmiştir.



Şekil 6.26 HHD-RELM uygulamasının test aşamasından elde edilen regresyon fonksiyonunun program çıktısı

ELM’ nin test aşamasında tahmin ettiği km’ ler ve gerçek km’ler kullanılarak elde edilen ortalama karesel hata değerleri (mse); S-dönüşümü-ELM uygulamasında (mse=75,72) ve RELM uygulamasında (mse=50,83), ADD-(ELM-RELM) uygulamasında (mse= 79,31) ve HHD-RELM uygulamasında (mse= 42,01) olarak hesaplanmıştır. En düşük ortalama karesel hata HHD-RELM uygulamasından elde edilirken, en yüksek değer ADD-(ELM-RELM) uygulanmasında gözlemlenmiştir.

7. SONUÇLAR

Bu tez çalışmasında YGDA iletim hatlarında meydana gelen toprak arızaların yerini tahmin edebilecek farklı makine öğrenme ve sinyal işleme yöntemleri kullanılmış ve birbirleri arasındaki performans farklılıkları incelenmiştir. Sinyal işleme ve özellik çıkarımı aşamasında ADD, S-dönüşümü ve HHD yöntemi kullanılarak arıza akım ve gerilim sinyalleri bileşenlerine ayrıştırılmıştır. Arıza yeri tahmini aşamasında ise YSA, LS-SVM ve ELM yöntemleri kullanılmıştır.

Arıza sinyallerinin analizi ve özellik çıkarımı aşamasında; ADD yöntemi için sinyalin enerjisi ve Shannon entropisi, S-dönüşümü için standart sapma, enerji, entropi ve ortalama büyüklük, HHD için ise ilk 3 IMF'den elde edilen anlık frekansların ortalaması-standart sapması ve anlık genliklerin ortalaması-standart sapması kullanılmıştır.

Tez çalışmasında kullanılan ADD yöntemi diğer sinyal işleme yöntemlerine kıyasla makine öğrenme yöntemlerinin eğitim ve test aşamalarında daha başarılı sonuçlar vermektedir. LS-SVM yöntemi her bir sinyal işleme yönteminde diğer yöntemlere kıyasla daha düşük ortalama karesel hata (mse) değerlerine sahiptir. Literatürde sıklıkla kullanılan ADD yönteminin YSA ve LS-SVM yöntemleri ile kombinasyonu gerçeğe en yakın km'leri tahmin etme aşamasında en iyi performansı vermektedir.

HHD ve S-dönüşümü, frekans-zaman bölgesinde sinyal bileşenlerini tanımlamada ADD yöntemiyle karşılaştırıldığında görsel olarak daha belirgin sonuçlar vermesine rağmen ELM ve YSA yöntemlerinin arıza tahmini aşamalarında yeterli performansı gösterememiştir. HHD' nin sinyal analiz aşamasında performansını etkileyen uç etkisi, sinyalin trende girmesi ve farklı sayıda IMF' nin elde edilmesi eğitimcilerin performansını olumsuz yönde etkileyen parametrelerin başında gelmektedir.

Arıza tahmini aşamasında, LS-SVM ve YSA yöntemleri daha doğru sonuçlar vermesine karşılık YSA' nın eğitim aşaması için daha fazla veriye ihtiyaç duyması ve işlem yükünün LS-SVM ve ELM yöntemlerine kıyasla fazla olması arıza tahminlerini olumsuz yönde etkileyebilmektedir.

8. TARTIŞMALAR

Bu yüksek lisans çalışmasında, YGDA iletim hatlarında meydana gelen tek faz-toprak arızaları Matlab programı üzerinde farklı sinyal işleme ve makine öğrenme yöntemleri kullanılarak incelenmiştir. Benzetim çalışmasından elde edilen arıza akım ve gerilim sinyalleri sadece DA iletim hattı üzerinde kaydedilmiş ve arıza direnci sabit kalmıştır.

İleriki çalışmalarda bu arızalar, alternatif akım hattının üzerinde oluşturulabilir ve farklı arıza dirençleri kullanılarak sinyal işleme ve makine öğrenme yöntemlerinin performansları incelenebilir. Bunların yanı sıra, farklı arıza şekilleri (faz-faz, iki faz-toprak v.s.) ve YGDA sistemlerde oldukça yaygın olan çift kutuplu bağlantılı GKD kullanan YGDA sistemler üzerinde de çalışmalar yapılabilir.

Bu çalışmada kullanılan YGDA sistemden elde edilen arıza akım ve gerilim sinyallerinde gerçek hayatta karşılaşılan gürültü, dış etkenler, komutasyon hataları vs. gibi dış etkenlerin olumsuz etkileşimleri bulunmamaktadır. Bu yüzden ileriki çalışmalarda farklı dış etkenlere maruz kalmış arıza akım ve gerilim sinyallerinin makine öğrenme yöntemlerinin performansını nasıl etkilediği araştırılabilir. Ayrıca bu yöntemler son yıllarda yaygınlaşan çok terminalli YGDA istasyonlar ve hibrit DA iletim hatları gibi farklı şebeke uygulamaları üzerinde test edilebilir.

KAYNAKÇA

- [1] **Schweitzer, E. O., Guzman, A., Mynam, M. V., Skendzic, V., Kasztenny, B. and Marx, S.**, 2014. Locating faults by the traveling waves they launch, in *50th Annual Minnesota Power Systems Conference*, Brooklyn, Minnesota, USA, November 4-6, pp. 95–110.
- [2] **Abdel-salam, M., Ahmed, A. and Ahmed, W.**, 2013. Wavelet Based Analysis for Transmission Line Fault Location, *Innov. Syst. Des. Eng.*, vol. 4, no. 14, pp. 145–157.
- [3] **Liu, X., Osman, A. H. and Malik, O. P.**, 2007. Stationary wavelet transform based HVDC line protection, *39th North American Power Symposium, NAPS*, Las Cruces, New Mexico, USA, 30 Sept.-2 Oct. pp. 37–42.
- [4] **Zhang, S., Zhang, B. H., You, M. and Bo, Z. Q.**, 2010. Realization of the transient-based boundary protection for HVDC transmission lines based on high frequency energy criteria, in *2010 International Conference on Power System Technology: Technological Innovations Making Power Grid Smarter, POWERCON2010*, Hangzhou, China, 24-28 Oct., pp. 1–7.
- [5] **Yi-Ning, Z., Yong-Hao, L., Min, X. and Ze-Xiang, C.**, 2011. A novel algorithm for HVDC line fault location based on variant travelling wave speed, in *DRPT 2011 - 2011 4th International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, Weihai, Shandong, China, 6-9 July, pp. 1459–1463.
- [6] **Burek, A., Rezmer, J. and Sikorski, T.**, 2015. Evolutionary algorithm for detection and localization of faults in HVDC systems, in *Environment and Electrical Engineering (EEEIC)*, pp. 1317 – 1322.
- [7] **Liu, X., Osman, A. H., and Malik, O.P.**, 2009. Hybrid traveling wave/boundary protection for monopolar HVDC line, *IEEE Trans. Power Deliv.*, vol. 24, no. 2, pp. 569–578.
- [8] **GuoBing, S., XinLei, C., ShuPing, G., JiaLe, S., and Guang, L.**, 2011. Natural frequency based protection and fault location for VSC-HVDC transmission lines, *2011 International Conference on Advanced Power System Automation and Protection (APAP)*, Beijing, China, 16-20 Oct. vol. 1, pp. 177–182.
- [9] **Liu, J., Fan, C. J. and Tai, N. L.**, 2014. A novel pilot directional protection scheme

- for HVDC transmission line based on specific frequency current, in *POWERCON 2014 - 2014 International Conference on Power System Technology: Towards Green, Efficient and Smart Power System, Proceedings*, Chengdu, China, 20-22 Oct., pp. 976–982.
- [10] **Triveno, J. P., Dardengo, V. P. and Almeida, M. C. De**, 2015. An Approach to Fault Location in HVDC Lines Using Mathematical Morphology, in *2015 IEEE Power & Energy Society General Meeting*, Denver, CO, USA, 26-30 July, no. 1, pp. 1 – 5.
 - [11] **Livani, H. and Evrenosoglu, C. Y.**, 2014. A single-ended fault location method for segmented HVDC transmission line, *Electr. Power Syst. Res.*, vol. 107, pp. 190–198.
 - [12] **Cui, H. and Tu, N.**, 2015. Generalized Regression Neural Networks Based HVDC Transmission Line Fault Localization, in *2015 7th International Conference on Intelligent Human-Machine Systems and Cybernetics*, Hangzhou, China, 26-27 Aug., vol. 1, pp. 25–29.
 - [13] **Nanayakkara, K., Rajapakse, A. D. And Wachal, R.**, 2011. Fault Location in Extra Long HVDC Transmission Lines using Continuous Wavelet Transform, in *International Conference on Power Systems Transients (IPST 2011)*, Delft, Netherland, 14-17 June, no. 1, pp. 1–7.
 - [14] **Jovcic, D and Ahmed, K.**, 2015. *High-Voltage Direct-Current Transmission Converters, Systems and DC Grids*, Wiley, West Sunset.
 - [15] **Chan-Ki, K., Sood, V. K., Jang, G. S., Lim, S. J. and Lee, S. J.**, 2009. *HVDC Transmission: Power Conversion Applications in Power Systems*, Wiley-IEEE Press, Singapore.
 - [16] **Arrillaga, J.**, 2011. High Voltage Direct Current Transmission Lines, in *IET Power and Energy Series*, 2. Edition., vol. 29, The Institution of Engineering and Technology, London.
 - [17] **Okba, M. H., Saied, M. H., Mostafa, M. Z. and Abdel- Moneim, T. M.**, 2012. High Voltage Direct Current Transmission - A review, part I, in *2012 IEEE Energytech*, Cleveland, OH, USA, 29-31 May, pp. 1–7.
 - [18] **Mazzanti, G. and Marzotto, M.**, 2013. *Extruded Cables for High-Voltage Direct-Current Transmission: Advances in Research and Development*, IEEE Press-Wiley, Hoboken, New Jersey.

- [19] **Okba, M. H., Saied, M. H., Mostafa, M. Z. and Abdel-Moneim, T. M.,** 2012. High Voltage Direct Current Transmission-A Review, Part II-Converter Technologies, in *Energytech, 2012 IEEE*, Cleveland, OH, USA 29-31 May, pp. 1–7.
- [20] **Saha, M. M., Izykowski, J. and Rosolowski, E.,** 2010. *Fault Location on Power Networks*, Springer, Heidelberg, New York.
- [21] **Gürleroğlu, D.,** 2011. Enerji İletim Hatlarında Verim Artırımına Yönelik HVDC Sistemlerin İncelenmesi, Yüksek Lisans Tezi, Y.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.
- [22] **Abrol, R. and Mahajan, A.,** 2015. HVDC System Fault Analysis Through Wavelet Analysis Technique, *Int. J. Eng. Res. Technol.*, vol. 4, no. 05, pp. 326–329.
- [23] **Kunlun, H., Zexiang, C. and Yang, L.,** 2011. Study on protective performance of HVDC transmission line protection with different types of line fault, in *2011 4th International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT 2011)*, Weihai, Shandong, China, 6-9 July, pp. 358–361.
- [24] **Ekici, S.,** 2007. Elektrik Güç Sistemlerinde Akıllı Sistemler Yardımıyla Arıza Tipi ve Yerinin Belirlenmesi, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- [25] **Murthy, P. K., Amarnath, J., Kamakshiah, S. and Singh, B. P.,** 2008. Wavelet transform approach for detection and location of faults in HVDC system, in *IEEE Region 10 Colloquium and 3rd International Conference on Industrial and Information Systems, (ICIIS 2008)*, Kharagpur, India, 8-10 Dec., pp. 6–11.
- [26] **Burrus, C. S. and Gopinath, R. A.,** 1998. *Introduction to Wavelets and Wavelet Transformer: A Primer*, 1 edition, Prentice Hall, Upper Saddle River, New Jersey, USA.
- [27] **Vetterli, M. and Herley, C.,** 1992. Wavelets and Filter Banks: Theory and Design, *IEEE Trans. Signal Process.*, vol. 40, no. 9, pp. 2207–2232.
- [28] **Daubechies, I.,** 1992. *Ten Lectures on Wavelets*, vol. 61. Society for Industrial and Applied Mathematics, Philadelphia, Pennsylvania, USA.
- [29] **Pathak, R. S.,** 2009. *The Wavelet Transform*, Atlantis Press, Amsterdam-Paris, France.
- [30] **Zheng-you, H., Xiaoqing, C. and Guoming, L.,** 2006. Wavelet Entropy Measure Definition and Its Application for Transmission Line Fault Detection and

- Identification; (Part I: Definition and Methodology), in *2006 International Conference on Power System Technology*, Chongqing, China, 22-26 Oct, pp. 1–6.
- [31] **Shang, L., Herold, G., Jaeger, J., Krebs, R. and Kumar, A.**, 2001. High-speed fault identification and protection for HVDC line using wavelet technique, in *2001 IEEE Porto Power Tech Proceedings*, Porto, Portugal, 10-13 Sept., vol. 3, pp. 473–477.
- [32] **Zheng-you, H., Xhiaoqing, C. and Ling, F.**, 2006. Wavelet entropy measure definition and its application for transmission line fault detection and identification (part II: Fault detection in transmission line), *2006 Int. Conf. Power Syst. Technol. (POWERCON2006)*, Chongqing, China, 22-26 Oct., pp. 1–5.
- [33] **Stockwell, R. G., Mansinha, L. and Lowe, R. P.**, 1996. Localization of the complex spectrum: The S transform, *IEEE Trans. Signal Process.*, vol. 44, no. 4, pp. 998–1001.
- [34] **George, N. V.**, 2009. S transform: time frequency analysis & filtering, M. S., National Institute of Technology, Rourkela, India.
- [35] **Wang, Y. H.**, 2010. The Tutorial: S Transform, Graduate Institute of Communication Engineering, National Taiwan University, Taipei, Taiwan, <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.694.8727&rep=rep1&type=pdf>, Son Erişim tarihi: 24 Ağustos 2016.
- [36] **Srikanth, P., Chandel, A. K. and Naik, K. A.**, 2010. HVDC system fault identification using S-transform approach, in *International Conference on Power, Control and Embedded Systems (ICPCES 2010)*, Allahabad, India, 29 Nov.-1 Dec., no. 2, pp. 2–7.
- [37] **Pinnegar, C. R. and Mansinha, L.**, 2004. Time-local Fourier analysis with a scalable, phase-modulated analyzing function: The S-transform with a complex window, *Signal Processing*, vol. 84, no. 7, pp. 1167–1176.
- [38] **Yan, Y. and Zhu, H.**, 2011. The generalization of discrete Stockwell transforms, in *19th European Signal Processing Conference (EUSIPCO 2011)*, Barcelona, Spain, 29 Aug.-2 Sept., pp. 1209–1213.
- [39] **Huang, N. and Atttoh-Okine, N. O.**, 2005. *The Hilbert–Huang Transform in Engineering*, CRC Press, Taylor & Francis Group, New York.
- [40] **Huang, N. E. And Wu, Z.**, 2008. A REVIEW ON HILBERT-HUANG TRANSFORM: METHOD AND ITS APPLICATIONS TO GEOPHYSICAL

- STUDIES, *Reviews of Geophysics Journal*, vol. 46, pp. 1–23.
- [41] **Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., Yen, N., Tung, C. C. and Liu, H. H.**, 1998. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis, *Proc. R. Soc. A Math. Phys. Eng. Sci.*, vol. 454, no. 1971, pp. 903-995.
 - [42] **Huang, N. E., Wu, M.-L. C., Long, S. R., Shen, S. S. P., Qu, W., Gloersen, P. and Fan, K. L.**, 2003. A confidence limit for the empirical mode decomposition and Hilbert spectral analysis, *Proc. R. Soc. A Math. Phys. Eng. Sci.*, vol. 459, pp. 2317–2345.
 - [43] **Barnhart, B. L.**, 2011. The Hilbert-Huang Transform: theory, applications, development, PhD Thesis, University of Iowa, Iowa, USA.
 - [44] **Nandana, J., Murthy, P. K. and Durga, S.**, 2013. VSC - HVDC Transmission System Analysis Using Neural Networks, *Int. J. Eng. Sci. Innov. Technol.*, vol. 2, pp. 17–24.
 - [45] **Öztemel, E.**, 2012. *Yapay sinir ağları*, 3. Baskı, Papatya Yayıncılık Eğitim, İstanbul.
 - [46] **Routray, P., Mishra, M, Rout, P. K.**, 2015. High Impedance Fault Detection in Radial Distribution System Using S-Transform And Neural Network, in *2015 IEEE Power, Communication and Information Technology Conference (PCITC)*, Bhubaneswar, India, 15-17 Oct., pp. 545 – 551.
 - [47] **Etemadi, H, Sood, V. K., Khorasani, K., Patel, R. V.**, 2000. Neural Network Based Fault Diagnosis in an HVDC System, in *International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT 2000)*, London, UK, 4-7 April, pp. 209 – 214.
 - [48] **Zhang, N.**, 2006. Advanced Fault Diagnosis Techniques and Their Role in Preventing Cascading Blackouts, PhD Thesis, Texas A&M University, Texas, USA.
 - [49] **Mahanty, R. N. and Gupta, P. B. D.**, 2004. Application of RBF neural network to fault classification and location in transmission lines, *IEE Proceedings-Generation, Transmission*, vol. 151, pp. 201–212.
 - [50] **Fyfe, C.**, 2000. Artificial Neural Networks and Information Theory, Department of Computing and Information Systems, The University of Paisley, Scotland. <http://www.ece.rice.edu/~erzsebet/ANNcourse/handouts502/course-cf-1.pdf> , Son Erişim Tarihi: 24 Ağustos 2016.

- [51] **Kröse, B, Van Der Smagt, P.**, 1996. An introduction to neural networks, Eighth Edition. The University of Amsterdam. 134 p.
- [52] **Demuth, H., Beale, M.**, 2002. Neural Network Toolbox For Use with MATLAB, The Mathworks Inc.,
http://www.image.ece.ntua.gr/courses_static/nn/matlab/nnet.pdf. Son Erişim Tarihi: 24 Ağustos 2016.
- [53] **Vapnik, V. N.**, 2000. *The Nature of Statistical Learning Theory*, 2. Edition, Springer, New York.
- [54] **Vapnik, V. N.**, 1999. An overview of statistical learning theory, *IEEE Trans. Neural Netw.*, vol. 10, pp. 988–99.
- [55] **Ekici, S.**, 2012. Support Vector Machines for classification and locating faults on transmission lines, *Appl. Soft Comput. Journal*, vol. 12, pp. 1650–1658.
- [56] **Franc, V., Hlavac, V.**, 2004. Statistical Pattern Recognition Toolbox for Matlab User's guide, Research Reports of CMP, Czech Technical University, vol. 48, pp. 99, Prague, Czech Republic.
- [57] **Burges, C. J. C.**, 1998. A Tutorial on Support Vector Machines for Pattern Recognition, *Data Min. Knowl. Discov.*, vol. 2, no. 2, pp. 121–167.
- [58] **Smola, A. J., Schölkopf, B.**, 2004. A Tutorial on Support Vector Regression, *Stat. Comput.*, vol. 14, no. 3, pp. 199–222.
- [59] **Suykens, J. A. K., Van Gestel, T., Brabanter, J. De, Moor, B. De and Vandewalle, J.**, 2002. *Least Squares Support Vector Machines*, World Scientific Publishing, Singapore.
- [60] **Suykens, J. A. K.**, 2003. Least Squares Support Vector Machines Tutorial, <http://www.esat.kuleuven.be/sista/lssvmlab/>. Son Erişim Tarihi: 24 Ağustos 2016.
- [61] **Van Gestel, T., Suykens, J. and Baesens, B.**, 2004. Benchmarking least squares support vector machines, *Mach. Learn.*, vol. 54, pp. 5–32.
- [62] **Brabanter, K. De, Karsmakers, P., Ojeda, F., Alzate, C., Brabanter, J. De, Pelckmans, K., Moor, B. De, Vandewalle, Suykens, J. A. K.**, 2011. LS-SVMlab Toolbox User ' s Guide, ESAT-SISTA Technical Report 10-146, Department of Electrical Engineering, Leuven-Heverlee, Belgium.
<http://www.esat.kuleuven.be/sista/lssvmlab/> Son Erişim Tarihi: 24 Ağustos 2016.
- [63] **Huang, G. B., Zhu, Q., and Siew, C. K.**, 2004. Extreme learning machine: A new learning scheme of feedforward neural networks, in *International Joint Conference*

on Neural Networks (IJCNN2004), Budapest, Hungary, 25-29 July, vol. 2, pp. 985 – 990.

- [64] **Huang, G. B., Zhu, Q. Y., Siew, C. K.,** 2006. Extreme learning machine: Theory and applications, *Neurocomputing*, vol. 70, pp. 489–501.
- [65] **Huang, G. B., Zhou, H., Ding, X., and Zhang, R.,** 2012. Extreme learning machine for regression and multiclass classification, *IEEE Trans. Syst. man, Cybern. Part B, Cybern.*, vol. 42, pp. 513–29.
- [66] **Yang, G., Bin Sun, X., Zhang, M. X., Li, X. L. And Liu, X. R.,** 2014. Study on ways to restrain end effect of hilbert-huang transform, *Journal of Computers*, vol. 25, pp. 22–31.



ÖZGEÇMİŞ

Fatih ÜNAL

Fırat Üniversitesi

Teknoloji Fakültesi

Enerji Sistemleri Mühendisliği Bölümü

23119, Elazığ.

- 1990 Kahraman Maraş' ta doğdu.
- 2003-2007 Kayseri-Bünyan Anadolu Lisesinde orta öğretimini tamamladı.
- 2008-2013 Osmaniye Korkut Ata Üniversitesi- Mühendislik Fakültesi-Enerji Sistemleri Mühendisliği bölümünde lisans eğitimini tamamladı.
- 2015 Fırat Üniversitesi Teknoloji Fakültesi-Enerji Sistemleri Mühendisliği bölümünde Araştırma Görevlisi olarak atandı.
- 2013-2016 Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Enerji Sistemleri Mühendisliği Anabilim dalında 'Yüksek Gerilim Doğru Akım Enerji İletiminde Meydana Gelen Arızaların Sayısal Koruma Yöntemleri ile Belirlenmesi' konulu yüksek lisans çalışmasını tamamladı.