



**GÜÇ KALİTESİ OLAYLARININ MAKİNE ÖĞRENME
TEKNİKLERİ İLE SINIFLANDIRILMASI**

Ferhat UÇAR

Doktora Tezi
Elektrik Elektronik Mühendisliği Ana Bilim Dalı
Danışman: Dr. Öğr. Üyesi Fikret ATA
İkinci Danışman: Prof. Dr. Beşir DANDIL

Ağustos-2018

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

**GÜÇ KALİTESİ OLAYLARININ MAKİNE ÖĞRENME TEKNİKLERİ İLE
SINIFLANDIRILMASI**

DOKTORA TEZİ

Ferhat UÇAR

(122113201)

Tezin Enstitüye Verildiği Tarih : 03 Temmuz 2018

Tezin Savunulduğu Tarih : 03 Ağustos 2018

Danışman : Dr. Öğr. Üyesi Fikret ATA (B.Ü.)

İkinci Danışman : Prof. Dr. Beşir DANDIL (F.Ü.)

Diğer Jüri Üyeleri : Prof. Dr. Muhsin T. GENÇOĞLU (F.Ü.)

Prof. Dr. Sami EKİCİ (F.Ü.)

Prof. Dr. Ramazan BAYINDIR (G.Ü.)

Prof. Dr. Salih MAMİŞ (İ. Ü.)

Ağustos 2018

ÖNSÖZ

Tez çalışmamızın hazırlanması süreci ile sınırlı kalmayarak, kendisini tanıdığım ilk zamandan bu yana bilgi ve tecrübesini cömertçe paylaşan, kavramları titizlikle irdeleyişi ve akademik bakışı ile meslek anlayışımı oluşturmamda birçok kazanım sağladığım değerli danışman hocam *Sayın Dr. Öğr. Üyesi Fikret ATA*'ya gönülden teşekkürlerimi sunarım.

Bu tez çalışması ve tüm akademik yaşantım boyunca engin bilgi ve tecrübelerinden faydalandığım, üstün bakış açısına sahip, değerli fikirleri ve öngörüsü ile bana her zaman yol gösteren ve destek olan danışman hocam *Sayın Prof. Dr. Beşir DANDIL*'a sonsuz teşekkürlerimi sunarım.

Tez çalışması boyunca, her konuda bana destek olan ve yol gösteren, katkıları ile çalışmalarımızda önemli bir yeri olan değerli meslektaşım *Sayın Dr. Öğr. Üyesi Ömer Faruk ALÇİN*'e teşekkürü bir borç bilirim.

Tez çalışması sırasında sunduğu imkanlarla, daha huzurlu bir çalışma ortamında olmamı sağlayan *Sayın Prof. Dr. Hikmet ESEN*'e de teşekkürlerimi sunarım. Tez çalışmalarımız sırasında tanıştığımız ve değerli katkılarını esirgemeyen Florida State Üniversitesinden *Sayın Dr. Reza ARGHANDEH*'e çok teşekkür ederim. Çalışmanın L^AT_EX ile yazılmasında verdiği desteklerden dolayı arkadaşlarım *Arş. Gör. M. Rıza SARAÇ*'a ve *Öğr. Gör. Dr. Yaman AKBULUT*'a da teşekkürlerimi sunarım.

Tezde kullandığımız veriyi elde etme sürecinde yardımcı olan, TEİAŞ Genel Müdürlükten başlayarak *Sayın Bilgehan TEKŞUT*'a, Güç Kalitesi İzleme Merkezi ekibinin değerli mühendisleri *Sayın Ertuğrul PARTAL*'a, *Sayın Cuma Ali MANTAŞ*'a, *Sayın Veli DURMUŞ*'a ve TEİAŞ Elazığ bölge müdürlüğünden sağladığı katkılarla Elk. Yük. Müh. *Sayın İsmail DAĞHAN*'a teşekkürlerimi sunarım.

Meslek hayatımın her anında yanımda olan ve burada tek tek ismini anamadığım sevgili dostlarıma ve yükümü hafifleten çalışma arkadaşlarıma da teşekkürlerimi sunarım. Zor günlerimde yanımda olan ve tez yazım sürecinin bir kısmında bana ofisinin kapılarını açan kardeşim *Sayın Av. Şehmus AÇIKGÖZ*'e ve ailesine de en içten teşekkürlerimi sunarım.

Tez çalışması süresince kullanılan donanımların temini konusunda maddi desteği elde ettiğimiz ve bu tezle birlikte tamamlanan *FÜBAP TEKF 16.18* doktora tezi araştırma projesi boyunca yardımlarını esirgemeyen FÜBAP birimine teşekkür ederim.

Tezimi, çalışmalarım boyunca hızlanan hayatımda bana katlanan, gül yüzleri ile pozitif enerjilerini yansıtarak bu süreci kolaylaştıran, yanımda kalan biricik Eşim *Sultan AÇIKGÖZ UÇAR* ve değerli oğlum *Muhammed Mustafa UÇAR* başta olmak üzere sevgili ailem ve yetişmemde büyük emekleri olan biricik dedem *Sami ÖZDEN* ile yakın zamanda Hakk'ın rahmetine kavuşan sevgili anneannem *Durdane ÖZDEN*'e ithaf ederim.

Ferhat UÇAR
ELAZIĞ - 2018

İÇİNDEKİLER

Sayfa No

ÖNSÖZ	II
İÇİNDEKİLER	IV
ÖZET	V
SUMMARY	VI
ŞEKİLLER LİSTESİ	VIII
TABLolar LİSTESİ.....	IX
KISALTMALAR LİSTESİ	X
1. GİRİŞ	1
1.1 Literatür Özeti	6
1.2 Problem Tanımı ve Amaç	12
1.3 Tezin Katkısı	14
1.4 Tezin Yapısı ve Organizasyonu	15
2. GÜÇ KALİTESİ OLAY TANIMLARI.....	17
2.1 Güç Kalitesi Kavramı	17
2.2 Güç Kalitesi Bozulma Olayları	19
2.2.1 Gerilim Çukuru	20
2.2.2 Gerilim Tepesi.....	24
2.2.3 Gerilim Kesintisi	26
2.2.4 Harmonikler	28
2.2.5 Gerilim Kırpışmaları	30
2.3 Düşük Güç Kalitesi ve Sahada Ortaya Koyduğu Olumsuz Etkiler	32
3. GÜÇ KALİTESİ OLAYLARI VERİ SETİ.....	36
3.1 Olay Üretici Benzetim Modeli ile Oluşturulan Yapay Veriler	36
3.2 Türkiye İletim Hattı Olay Verileri.....	39
3.2.1 Türkiye Elektrik İletim Sistemi	39
3.2.2 TEİAŞ Güç Kalitesi İzleme Merkezi Gerçek Veri Seti	42
4. AKILLI ÖRÜNTÜ TANIMA METODOLOJİSİ	55
4.1 Öznitelik Çıkarımı	56
4.1.1 Ayırık Dalgacık Dönüşümü.....	57
4.1.2 İstatistiksel Verilere Dayalı Öznitelikler	68
4.1.3 Histogram.....	70
4.1.4 Permütasyon Entropi.....	71
4.1.5 Yerel Tepe Noktaları	73
4.1.6 Anlık Zaman Bölgesi Öznitelikleri	74
4.1.7 Fisher Vektör Kodlama	77
4.2 Akıllı Sınıflandırıcı Yapıları.....	81
4.2.1 Uç Öğrenme Makinesi (ELM)	84
4.2.2 Seyrek Bayes Tabanlı Uç Öğrenme Makinesi (SB-ELM)	87
4.2.3 Ağırlıklandırılmış Uç Öğrenme Makinesi (W-ELM).....	93

5. BULGULAR ve İNCELEME	96
5.1 Güç Kalitesi Olaylarına ait Özniteliklerin Analizi.....	96
5.1.1 Ayırık Dalgacık Öznitelik Seti	97
5.1.2 Temel İstatistik Parametreleri Öznitelik Seti	105
5.1.3 Histogram Öznitelik Seti.....	107
5.1.4 Permütasyon Entropi Öznitelik seti	109
5.1.5 Anlık Zaman Bölgesi Öznitelik Seti	111
5.2 Önerilen Modelde Uygulanan Değerlendirme Yöntemi ve Ölçütleri.....	112
5.3 Deneysel Sonuçlar	117
5.3.1 Değerlendirme Senaryoları	118
5.3.2 ELM Yönteminden Elde Edilen Bulgular.....	120
5.3.3 SB-ELM Yönteminden Elde Edilen Bulgular.....	125
5.3.4 W-ELM Yönteminden Elde Edilen Bulgular	131
5.3.5 Model Başarım Karşılaştırmaları	136
6. TARTIŞMA VE SONUÇ	140
KAYNAKLAR.....	147
ÖZGEÇMİŞ	155

ÖZET

Endüstri sektörü ve yaşam alanları elektrik enerjisinden verimli bir şekilde faydalanmalıdır. Bu amaçla, güç sistemi gerilim ve akım işaretlerinin üst düzey bir şekilde işlendiği ve izlendiği akıllı şebeke kavramı geliştirilmiştir. Böylece, denetleme sistemleri şebekenin hem normal hem de arıza koşulları altında sürdürülebilir şekilde işletilmesini sağlayacak hale gelmektedir.

Günümüz endüstriyel ortamı, endüstri 4.0 kavramının da tartışılıyor olması ile birlikte, geçmişte hiç olmadığı kadar “akıllı” bir hale gelmiştir. Birçok üretim hattı, aralarında haberleşebilen motor sürücüler ve tek noktadan denetlenebilen diğer elektrikli cihazlar bütünü içermektedir. Bu bileşenlerin bir çoğu endüstriyel internet olarak da adlandırılan bir internet köprüsü ile birbirlerine bağlı ve iletişim içinde çalışmaktadır. Endüstriyel internet kullanımı ile birlikte daha da gelişen akıllı teknoloji, “izleme” (monitoring) sistemlerine duyulan ihtiyacı da beraberinde getirmektedir. Son derece ihtiyaç duyulan ve gelişen bir teknoloji olarak karşımıza çıkan bu izleme sistemleri, arıza tespiti, şebekenin kendini iyileştirmesi ve onarması ve güç kalitesi bozulmalarının çevrimiçi izlenmesi gibi önemli başlıklara çözüm getirmektedir.

Geniş çaplı ve karmaşık bir sistem olarak elektrik şebekesi, denetim merkezlerinde, şalt sahalarında, iletim ve dağıtım taraflarında çok çeşitli bileşenler içermektedir. Böylesine karmaşık bir sistemde, izleme süreçleri çok önemli bir rol oynamaktadır. Akıllı ölçüm birimleri, güç kalitesi bozulmalarının izlenmesi amacıyla şebekede dolaşan özellikle gerilim ve akım işaretlerine ait tüm bilgiyi toplamaktadır. Toplanan bu verilerin yorumlanması ile operatöre, teşhis ve önleme adımları atmasını sağlayacak gerekli bilgiler ulaştırılmaktadır. Bu tez çalışması, elektrik şebeke izleme sisteminin en temel kısımlarından birisi olan ve güç kalitesi olay sınıflandırma olarak adlandırılan alana, makine öğrenme perspektifini yansıtarak, bütüncül bir model önermektedir.

Bu çalışmada, güç kalitesi olay sınıflandırma gerçekleştiren bir akıllı örüntü tanıma sistemi tasarlanmıştır. Çalışmanın temel yapı taşı olan veri seti, Türkiye genelinde konumlanmış trafo merkezlerinden elde edilmiştir. Ham işaretlerden ayırt edici özniteliklerin elde edildiği, öznitelik çıkarım aşamasında Histogram, Permütasyon Entropi, Yerel Tepe Noktaları sayısı ve anlık zaman bölgesi öznitelikleri kullanılmıştır. Güç kalitesi literatüründe daha önce önerilmeyen bu yöntemlere ek olarak, yaygın olarak tercih edilen Ayrık Dalgacık Dönüşümü öznitelikleri ile de gürbüz bir giriş seti elde edilmiştir.

Karar aşamasında, makine öğrenme tabanlı Uç Öğrenme Makinesi ve onun geliştirilmiş versiyonları olan Seyrek Bayes Uç Öğrenme Makinesi ve Ağırlıklandırılmış Uç Öğrenme Makinesi kullanılmıştır. Öğrenmede geriye yayılım kullanan yöntemlerin aksine, döngüsel bir işleyiş içermeyen uç öğrenme makinesi ve geliştirilmiş versiyonları bir çok farklı alanda kullanılmaktadır. Tez sonucunda elde edilen bulgular detaylı olarak analiz edilmiş ve kapsamlı bir değerlendirme yöntemi kullanılarak, önerilen modeller farklı değerlendirme ölçütlerine göre yorumlanmıştır. Tüm analizler MATLAB programı kullanılarak gerçekleştirilmiştir. En iyi performans gösteren algoritma modeli, kapsamlı bir ürün olarak tezin çıktısını oluşturmaktadır.

Anahtar Kelimeler: Akıllı Şebeke, Güç Kalitesi, Güç Kalitesi Olayları, Uç Öğrenme Makinesi, Örüntü Tanıma.

SUMMARY

Classification of Power Quality Events using Machine Learning Methods

Industrial plants and residential areas need to utilize electrical energy effectively. For this purpose smart grids were performed within power system where voltage and current signals are processed and monitored in detail. Thus controller systems provide solutions that keep the grid sustainability in both faulty and normal conditions.

Today's industrial environment is smarter than ever before whilst Industry 4.0 is being globally approved. Most production lines include electrical devices which are able to communicate each other and controlled from a single station with automation systems. Most of those elements have an internet connection link known as industrial internet. Development of smart technology with industrial internet comes with a need of monitoring. Monitoring technologies are emergent systems that focus on fault detection, grid self – healings and online tracking of power quality issues.

As a comprehensive and complex system, electrical grid includes numerous components in control center, switchyards, transmissions and distribution modules. In a complex system, monitoring process has a great role. Smart measurement units collect all required data signals roaming in electrical grid which are especially voltage and current signals to monitor power quality issues. Using the collected data, all the required information to the operator is provided to specify a diagnosis and prevention abnormal operation. Present study deals with one of the essential part of an electricity grid monitoring system called power quality event classification in a manner of machine learning topic.

In this study, an intelligent pattern recognition system which performs classification of power quality events has been designed. The backbone of the study which is the dataset has been gathered from the substation centers all over the Turkey. In the feature extracting stage which builds a meaningful whole from the raw dataset, Histogram, Permutation Entropy, Local Peaks, and instantaneous time domain based techniques have been used. In addition to those techniques of feature extracting which are novel to power quality event classification field, commonly used Discrete Wavelet Transform features are determined to construct a robust feature set.

In decision stage, a machine learning based structure which is Extreme Learning machine and its enhanced versions Weighted Extreme Learning Machine and Sparse Bayesian Extreme Learning machine have been designed. Extreme learning machine and its enhanced versions are preferred in most of the research fields because of their learning structure which does not include any iterative process contrary of *back propagation learning* based methods. Findings of thesis are analyzed in detail and a comprehensive evaluation method is used with various performance criteria. All the analyzes are held in MATLAB environment. The algorithm of the best performance is proposed to build a generic product as an output for this thesis.

Key Words: Smart Grid, Power Quality, Power Quality Events, Extreme Learning Machine, Pattern Recognition.

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1	Güç kalitesi bozulmaları	19
Şekil 2.2	IEEE 1159 Standardının önerdiği genlik-süre düzleminde olaylar . . .	20
Şekil 2.3	Örnek bir çukur olayı	22
Şekil 2.4	Asenkron motor kalkışı 3 faz dalga şekilleri	23
Şekil 2.5	Asenkron motor kalkışı 3 faz rms değişimleri	23
Şekil 2.6	Örnek bir tepe olayı	25
Şekil 2.7	Örnek bir kesinti olayı	26
Şekil 2.8	Örnek bir uzun süreli kesinti olayı	27
Şekil 2.9	Örnek harmonik bileşenler	29
Şekil 2.10	Örnek bir gerilim kırpışması olayı	31
Şekil 2.11	Türkiye EDAS haritası	33
Şekil 2.12	Güç kalitesi problemlerinin türü ve görülme sıklıkları	34
Şekil 2.13	Kullanım dışı kalan trafo verileri	35
Şekil 3.1	Benzetim model: Örnek gerilim çukur olayı	38
Şekil 3.2	Benzetim model: Örnek gerilim tepe olayı	38
Şekil 3.3	Benzetim model: Örnek gerilim kesinti olayı	38
Şekil 3.4	Benzetim model: Örnek gerilim kırpışma olayı	39
Şekil 3.5	Türkiye kurulu güç değerinin yıllara göre değişimi	41
Şekil 3.6	Veri alınan trafo merkezleri	43
Şekil 3.7	GKO gerçek veri seti hazırlama blok şeması	45
Şekil 3.8	Segmentasyon akış şeması	47
Şekil 3.9	Çalışmada kullanılan segmentasyon algoritma özeti	49
Şekil 3.10	3 faz gerilimleri: 154 kV iletim hattında bir çukur olayı	50
Şekil 3.11	Örnek çukur olayına ait Faz-A gerilimi	51
Şekil 3.12	Çukur olayı detaylı görünüm	51
Şekil 3.13	Son halini alan veri setinden örnek çukur olayı	52
Şekil 3.14	Örnek bir tepe olayı (Gerçek veri son hali)	53
Şekil 3.15	Örnek bir kesinti olayı (Gerçek veri son hali)	53
Şekil 3.16	Örnek bir harmonik olayı (Gerçek veri son hali)	53
Şekil 4.1	Örüntü tanıma sistemi genel şeması	55
Şekil 4.2	Öznitelik çıkarım aşaması	57
Şekil 4.3	Dalgacık dönüşümü blok şeması	58
Şekil 4.4	dB4 Dalgacık ve ölçek fonksiyonu	59
Şekil 4.5	DWT tek seviye dönüşüm blok şeması	61
Şekil 4.6	DWT çok seviye dönüşüm blok şeması	62
Şekil 4.7	DWT MRA katsayı karşılaştırmaları (8. seviye)	63
Şekil 4.8	DWT MRA ayrıştırma seviyeleri	63
Şekil 4.9	Gerilim çukuru ve tepesine ait DWT Entropi değerleri	64
Şekil 4.10	Bozulma türlerine göre DWT enerji değerleri	65
Şekil 4.11	Örnek bozulma türlerine ait DWT STD detayları	66

Şekil 4.12	DWT MRA tabanlı D_{STD} hesabı blok şeması	67
Şekil 4.13	Örnek çukur ve tepe olaylarına ait DWT D_{STD} öznitelikleri	67
Şekil 4.14	Çarpıklık ve basıklık genel gösterimleri	69
Şekil 4.15	Olay verilerine ait histogram çubuk grafikleri	70
Şekil 4.16	Örnek bozulma olaylarına ait PE değerleri	73
Şekil 4.17	Örnek bir işarete ait yerel tepe noktaları	74
Şekil 4.18	Önerilen FV kodlama algoritma adımları	80
Şekil 4.19	Önerilen FV kodlamalı yöntemin blok şeması	80
Şekil 4.20	Çalışmada kullanılan sınıflandırıcı yapıları	81
Şekil 4.21	CRISP modeline ait süreç döngüsü	83
Şekil 4.22	Tek katmanlı ileri beslemeli ağ yapısı	84
Şekil 4.23	Önerilen W-ELM yöntemine ait algoritma	94
Şekil 5.1	DWT-MRA için örnek işaret: Normal sinüs	98
Şekil 5.2	DWT-MRA normal sinüs detaylar	98
Şekil 5.3	DWT-MRA için örnek işaret: Çukur	99
Şekil 5.4	DWT-MRA çukur olayı detaylar	99
Şekil 5.5	DWT-MRA için örnek işaret: Tepe	100
Şekil 5.6	DWT-MRA tepe olayı detaylar	100
Şekil 5.7	DWT-MRA için örnek işaret: Kesinti	101
Şekil 5.8	DWT-MRA kesinti olayı detaylar	101
Şekil 5.9	DWT-MRA için örnek işaret: Harmonik	102
Şekil 5.10	DWT-MRA harmonik olayı detaylar	102
Şekil 5.11	DWT-MRA delta standart sapma öznitelikleri	103
Şekil 5.12	DWT-MRA Entropi öznitelikleri	104
Şekil 5.13	DWT-MRA Enerji öznitelikleri	104
Şekil 5.14	DWT-MRA Yaklaşım iş. enerjisine ait öznitelikleri	105
Şekil 5.15	Istatistik-8: Çarpıklık öznitelikleri	106
Şekil 5.16	Istatistik-9: Basıklık öznitelikleri	107
Şekil 5.17	Histogram öznitelikleri	108
Şekil 5.18	Permütasyon Entropi öznitelikleri	110
Şekil 5.19	Yerel tepe noktaları öznitelikleri	110
Şekil 5.20	Anlık zaman bölgesi öznitelikleri	111
Şekil 5.21	5-kat çapraz geçерleme örnek anlatım	112
Şekil 5.22	Tez çalışmasında kullanılan değерlendirme yöntemi	113
Şekil 5.23	Örnek hata matrisi anlatımı	114
Şekil 5.24	Örnek hata matrisi: Çoklu sınıflandırma	116
Şekil 5.25	ELM Parametreler: Gizli katman nöron sayısı değışimi	121
Şekil 5.26	ELM hata matrisi: Senaryo-20	125
Şekil 5.27	SB-ELM hata matrisi: Senaryo-18	130
Şekil 5.28	WELM Parametreler: Gizli katman nöron sayısı değışimi	131
Şekil 5.29	W-ELM hata matrisi: FV1-TS senaryosu	135
Şekil 5.30	W-ELM eğitim seti örnek sayısının başarıma etkisi	137
Şekil 5.31	W-ELM, LSSVM ve ANN kutu grafiğı	138

TABLÖLAR LİSTESİ

Sayfa No

2.1	Gerilim çukur olayına ait özet bilgiler	24
2.2	Gerilim tepesi kategorileri (IEEE 1159–2009)	24
2.3	Gerilim tepesi olayına ait özet bilgiler	25
2.4	Gerilim kesintisi olayına ait özet bilgiler	28
2.5	Gerilim kırışması olayına ait özet bilgiler	32
3.1	GKO üreticine ait genel parametreler	37
3.2	İletim hattı uzunluklarındaki yıllara göre değişim	42
3.3	İndirilen olaylara ait bazı nitelik ve nicelikler	44
3.4	Gerçek veri setine ait önemli parametreler	48
4.1	İstatistiki özniteliklere ait detaylar	68
5.1	Olay Türleri ve Sınıf Kodları	96
5.2	DWT–MRA tabanlı öznitelik alt seti	97
5.3	İstatistik tabanlı öznitelik alt seti	106
5.4	Histogram öznitelik alt seti	107
5.5	Permütasyon Entropi ve Yerel Tepe öznitelikleri alt seti	109
5.6	Anlık Zaman Bölgesi öznitelik alt seti	111
5.7	Tam öznitelik setine ait detaylar	119
5.8	Deney senaryolarına ait detaylar	119
5.9	Deney senaryolarına ait detaylar: FV kodlama öznitelikler	120
5.10	ELM sınıflandırıcı parametreleri	121
5.11	ELM sınıflandırıcı yapısına ait genel başarımlar değerleri	122
5.12	ELM yönteminde sınıflara göre ortaya çıkan test başarımları	124
5.13	SB–ELM sınıflandırıcı parametreleri	126
5.14	SB–ELM sınıflandırıcı yapısına ait genel başarımlar değerleri	127
5.15	SB–ELM: Seçilen senaryolar için aktif nöron değerleri	128
5.16	SB–ELM yönteminde sınıflara göre ortaya çıkan test başarımları	129
5.17	W–ELM sınıflandırıcı parametreleri	131
5.18	W–ELM sınıflandırıcı yapısına ait genel başarımlar değerleri	132
5.19	W–ELM yönteminde sınıflara göre ortaya çıkan test başarımları	134
5.20	Deney sonuçlarına ait genel başarımlar tablosu	136
5.21	Genel sonuçlarda sınıflara göre ortaya çıkan test başarımları	136
5.22	Karşılaştırmalı başarımlar tablosu	139

KISALTMALAR LİSTESİ

ANN	: Artificial Neural Network
AI	: Artificial Intelligence
CBEMA	: Computer and Business Equipment Manufacturers Association
CENELEC	: European Committee for Electrotechnical Standardization
CRISP	: Cross Industry Standard Process for Data Mining
CWT	: Continious Wavelet Transform
DL	: Deep Learning
D_{STD}	: Delta Standard Deviation
DWT	: Discrete Wavelet Transform
ELM	: Extreme Learning Machine
EPRI	: Electric Power Research Institute
FT	: Fourier Transform
FV	: Fisher Vector
GKO	: Güç Kalitesi Olayları
HB	: Hilbert Based
HT	: Hilbert Transform
IEC	: The International Electrotechnical Commission
IEEE	: The Institute of Electrical and Electronics Engineers
IRERA	: International Renewable Energy Research Alliance
ITD	: Instantaneous Time Domain
k-NN	: k-Nearest Neighbour
LP	: Local Peaks
LSSVM	: Least Squares Support Vector Machine
ML	: Machine Learning
PE	: Permutation Entropy
RMS	: Root Mean Square
SB-ELM	: Sparse Bayesian Extreme Learning Machine
SCADA	: Supervisory Control and Data Acquisition
SLFN	: Single Layer Feedforward Neural Network
ST	: S-Transform
STD	: Standard Deviation
TEİAŞ	: Türkiye Elektrik İletim Anonim Şirketi
TÜBA	: Türkiye Bilimler Akademisi
WELM	: Weighted Extreme Learning Machine

1. GİRİŞ

Gelişen şartların değerlendirilmesi ile oluşan ve yapılacak iyileştirmeleri aktarabileceğimiz geliştirilmiş elektrik şebekesi akıllı şebeke olarak adlandırılmaktadır. Akıllı şebekeler, gerek denetlenebilme gerekse yönetilebilme unsurları açısından kullanıcılara önemli imkânlar sunmaktadır. Akıllı şebekelerde güç kalitesi işaretlerinin işlenerek denetim ve süreklilik açısından yapılandırılıp, akıllı koruma ve izleme cihazlarında kullanılması, günümüz endüstrisinde önemli bir geliştirme alanını oluşturmaktadır.

İlerleyen teknoloji ile birlikte elektrik şebeke yapısının geleneksel biçimden akıllı şebeke biçimine dönüştürülmesi günümüz elektrik sektörünün vazgeçilemez amacıdır. Üretim merkezlerinin yenilenebilir enerji kaynakları ile de çeşitlilik kazanmasıyla dağıtılmış üretim merkezleri (mikro-şebeke) ve bunların şebekeden bağımsız olarak çalıştığı ada modu çalışma gibi şebekenin davranışını daha dinamik hale getiren yapılar da gün geçtikçe artmaktadır. Böylesi bir dinamik yapıda elektrik enerjisinin üretildiği yerden son kullanıcıya aktarılma sürecine dek güç kalitesi kavramı büyük önem kazanmaktadır. Güç kalitesi sağlanarak aktarılan enerji, süreklilik ve güvenilirlik temelinde daha sürdürülebilir bir yapıya sahiptir. Şebekenin iletim ve dağıtım taraflarında oluşabilecek güç kalitesi problemleri iyi izlenmeli ve çözüm sürecinde hızlı, etkili adımlar atılmalıdır [1].

Akıllı şebeke sistemlerinde rol alan her bir eleman denetim merkezine bir takım veriler iletmektedir. Aynı şekilde denetim merkezinden de elemanlara doğru bir veri akışı söz konusudur. Bu çift yönlü iletişime sahip karmaşık yapıda anlık olarak kaydedilen verilerin ilgili kısmının anlamlandırılması ile güç kalitesi izleme sistemleri oluşturulmaktadır. Şebekenin akım-gerilim işaretlerinin takibine dayanan bu sistem, günümüzde artık büyük veri (*big data*) olarak tabir edilen geniş veri tabanlarını işleyerek operatöre anlamlı bilgi yumağını sunmaktadır. Büyük veri işleme sürecinde sistemin doğruluğu kadar işlem hızı da büyük önem kazanmıştır [2, 3].

Güncel teknolojileri kullanarak, her biriminde ölçülebilir ve izlenebilir nitelikler sunabilen ve tüketiciye aktarılan elektrik enerjisinde süreklilik ve verimliliği esas alan modern şebeke kavramı günümüzde akıllı şebekeler başlığı altında incelenmektedir. Kaynakların hızla tükeniyor olmasıyla birlikte ülkelerin verimlilik odaklı akıllı elektrik şebekesine geçiş sürecine ayırdıkları ar-ge bütçeleri de artış göstermektedir. Teknolojideki ilerleme, üretim

bantlarında kullanılan cihazların da gelişme göstererek karmaşık denetim mekanizmaları ile çalışmalarına olanak tanımıştır. Kullanıcı tarafındaki bu tür yüklerin artış göstermesi ile şebeke operatörlerinin çok çeşitli güç kalitesi problemleri ile yüz yüze gelmeleri kaçınılmaz olmuştur. Endüstri 4.0, endüstriyel internet, nesnelerin interneti, karanlık fabrikalar, insansız sürüş teknolojisi ile donatılmış otonom özellikteki elektrikli araçlar, akıllı şehirler gibi kavramların tartışıldığı günümüz ortamında, elektrik şebekesi ve onları yöneten operatörlerin gelişen bu şartlara uygun adımlar atması gerekmektedir.

Güç elektroniği tabanlı elektrik motor sürücüler, değişken hız denetim cihazları, ofislerde kullanımı artış gösteren kesintisiz güç kaynakları gibi anahtarlama tabanlı ve doğrusal olmayan yükler, şebekeden çektikleri akımlarda meydana getirdikleri harmonik bozulmalar ile de sorun teşkil etmektedirler. Ayrıca yenilenebilir enerji kaynaklı elektrik üretim santrallerinin kullanımındaki artışın ortaya çıkardığı etkiler de güç kalitesi alanında yoğun çalışılan bir başlık halini almıştır. Özellikle rüzgar enerji santrallerinin değişken yapıları ve şebekeyle bütünleşmesindeki problemlerden dolayı gerilim çökmesi ve yükselmesi olayları yoğun olarak meydana gelmektedir [4].

Güç kalitesi problemlerine çözüm bulmak için şebekenin iyi bir şekilde izlenmesi ve elde edilen verilerin detaylı olarak yorumlanması gerekmektedir. Bu amaçla oluşturulan güç kalitesi izleme sistemleri, şebekenin gerek iletim gerekse dağıtım tarafında hala geliştirme potansiyeli yoğun olan bir başlıktır. Ülkemizdeki elektrik iletim altyapısı devlet denetiminde işletilmektedir. Devlet iletim sisteminin hem sahibi hem de işleticisi pozisyonundadır. Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) bünyesinde gerçekleştirilen ar-ge çalışmaları ile iletim tarafı güç kalitesi çalışmaları devam etmekle birlikte ülkemiz genelinde büyük oranda özelleştirilen dağıtım şirketleri bünyesinde de güç kalitesi izleme sistemleri ar-ge çalışmaları hız kazanmıştır. 2015 – 2019 yıllarını kapsayan stratejik plan kapsamında Enerji ve Tabii Kaynaklar Bakanlığı da ar-ge ve inovasyon başlığı altında sunduğu desteklerle dağıtım firmalarının güç kalitesi izleme yönünde ortaya koyacakları projelerinin teşvik edilmesini vurgulamıştır [5]. Kapsamlı şekilde oluşturulmuş bir izleme sistemi, şebekenin sorun haritasını ortaya koyarak çözüm aşamasına büyük katkı sağlayacaktır.

Dünya nüfustaki artış ile birlikte sıklıkla bahsedilen enerji tasarrufu kavramının, endüstriyel üretimin lokomotifi olan elektrik enerjisi üzerindeki tesiri gün geçtikçe artmaktadır.

Elektrik şebeke yapısındaki değişimin, enerji verimliliği ve sürekliliği başlıklarının tetikle-mesi ile daha modern ve akıllı bir yapıya kavuşması gerekliliği geçtiğimiz on yıldan beri tar-tışılmaktadır. Fosil yakıtların dünya üzerinde tükeniyor olması, güneş ve rüzgâr enerjisi gibi yenilenebilir enerji kaynaklarına geçişin de hız kazanmasını sağlamıştır. Gelişen ve daha da karmaşıklaşan elektrik enerjisi üretiminin güncel yapısında, geleneksel şebeke ile yola de-vam edilmesinin zorluğu aşikârdır. Elektrik enerjisi üretimi, iletimi ve dağıtımı aşamalarında meydana gelen sorunların çözümlerinde akıllı şebeke yapılarının gerekliliği vurgulanmakta-dır. Ülkemizde elektrik şebekesinin dönüştürülerek, sahaya çıkan yeni oyuncuların enterkon-nekte sisteme bağlantısı ve ülke geneli enerji verimliliği ve sürekliliği sağlanması amacıyla akıllı şebeke alt yapısı kazanması gerekliliği yapılan çalışmalarla ortaya konmaktadır [1].

Akıllı şebekeleri geleneksel şebekelerden ayıran en önemli özellik izlenebilir bir yapıya sahip olmalarıdır. Enerji santrallerinin denetim merkezlerinden başlayarak ülke genelindeki tüm santrallerde üretilen enerjiyi yöneten iletim sağlayıcı kuruma kadar uzanan zincirde, enerji kalitesinin izlenmesi son derece önemli bir süreçtir. Bahsedilen sistemin ülkemiz ge-nelinde uygulamaya alınması adına son yıllarda ciddi çalışmalar ortaya konmuştur [6].

Genel anlamda güç kalitesi izleme olarak tanımlanan bu süreçte akıllı ölçüm merkezle-rinden elde edilen verilerin üst düzey olarak yorumlanması ile geçmişte oluşmuş güç kalitesi bozulmaları belirlenmekte, listelenmekte ve olası sorunlara karşı bölgesel ya da merkezi ön-lemler alınması sağlanmaktadır [4].

Elektrik enerjisinin son kullanıcıya ulaştırılmasının özel şirketler aracılığı ile gerçek-leştiriliyor olması, bu dağıtım firmalarının da güç kalitesi izleme ile ilgili alt yapı oluşturma-larını zorunlu kılmaktadır. Çünkü çok oyunculu bu sahada ortaya çıkabilecek bir güç kalitesi bozulmasına neden olan kurum ya da firma da ancak bu şekilde tespit edilebilmektedir.

Güç kalitesi problemlerinin temelini oluşturan iki unsur, olaylar ve değişimlerdir. Bu kavramları net bir şekilde ayıran temel özellik, olayların zamanın her anında gerçekleşme-diği; değişimlerin ise zamanın her anında ölçülebildiği gerçeğidir [4]. Bu açıklamalarda, gerekliliği bir çok yönden vurgulanan izleme sistemlerinin en önemli bileşeni, Güç Kalitesi Olayları (GKO) tespit, tanılama ve sınıflandırma sistemidir [7].

Elektrik şebekesinden elde edilen ve büyük veri kapsamına girebilecek boyuttaki ve-rilerin detaylı olarak yorumlanması, analizinin yapılması ve sınıflandırma kavramı içeren bir sistemin oluşturulması başlıklarının amaçlandığı bir çalışma, *örüntü tanıma* uygulama-larının kullanıldığı alanların kapsamına girmektedir. Temeli 1950'li yıllara dayanan Yapay

Zeka (Artificial Intelligence–AI) ve oluşturduğu büyük resim içerisinde ortaya çıkan kavramlar, son yıllarda gerçekleşen önemli gelişmeler ile uygulama çeşitliliği bakımından geniş bir yelpazeye yayılmıştır [3]. 1980’li yılların başlarından itibaren heyecan uyandırmaya başlayan makine öğrenme (Machine Learning–ML) kavramı, son on yıldaki hızlı teknolojik gelişmelerin etkisi ile derin öğrenme (Deep Learning–DL) kavramını beslemeye başlamıştır.

Bilgisayar bilimlerinin alt dalı olan AI, baş döndürücü bir hızla gelişerek ML ve DL kavramlarının tetiklediği ve insanoğlunun öğrenme yapısını taklit eden, adeta beynimizin işlediği şekilde öğrenme, geri çağırma ya da tanılama işlemleri gerçekleştiren uygulamalar oluşturulmasına öncülük etmiş ve bu uygulamaların bir çoğu günlük yaşamda da rastlanabilecek örneklerle dek indirgenmiştir [8].

Bu noktada, tez çalışmasının da motivasyon kaynağını oluşturan bir soru akla gelmektedir: “*Neden makine öğrenmesi?*”. Bu sorunun cevabını vermek için *makine öğrenmesi* kavramına ait genel tanımdan başlamak koşulu ile bir çok geçerli neden sıralanabilmektedir.

Öğrenme psikolojisi yaşıntıya dair birçok temel noktayı içine almaktadır. Etkisinin genişliği karşısında, adı geçen bir psikoloji dalının oluşmasına dahi ilham veren *öğrenme* kavramı, Türkiye Bilimler Akademisi (TÜBA) tarafından hazırlanmış bilimler sözlüğünde geçtiği üzere, *kavramsal düzenlemeler yapma süreci* olarak tanımlanmıştır [9]. İnsana özgü olan bu toplumsal süreç içeren davranışın “*makine*” ile bir araya gelmesi, ilk okunduğunda bir anlam karmaşası hissi vermektedir. Bilgisayar bilimleri, temel bilimlerden matematik ve yan dalı istatistik bilimlerinin ortak paydasında yürütülen ve yıllara dayanan çalışmalar makinelerin de öğrenme yeteneği kazanmasını sağlamıştır. Klasik anlamı ile bilinen ve akılda mekaniksel bir çağrışım uyandıran “*makine*” sözcüğü, hareketli aksamı ve dişli parçaları ile bir amaca yönelik iş ortaya koyan hali ile düşünülse de artık bu anlam genişleyip, yazılım ve donanımdan oluşan bir bilgisayar sistemini de kapsar hale gelerek kanıksanmış bir durum olarak karşımıza çıkmaktadır. Bu durumda, artık öğrenenin donanım değil yazılım olduğu sonucuna ulaşılabilecektir. Kullanılan araçlardan, yiyecekleri soğutan buzdolabına ya da görüntü aktarımı yapan televizyondan, bir cep telefonuna kadar, yazılım ihtiva eden tüm makinelerin öğrenebileceği, günümüzün normalleşmiş gerçekleri arasına girmiştir [8]. Makine öğrenme konusuna ait ayrıntılı bilgiler için tez çalışması boyunca da makine öğrenme terimlerinin Türkçe karşılıklarının kullanılmasında önemli bir yer tutan [10] çalışmasına başvurulabilir.

Yukarıda genel hatlarıyla tanımlanan makine öğrenmesi kavramının amaçları, özet bir

liste ile şu şekilde verilebilir [8]:

- Etkili ve hatasız tahmin yapabilen algoritmaları tasarlamak,
- Bilgisayar programını, tarihsel bilgi ve deneyime dayalı verilerden otomatik olarak eğitmek,
- Başarım optimizasyonu ya da geçmiş deney verilerini kullanarak programlama gerçekleştirmek,
- Veriden kural öğrenebilen, uyum sağlama yeteneği olan ve deneyim ile başarımını yükseltebilen yazılımları tasarlamak.

Makine öğrenmesinin tüm bu amaçları ışığında, GKO sınıflandırma işleminin örüntü tanıma mantığı ile gereksinimlerine uygun olarak gerçekleştirilebileceği ortaya çıkmıştır. Literatürde kabul gören ML yöntemleri arasında destek vektör makinesi (Support Vector Machine–SVM), Naive Bayes sınıflandırıcı, k–en yakın komşu algoritması, logistik regresyon analizi ve C4.5 karar ağacı gibi bir çok yöntem bulunmaktadır [8]. Tez çalışmasında önerilen modellerde ise günümüzde bir çok alanda yaygın olarak tercih edilen uç öğrenme makinesi (Extreme Learning Machine–ELM) tabanlı yöntemler kullanılmıştır.

Her ne kadar makinelerin öğrenme yeteneği üst düzey basamaklara çıkmış olsa da, klasik bir örüntü tanıma sistemindeki en önemli aşamalardan birisi, ham işaretlerden ya da veri setinden ayırt edici özelliklerin çıkarıldığı, öznitelik çıkarım sürecidir. Veri seti olduğu halile sınıflandırma işlemine tabi tutulmayarak, hem boyut azalımı sağlamak hem de sınıflandırıcı başarımını arttırmak amaçları ile öznitelik çıkarımı gerçekleştiren çok çeşitli yöntem bulunmaktadır [4].

Günümüzdeki gelişmelerle birlikte, güç kalitesi işaretlerinin izlenip yorumlanması süreci sayısal ortamda son derece hızlı bir şekilde yapılabilmektedir. Geleneksel sistemlerin bellek tabanlı çalışmasının yani verileri ilk önce kaydedip istenildiğinde bilgisayar ortamına aktararak analiz sürecini gerçekleştirmesinin en büyük dezavantajı zaman kaybıdır [11]. Bu dezavantajı gidermek adına; yapısında Dalgacık Dönüşümü (Wavelet Transform-WT), Kalman Filtreleme (*Kalman Filter*), S Dönüşümü (*S Transform*) gibi üst düzey işaret işleme yöntemlerini barındıran ve karar mekanizmasında; Yapay Sinir Ağları (*Artificial Neural Network–ANN*), Uzman Sistemler (*Expert Systems*) gibi yapay zekâ yöntemlerini kullanan,

akıllı örüntü tanıma sistemleri geliştirilmiştir. Bu yöntemler işaretleri gerçek zamanlı işleyerek, süreci önemli ölçüde hızlandırmaktadır.

1.1. Literatür Özeti

Güç kalitesi bozulmaları sınıflandırma işlemlerinde kullanılan yaklaşımlar 1990'lı yılların başlarında, işaret işleme yöntemlerini mühendislik bilgisi ile yorumlamayla sınırlı kalmıştı. 2000'li yıllarla birlikte yumuşak hesaplama yöntemlerindeki gelişmelerle doğru orantılı olarak, ileri seviye işaret işleme yöntemleri ve akıllı sistemlerin birlikte kullanıldığı sınıflandırma yaklaşımları, izleme sistemlerinde kullanılmaya başlanmıştır [12].

Güç kalitesi kavramı, ilk ortaya atıldığı ve üzerinde çalışmalara başlandığı 1970'li yıllarda, elektrik enerjisinin kesintisiz olarak sunulması olarak kabul edilmişti. Teknolojik gelişmelerin güç sistemlerine yansıtılmasıyla birlikte, kalite kavramına bakış da değişim geçirmiş ve içerisinde yapılandırma, koruma, iyileştirme gibi başlıklarla ilgili standartları içerecek haliyle yeniden düzenlenmiştir. Bu amaçla, uluslararası sahada birçok çalışma grubu oluşturulmuştur. IEEE, IEC, EPRI, CBEMA, IRERA ve CENELEC gibi çalışma grupları güç kalitesi bozulma türlerinin özellikleri ve sınıfları, ölçüm yöntemleri, akım, gerilim ve frekans büyüklüklerinin karakteristikleri gibi kavramlar hakkında standartlar belirlemişlerdir ve bu gruplar güç kalitesi üzerine geliştirme çalışmalarına hala devam etmektedir. Uluslararası sahadaki güç kalitesi çalışmalarında, IEEE ve IEC standartları daha çok tercih edilmektedir [12, 13]. Bu tez çalışmasında, IEEE standartları referans alınarak güç kalitesi bozulma olaylarının temel tanımlamaları ortaya konmuştur [14].

Güç kalitesi olayları arasında gerilim genlik bozulma olayları olarak da gruplandırılan gerilim çukuru ve tepesi olaylarının tespit edilmesinde; standartlarda da tanımlanan etkin değer (rms) değişimi ile tanımlama yöntemi kullanılmaktadır [14]. Bu yöntem, uygulanması basit ve kolay olmasına rağmen, olay işaretlerinin; faz açıları, frekansları ve harmonik içerikleri hakkında bilgi verememesi özellikleri ile kullanım alanı olarak kısıtlı kalmıştır [15]. Bu yöntemin sınırlamalarını kaldırmak için kısa zamanlı Fourier Dönüşümü (Fourier Transform-FT), Kalman filtre ve WT gibi işaret işleme yöntemleri varyasyonları ile birlikte kullanılmıştır. Aşağıda, gerek öznitelik çıkarım aşaması ve işaret işleme kısmı gerekse sınıflandırıcı aşamasında çeşitli yöntemler kullanarak olay sınıflandırma yapılan çalışmalara dair özet bilgiler sunulmuştur.

Kısa zamanlı FT, pencere olarak tanımlanmış fonksiyonlarla işareti parçalara ayırarak

analiz yapar, böylece durağan olmayan fonksiyonlar da o pencere genişliği boyunca durağanlaştırılmış olur. İşaretten elde ettiği katsayılarla, FT yöntemine ek olarak işarete ait zaman ve frekans bilgilerini sunar. Bu haliyle birçok güç kalitesi çalışmasında tercih edilen bir analiz yöntemi olmuştur [16]. Kısa zamanlı FT yönteminde bahsedilen pencere fonksiyonunun genişliği sabit kaldığı için taranan işaretin yüksek frekanslı bölgelerinde analiz tam olarak gerçekleştirilemez. Geliştirilen diğer yöntemlerle bu dezavantaj giderilmiştir [17].

WT yönteminin temel detaylarının ele alındığı [18] çalışmasında, güç kalitesi bozulmaları ile ilgili işaret işleme sürecinde WT yöntemi kullanım basamakları sunulmuştur. Ayrıca FT yöntemi ve WT yöntemi karşılaştırmalı olarak sunulmuş güçlü ve zayıf yönleri analiz edilmiştir.

Çalışma [19] ile yazarlar, WT yönteminin güç kalitesi olaylarında kullanımını gerilim olayları tabanlı incelemişlerdir. Kapsamlı bir anlatım sunan çalışmada WT yönteminin öznitelik çıkarma işleminde kullanım tarzları özetlenmiş ve WT kullanan yapay zeka sınıflandırma yöntemlerine değinilmiştir.

S–dönüşümü (S–Transform) ve uç öğrenme makinesi (ELM) yöntemlerine dayanan, güç kalitesi bozulmalarının altında yatan sebeplerin otomatik olarak tanımlanması işlemlerinin sunulduğu [20] çalışmasında, ELM performans değerlendirmesi 10 farklı sınıflandırma prosedürü ile karşılaştırarak vurgulanmıştır. Veri seti olarak sınırlı sayıda bir veri çalışılmıştır ve veri setindeki dengesiz dağılım bu çalışmada göz önünde bulundurulmamıştır. Burada ELM yöntemi, en temel haliyle kullanılmıştır.

Çalışma [21] ile güç kalitesi olayları sınıflandırıcısı girişine uygulanacak özniteliklerin en uygun şekilde seçildiği bir algoritma önerilmektedir. Öznitelik çıkarma işleminde çok çözünürlüklü ayrıştırma gerçekleştiren WT yönteminden elde edilen detay katsayılarına; k–ortalama ve Apriori algoritmaları uygulanarak en uygun öznitelikler elde edilmiş ve en küçük kareler Destek Vektör Makinesi (Least Squares Support Vector Machine–LSSVM) sınıflandırıcı yapısına giriş olarak uygulanmıştır. Gerçek bir güç sisteminden elde edilen veri seti ile önerilen yapının başarımı değerlendirilmiştir.

WT ve SVM tabanlı, güç kalitesi olaylarını otomatik olarak sınıflandıran bir algoritmanın önerildiği [11] çalışmasında kullanılan sistemde, güç sistemleri benzetim modelleri tasarlanabilen bir paket program kullanılarak elde edilen yapay olay verileri kullanılmıştır. SVM yapısı çekirdek fonksiyonları iyileştirilerek en az hatalı sınıflandırma değerini veren yapı saklanmıştır. 6 çeşit olay verisi kabul edilebilir bir başarımla değerlendirilmiştir.

Güç kalitesi olaylarının altında yatan nedenlere göre tanımlanması ve sınıflandırılması, elde ettiği farklı özniteliklere göre gerçekleştiren bir yapının ortaya konduğu [22] çalışmada, altta yatan her neden için ayrı bir öznitelik seti elde edilmiş ve bu veriler kurallı tabanlı bir sınıflandırıcı yapısına giriş olarak uygulanmıştır. Önerilen sınıflandırıcı kabul edilebilir değerde sınıflandırma başarımı elde edebilmiştir. Bollen ve ekibi tarafından yapılan çalışmalar; olay sınıflandırma işlemini bir basamak üste taşıyarak, olayları altında yatan nedenleri de ortaya koyarak tanımlama yöntemlerini literatüre kazandırmışlardır.

Çalışma [23] ile güç sistemi olaylarının sınıflandırma ve detaylı analizi için bir uzman sistem önerilmiştir. Bu çalışmada da önerilen uzman sistem yapısı olayları, altta yatan nedenlere göre sınıflamıştır. Sahadaki gerçek kaynaklardan oluşmuş olay verisi sistemin başarımını değerlendirmede kullanılmış ve kabul edilebilir sonuçlar elde edilmiştir.

Güç sistemleri olaylarının otomatik sınıflandırılması amacıyla gerilim ölçümlerinden hesaplanan etkin değer yönteminin kullanıldığı [24] çalışmada, gerilim çukuru olayını oluşturan arızalar üzerinde durulmuştur. Bu tarz bir yöntemle oluşturulan izleme sisteminin kısıtlarına da değinilmiştir.

Güç kalitesi bozulmalarının altında yatan nedenlerin sınıflandırılmasının gerçekleştirildiği [25] çalışmada, deterministik ve istatistiksel yöntemler karşılıklı değerlendirilerek oluşturulan bir model önerilmiştir. Olayları, altta yatan nedenlerle birlikte sınıflandırma işlemi kısıtlı bir veri kümesi ve uzman görüşüne sıkı bağlılık gibi dezavantajlarından dolayı uygulamaya yansması çok ender olan bir alandır.

Gerilim çukuru olaylarını sınıflandıran ve analiz eden bir yapı uzman sistem tabanlı olarak [26] çalışması ile gerçekleştirilmiştir. Arıza, transformatör doyumu, indüksiyon motoru kalkışı gibi altta yatan nedenleri içeren gerilim çukurları, Kalman filtre yöntemi destekli bir uzman sistem yardımıyla başarılı şekilde ayırt edilebilmiştir.

Güç kalitesi olay sınıflandırma işlemi için en uygun özellik setini araştıran bir algoritma [27] çalışmada önerilmiştir. Elde edilen özellik serileri Bayes ve SVM tabanlı iki farklı sınıflandırıcı yapısında test edilmiştir. Çalışmada, sınıflandırıcı yapısına göre özellik vektörlerinin başarımının negatif ve pozitif yönde değiştiği de vurgulanmıştır.

Dağıtım sistemindeki güç kalitesi olaylarının yeni bir sınıflandırma sistemi ile gerçekleştirilmesinin sunulduğu [28] çalışmada, SVM sınıflandırıcı yapısının diğer farklı yöntemlerle birebir karşılaştırılması yapılmıştır. Temel amaç olarak genişletilmiş ampirik kip ayrıştırma (*Empirical Mode Decomposition*) yöntemi ile geleneksel ampirik kip ayrıştırma

yönteminin öznitelik çıkarımındaki başarımları değerlendirilmiştir. Öznitelikler Hilbert Huang dönüşüm yöntemi ile elde edilmiş ve bahsedilen sınıflandırıcılara giriş olarak verilmiştir.

WT yöntemi ve ampirik kip ayrıştırma yönteminin güç kalitesi olaylarını sınıflandırmadaki başarımlarını karşılaştırmalı olarak çalışma [29] ile sunulmuştur. Bu çalışmada sınıflandırıcı olarak ANN kullanılmıştır.

Güç kalitesi olaylarını tanımada görüntü işleme tabanlı bir yöntemin önerildiği [30] çalışmasında, olay işaretlerinden gri-ölçekli görüntüler elde edilerek, tek boyutlu işaretler iki boyuta çıkarılmış ve buradan ayırt edici özellikler belirlenmiştir. Olayları sınıflandırmada, görüntü işleme yöntemlerinde kullanılan kenar algılama algoritmaları kullanılmıştır.

İletim hatlarındaki yıldırım darbelerini sınıflayabilen, çok çözünürlüklü ayrıştırma ve makine öğrenme tabanlı bir yapının önerildiği [31] çalışmasında, farklı parametrelerle gerçekleştirilen WT yöntemi, üç faz gerilim işaretlerine uygulanmıştır. ANN, k-En Yakın Komşu (k-NN) ve SVM sınıflandırıcı yapıları olay işaretlerini sınıflandırma işlemi için kullanılmıştır.

Yüksek derece istatistik (*Higher Order Statistics*) yöntemi ile gerilim işaretlerindeki bozulmaları belirleyen bir algoritma [32] çalışmasında önerilmiştir. Bu algoritma ile elde edilen katsayılar filtrelenerek sınıflandırma gerçekleştirilmiştir.

Güç kalitesi olaylarının incelenmesinde bulanık sınıflandırıcı kullanan bir yapı [33] çalışması ile önerilmiştir. Ayrıca WT yöntemi, işaretlerin gürültülerinden arındırılması ve ayırt edici özelliklerin çıkarılması amacıyla kullanılmıştır. Elde edilen özellikler çeşitli bulanık sınıflandırıcı yapılarına giriş olarak verilmiş ve başarımları karşılaştırmalı olarak sunulmuştur.

Tekli ve çoklu güç kalitesi olaylarının tanıma ve sınıflandırması amacıyla hibrid demodülasyon ve harmonik analizi yönteminin kullanıldığı [34] çalışmasında, Çoklu Sinyal Sınıflandırma (*Multiple Signal Classification*) yöntemi kullanılarak elde edilen öznitelikler bulanık sınıflandırıcı yapısına uygulanmıştır. Çeşitli olaylar için önerilen algoritmanın başarımları test edilmiştir.

Genetik algoritma yöntemi kullanarak yapılan sınıflandırma çalışmalarını da içeren detaylı bir derleme çalışması [35] ile sunulmuştur. Güç kalitesi problemlerini tanılama ve değerlendirme için kullanılan model tabanlı bir yaklaşım ise çalışma [36] ile önerilmiştir. Gerçek zamanlı işleme süreci yapabilen yöntemde olaylar, neden-sonuç ilişkisi bağlantısı ile sınıflandırılmışlardır. Çalışmada, altta yatan nedenleri gösteren zengin bir ağaç yapısı sunulmuştur.

Veri madenciliği yöntemlerinin akıllı şebeke alt yapılı güç üretim merkezlerinde araştırılması ve uygulanması yönünde bir derlemenin sunulduğu [37] çalışmasında, arızaların veri madenciliği yöntemleri kullanılarak teşhis edilmesi üzerine yapılan araştırmalar ortaya koyulmuştur.

Akıllı şebekelerdeki arızalı hattın tanılama işlemi için makine öğrenme tabanlı ve gerçek zamanlı çalışabilen bir sistem [38] çalışmasında sunulmuştur. Arıza sonrası oluşan etkin değerleri ölçen akıllı sistemden elde edilen veriler işlenerek SVM sınıflandırıcı yapısına giriş olarak verilmiştir. Çalışmanın başarımı, oluşturulan benzetim çalışmalarında kapsamlı olarak test edilmiştir.

GKO sınıflandırma gerçekleştirilen SVM modellerine getirilen iyileştirmeleri özetleyen geliştirme algoritmaları çalışma [39] ve çalışma [40] ile sunulmuştur. Her iki çalışmada da SVM parametre belirleme ile ilgili ayrıntılara yer verilerek sınıflandırma işlemlerinin başarımlarını önceliği geri planda tutulmuştur.

Teager Enerji Operatörü algoritmasının güç kalitesi olay tanılamada kullanıldığı [41] çalışmasında, sinüzoidal dalga formunun bu yöntem kullanılarak elde edilen modeli ile gerilim olaylarına ait farklı analizler gerçekleştirilmiştir.

Güç kalitesi olaylarını altta yatan nedenlerle birlikte otomatik olarak sınıflandırabilen bir yapı [42] çalışmasında önerilmiştir. Yazarlar tarafından geliştirilen çerçeve-tabanlı dizi sınıflandırma (*Frame-Based Sequence Classification*) yöntemi genişletilmiş bir WT önerisidir.

Gerçek verilerden oluşan bir GKO veri setinin kullanıldığı [43] çalışması ile yüksek dereceli istatistik öznelikleri kullanarak sınıflandırma gerçekleştirilmiştir. Sınıflandırıcı olarak temel ANN yapısı kullanılan yöntemle 8 farklı GKO sınıfı ayırt edilmiştir. Bu çalışmanın önemli bir avantajı, donanımsal olarak da gerçekleştirilmiş olmasıdır.

WT tabanlı bir olay tanılama sistemini içeren ve fazör ölçüm birimi (*Phasor Measurement Unit*) yöntemi ile elde edilmiş faz bilgisinden de faydalanarak önerilen bir model, çalışma [44] ile sunulmuştur. İşlemler gerçek veri seti kullanılarak değerlendirilmiştir. Bu çalışmada sınıflandırma yapılmamış sadece tanılama (*detection*) işlemi gerçekleştirilmiştir.

Çevrimiçi bir GKO tanılama sistemini içeren model, [45] çalışması ile sunulmuştur. Burada, gerçek fazör ölçüm birimlerinden elde edilen veriler kullanılmıştır. Tespit edilen yoğunluk tabanlı uç örnek yakalama algoritması ile de ölçüm verisi daha düzgün dağılımlı hale

getirilmiştir. Bu çalışmada da sadece tanılama işlemi gerçek veriler kullanılarak oluşturulmuştur.

Gerçek GKO verileri kullanılarak oluşturulmuş bir GKO sınıflandırma ve arıza yeri belirleme algoritması [46] çalışması ile sunulmuştur. Burada sınıflandırıcı yapısına giriş olarak verilen öznitelikler, DWT çok çözünürlüklü ayrıştırma yönteminden faydalanılarak elde edilmiştir. Bu çalışmada, sınıflandırıcı olarak bulanık mantık (*Fuzzy Logic*) tabanlı algoritma ile ANN yapısını birleştiren uyarlamalı rezonans teorisi (Adaptive Resonance Theory) tabanlı, bulanık sınıflandırıcı ve ANN yapısı entegrasyonu kullanılmıştır.

GKO sınıflandırma işlemini gerçek olay verileri kullanarak gerçekleştiren ve öznitelik çıkarım yöntemi olarak çift çözünürlüklü S-dönüşümü kullanan bir örüntü tanıma sistemini içeren [47] çalışmasında, sınıflandırıcı olarak doğrudan asiklik (dolamsız) grafik (Directed Acyclic Graph) SVM kullanılmıştır. Çalışmada 7 adet münferit ve 2 adet birleşik olmak üzere 9 olay sınıfı kabul edilebilir başarımlar değerlerinde sınıflandırılmıştır.

Gerçek verilerden elde edilen GKO setini, DWT yöntemi tabanlı öznitelik çıkarım kullanılarak, SVM ile sınıflandıran bir sistem [48] çalışmasında önerilmiştir. Olay sınıflandırma işlemine ait gömülü deneyler de bu çalışma kapsamında gerçekleştirilmiştir.

GKO sınıflandırma işleminin standartlar ışığında oluşturulan bir akıllı ölçüm cihazında kullanılmak üzere tasarlandığı bir iş akışı [49] çalışmasında sunulmuştur. Gerçek veri seti kullanan bu çalışmada, SCADA sistemine entegre olabilen ve haberleşme özelliğine sahip konsept bir akıllı ölçüm cihazı tasarlanmıştır.

Güç kalitesi işaretlerinin işlendiği fakat GKO sınıflandırma işleminin yapılmadığı [50] çalışmasında, bir evde kullanılan bazı elektrikli cihazlara ait güç işaretleri yardımıyla yük tahmini gerçekleştirilmiştir. Bu işleme ait özel çalışma başlığı, kesintisiz yük izleme (Non-Intrusive Load Monitoring) olarak adlandırılmaktadır. Burada her yük başına teker teker güç ya da akım-gerilim bilgisine ihtiyaç duyulmadan elde edilen sürekli zaman ölçümlerinin kullanılmasıyla yük izleme ve analiz işlemlerinin gerçekleştirilmesi amaçlanmıştır.

Şebeke bağlantılı (*grid connected*) dağıtılmış üretim sistemi (*Distributed Energy Resource*) konseptinde meydana gelen bozulma olaylarının karar ağacı algoritmaları kullanılarak yapıldığı bir sınıflandırma işlemi [51] çalışması ile sunulmuştur. Öznitelik çıkarım yöntemi olarak değişken kip ayrıştırma (*Variable Mode Decomposition*) kullanılmıştır. Kullanılan veri seti gerçek dünya ölçümlerine dayanmaktadır. Bu çalışmada da öznitelik çıkarım yönteminin dayandığı temel bir dönüşüme bağlı olduğu için hesapsal maliyet ortaya çıkmaktadır.

Öznitelik çıkarım sürecinde ölçüm cihazının bağlı olduğu bölgeye ait bir takım özellikleri de hesaba katan bir yöntemin önerildiği [52] çalışmasında ana amacın algoritmayı akıllı bir ölçüm cihazında kullanmak olduğu vurgulanmıştır. Bu nedenle sade bir model önerilmiş ve sınıflandırıcı olarak SVM kullanılmıştır.

Güç kalitesi olay sınıflandırma literatürünün oluşturduğu büyük resimde, öznitelik çıkarım yöntemlerinin çeşitlendiği ve sınıflandırıcı olarak “akıllı” yapıların öne çıktığı görülmektedir. Önemli bir nokta da, çalışmalarda kullanılan çoğu veri setinin yapay veriler kullanılarak elde edilmiş olması ya da kısıtlı olanaklarla hazırlanmış gerçek veri setleri olarak kullanılmalarıdır. Gerçek veri kullanan bir çok çalışma ise laboratuvar koşullarında hazırlanan veri setleri ile deneylerini gerçekleştirmişlerdir. Bu tez çalışmasında, veri setinin Türkiye geneli trafo merkezlerinden elde edilmiş olması ve bunun yanı sıra ciddi bir ön işleme ve izleme sürecinden geçirilerek elde edilmiş olması bir çok avantajı da birlikte getirmiştir. Öznitelik çıkarım yöntemi olarak, karmaşık hesapsal süreçler içeren dönüşüm tabanlı sistemlerden kaçınılarak en az sayıda öznitelik elde edilmesi amaçlanmıştır. Karar aşamasında sınıflandırma işlemi için kullanılan ELM tabanlı akıllı sınıflandırıcılar sahip oldukları genelleme başarımı ve işlem hızındaki etkinlikleri ile bir çok alanda yaygın olarak kullanılmaktadır [53]. Bu amaçla, bu tez çalışmasında da GKO sınıflandırma işlemine makine öğrenme perspektifi ile yaklaşarak çözüm arayan geliştirilmiş sınıflandırıcı modelleri önerilmiştir.

1.2. Problem Tanımı ve Amaç

İletim ve dağıtım hatlarında meydana gelen arızaların sonucunda oluşan gerilim çukuru, tepesi, kesintisi gibi bozulma olaylarının tespit edilmesi ve sınıflandırılması adına 2000’li yılların başından bu yana çok sayıda çalışma yapılmıştır [17]. Yukarıda sunulan geniş çaplı literatür taramasından incelenebileceği üzere, gerek öznitelik çıkarım sürecine getirilen katkılarla gerekse farklı sınıflandırıcı yapıları kullanılarak karar aşamasına getirilen katkılarla elde edilen GKO sınıflandırma sistemlerinin genel problemi, izleme sisteminde çalışacak algoritmaların ve önerilen modellerin en yüksek değerde başarımlı üretecek şekilde ayarlanması gerekliliğidir. Hatanın işlenmesi sürecine dayanan ve operatörün birçok hayati manevra yapabileceği ve önemli kararlar alabileceği bu bütüncül sistemde, önerilen algoritmaların da tüm olasılıklar göz önünde bulundurularak oluşturulması gerekmektedir. Bununla birlikte, önerilen modellerin gömülü cihazlarda ya da akıllı ölçüm birimlerinde en az sorunla

çalışabilmesi özelliğinin de göz ardı edilmemesi gerekmektedir.

Günümüzde yapay zeka ve makine öğrenmesi tabanlı yöntemleri içeren akıllı örüntü tanıma sistemlerinin geliştirilmeye son derece açık olması ve sahip oldukları avantajlardan dolayı çözüm adına sundukları katkılar ile üretilen çözüm modelleri de çeşitlilik kazanmıştır. Tez çalışmasının motivasyon noktasını da, bu alanda ortaya konacak bütüncül bir sistem neticesinde yukarıda betimlenen probleme en uygun çözüm yolu arayışı oluşturmaktadır.

Bu tez çalışmasında, GKO verilerinin sınıflandırmasını gerçekleştirmeye yönelik ve sahada çevrimiçi de kullanılabilecek haliyle tasarlanmış, güncel makine öğrenme yöntemlerinin işlem hızı, genelleştirme yetenekleri gibi olumlu taraflarıyla zenginleştirilen akıllı bir olay tanıma ve sınıflandırma modelinin elde edilmesi amaçlanmıştır. Problemin çözümü yolunda ve tezin amacına yönelik atılan adımlarda öncelikle, kullanılacak makine öğrenme yöntemleri belirlenmiş ve veri seti hazırlama işlemine başlanmıştır.

Tez çalışmasının erken döneminde, Türkiye geneli gerçek verilerin elde edilmesine yönelik adımlar atılmış ve TEİAŞ işbirliği ile gerçekleştirilen ikili antlaşma neticesinde veri elde etme süreci tamamlanmıştır. Tüm bu aşamalarda, tercih edilen algoritmaların uygunluklarının tespiti ve ön deneyler için kapsamlı bir benzetim model oluşturulmuş ve bu matematiksel model yardımıyla oluşturulan yapay veriler ile ön çalışmalara başlanmıştır.

3 faz olay verilerinden ve 2015 (ilgili yılın bir önceki) yılı süresince gerçekleşen ve Türkiye'nin dört bir tarafından elde edilen olay verileri matrisi, bir dizi ön işlem sürecinden geçirildikten sonra işleme alınmıştır. Bu işlemlerde, öncelikle olayın olduğu faz tespit edilmiş, olay anı genel pencereden ayrılarak segmentasyon işlemi gerçekleştirilmiştir. Böylece hem sınıflandırıcı başarımını olumlu etkileyecek bir yapı ve hem de boyut azalımı sayesinde hesapsal maliyeti de en aza indirgeyecek bir yapı elde edilmesi amaçlanmıştır.

Çalışmanın veri tanımı ve hazırlıkları aşamasında çözüm odaklı ve kapsamlı bir veri indirme, biriktirme ve hazırlama otomasyonu ortaya çıkarılmıştır. TEİAŞ ile gerçekleştirilen problem odaklı görüşmeler neticesinde Türkiye genelinde 7 farklı ölçüm noktasının 2015 yılına ait tüm olaylarını içeren bu veri yapısı da tez çalışmasının önemli bir ürünü olarak öne çıkmaktadır. Tez çalışmasının devamında gerçekleştirilecek gelişmelere de yansıtacak katkısı düşünüldüğünde, bu veri setinin güç kalitesi işaret işleme alanında üst düzey kullanımlara hitap eder tarzda tasarlanması amaçlanmıştır.

Tez çalışması sonucunda, yüksek genelleme başarımına sahip sonuçların üretilmesi ve hesapsal maliyet açısından en az işlem yükü barındırma gibi hedefleri gerçekleştirecek ve

bütüncül yapıda, tüm özellikleri ile tarif edilecek, bir güç kalitesi olay sınıflandırma modeli elde edilmesi amaçlanmıştır.

1.3. Tezin Katkısı

Güç sistemleri ve işaret işleme alanlarının birleştirilmesi neticesinde ortaya çıkan ve güç kalitesi kavramını teknolojik gelişmelerle daha ileri noktalara taşıyan birçok öneri ve uygulama akıllı şebekelerin daha etkin işletilmesi amacıyla araştırmacılar tarafından literatüre kazandırılmıştır [4, 17]. Bu uygulamalardan önemli bir tanesi de güç kalitesi olay sınıflandırma işlemidir ve örüntü tanıma sistemleri bakış açısı ile ele alınır. Veri setinin işlenmesi, ham verilerden elde edilecek ayırt edici öznitelikler ve karar aşaması olarak üç ana bileşenin ürünü olan çıktılar üretirler [54]. Özniteliklerin tespiti işleminde, dönüşüm tabanlı ya da karmaşık süreçli hesaplar içeren yöntemler bulunmaktadır [2, 17]. Bu tez çalışmasında, veri setinden, en az elemanla fakat en yüksek başarıyı verecek şekilde elde edilecek özniteliklerin tespit işleminde, dönüşüm tabanlı yöntemlerin tercihi son sıraya bırakılmıştır. Bu çalışmaya özgü olarak Histogram, Permütasyon Entropi, Yerel Tepe noktaları yöntemlerinin yanı sıra anlık zaman bölgesi özniteliklerinin de kullanıldığı 51 öznitelikli bir set kullanılmıştır. Seti güçlendirmek adına, geleneksel yöntemler arasında anılan DWT yöntemi çok çözünürlüklü ayrıştırma (Multi Resolution Analyze–MRA) ve temel istatistik parametreleri öznitelikleri de kullanılmıştır.

Karar aşamasında belirlenen makine öğrenme yöntemi, tezin amacı doğrultusunda, yüksek başarımlı elde edecek ve işlem hızı da en az olacak şekilde bir modelin kullanımını gerektirmiştir ki bu noktada, yüksek sınıflandırma ve genelleme başarımlı literatürdeki birçok alanda kanıtlanmış olan ELM yöntemi tercih edilmiştir [53]. Bu yöntemde oluşabilecek bazı dezavantajların giderilmesi amacıyla temel yöntemin geliştirilmiş versiyonları olan Seyrek Bayes (SB) ELM yöntemi ve ağırlıklandırılmış (Weighted) ELM (W–ELM) yöntemleri kullanılmıştır [55, 56].

Tez çalışması genel çerçevesi ile ele alındığında ortaya koyduğu katkıları şu şekilde sıralamak mümkündür:

- Öznitelik çıkarım aşaması tez boyunca kapsamlı olarak üzerinde çalışılmış bir başlıktır. Bu başlık altında Histogram, Permütasyon Entropi, Yerel Tepe noktaları ve anlık zaman bölgesi özellikleri olarak adlandırılan yöntemler önerilmiştir. Ayrıca Fisher

Vektör (FV) kodlama katkısı da bu aşama için önerilen yöntemler listesine dahil edilmiştir. Tüm bu yöntemlerden elde edilen öznitelik seti ve ek olarak FV kodlama zenginleştirilmesi ile GKO sınıflandırma işlemini yüksek başarımlı çıktı ile gerçekleştiren akıllı bir model, literatüre bu tez çalışması ile kazandırılmıştır.

- Karar aşamasını oluşturan ve önerilen modelin en temel noktasını betimleyen sınıflandırıcı yapısında, ELM ve geliştirilmiş versiyonları olan W-ELM ile SB-ELM kullanılmıştır. Bu yöntemlerin ve makine öğrenme perspektifinin GKO sınıflandırma alanına getirdiği işlem hızı ve genelleme başarımı artıları da çalışmanın önemli katkılarını oluşturmaktadır. Yukarıda ayrıntıları verilen öznitelik setlerini giriş verisi olarak kullanarak üstün çıkış üreten ve ELM algoritmaları içeren makine öğrenme tabanlı akıllı sınıflandırıcı modelleri de bu tez çalışmasının literatüre katkıları olarak vurgulanabilir.

1.4. Tezin Yapısı ve Organizasyonu

Bu tezin amacı Türkiye iletim sisteminden elde edilmiş gerçek güç kalitesi olay verileri setinin tanımlama ve sınıflandırma işlemlerini makine öğrenme perspektifi ile gerçekleştirecek kapsamlı bir model belirlenebilmesidir. Bu amaca yönelik olarak, Bölüm 1 ile verilen giriş kısmını takiben, çalışmanın teorik alt yapısını oluşturmak adına örüntü tanıma sistemi bileşenlerinin temeli olan materyal yani güç kalitesi olay verilerine ait kavramların standartlar ışığında sunulduğu güç kalitesi olay tanımlarına Bölüm 2 ile değinilmiştir. Burada, problemin temelini oluşturan güç kalitesi kavramının ne olduğu, bozulma olayları ve düşük güç kalitesinin sahada ortaya koyduğu olumsuz etkiler anlatılmıştır.

GKO tanımları ve kavramsal bilgilerin verilmesinin ardından, güç kalitesi olayları veri seti anlatımını içeren Bölüm 3 ile öncelikle tez çalışmasının erken dönemlerinde ön deney ve testlerin gerçekleştirildiği benzetim model anlatılmış ve Türkiye iletim hattı olay verilerinin temin edilmesinden başlayıp işlenecek hale getirilmesine kadar olan süreçler detaylı olarak açıklanmıştır. Ayrıca gerçek verilere değinilmeden önce, Türkiye iletim sistemi hakkında özet bilgiler verilmiştir.

Tez çalışmasında önerilen bütüncül modelin tüm bileşenlerini içeren metodoloji alt yapısı, akıllı örüntü tanıma metodolojisi başlığı ile verilen Bölüm 4 ile açıklanmıştır. Bu bölümde, Öznitelik Çıkarımı ve Akıllı Sınıflandırıcı Yapıları başlıkları altında örüntü tanımanın önemli iki bileşenine ait metodolojik alt yapı sunulmuştur. Kullanılan öznitelik çıkarım yöntemleri ve makine öğrenme tabanlı sınıflandırıcılar ELM, SB-ELM ve W-ELM

yöntemlerine ait kavramsal açıklamalara bu bölümde yer verilmiştir.

Bulgular ve inceleme başlığı ile verilen Bölüm 5 ile öncelikle öznitelik veri setlerinin analizleri sunulmuştur. Önerilen modellerin değerlendirme yöntemleri ve başarımlarının verilmesinin ardından, deneysel sonuçlara geçilerek, her yöntem için ayrı ayrı gerçekleştirilen deney sonuçları bu bölümde listelenmiştir.

Tartışma ve sonuçların verildiği Bölüm 6, tez çalışmasının genel bir değerlendirmesini ve sonuçlar hakkında yapılan yorumları içermektedir. Ayrıca gelecek çalışmalara ait önerilere de ışık tutan bu bölüm, tez süresince oluşturulmuş bazı yayınların bilgisi ile son bulmaktadır.



2. GÜÇ KALİTESİ OLAY TANIMLARI

Bu bölümde, güç kalitesi problemlerine ait temel bilgiler açıklanacaktır. Tez çalışmasında analizleri gerçekleştirilen 4 bozulma türü olan; gerilim çökmesi, gerilim sıçraması, gerilim kesintisi ve harmonik bozulmalarının yanı sıra sahada gerçekleşebilen diğer bozulma türleri de standartlarda belirtilen özellikleri ile birlikte sunulacaktır. Bu bölümde öncelikle, güç kalitesi kavramı ele alınarak, temel güç kalitesi hakkındaki tanımlar verilecektir. Devamında ise güç kalitesi bozulma türleri ile ilgili bilgilerin verilmesini takiben, güncel çalışmalar ışığında, düşük güç kalitesinin olumsuz etkilerini gösterir bir takım veriler özet olarak aktarılacaktır. Güç kalitesi olay tanımlamaları, TEİAŞ güç kalitesi izleme merkezinde yapılan analizlerde dikkate alınan Elektik–Elektronik Mühendisleri Enstitüsü (The Institute of Electrical and Electronics Engineers–IEEE) IEEE-1159-2009 [14] standardı ve Uluslararası Elektroteknik Komisyonu (International Electrotechnical Commission–IEC) IEC-61000-4-30 [57] standardındaki gerilim olayları ve değişimleri tanımlamasını da kapsayan TS EN 50160 standardına uygun teknik bilgiler çerçevesinde açıklanacaktır [58].

2.1. Güç Kalitesi Kavramı

Güç kalitesi tarif edilirken, birçok kaynak farklı ve hatta kafa karıştırıcı tanımları ileri sürmüşlerdir. IEEE terimler sözlüğünde geçen güç kalitesi tanımı şöyledir [59]:

“Bir hassas alıcının çalışma şekline uygun olarak, performansını olumsuz etkilemeyecek şekilde o alıcıya elektriksel güç sağlayarak, korumasını gerçekleştirmektir.”

Bu tanımdan harmonik akım bozulmasının sadece hassas cihazlara zarar verdiği şartlarda güç kalitesi problemi sayılabileceği anlayışı çıkarılabilmektedir. Ayrıca tanımın diğer bir kısıtlaması da sonucu sadece cihaz performansı ile değerlendirmesidir.

IEC güç kalitesini, IEC 61000-4-30 standardında şu şekilde tanımlamaktadır [57]:

“Bir elektrik sisteminde, belirli bir noktadaki elektriksel karakteristiklerin, bir grup referans teknik parametreye göre değerlendirilmesidir.”

Bu tanım güç kalitesini alıcının performansı ile ilişkilendirmez ama süreci ölçme ve bir takım standartlara uymaya dayandırmaktadır.

Bu çalışmada güç kalitesi tanımı Bollen’in [4] çalışmasındaki şekliyle, aşağıdaki gibi kullanılmıştır:


Güç kalitesi; gerilim kalitesi ve akım kalitesi kavramlarının bir kompozisyonu olarak

tarif edilir. Gerilim kalitesi, gerçek gerilimin ideal gerilim şeklinden uzaklaşma yönünde oluşturduğu değişimleridir, akım kalitesi ise bu tarifi akıma uyarlanmış halidir. İdeal akım ve gerilim için en temel tanımlama aşağıdaki gibi yapılabilir [4]:

“Nominal değerlerinde, sabit genlik ve sabit frekansta salınım yapan sinüzoidal dalga şekline sahip olan akım ve gerilimlerdir”.

İdeal akım dalga şeklinden gerilim ile aynı frekans ve fazda olması da ayrıca beklenmektedir. Akım ve gerilimin ideal şekillerinden sapacak şekilde değişmesi *güç kalitesi bozulması* olarak tanımlanır. Güç kalitesi bozulması akım ya da gerilim sebebiyle oluşabilir. Bu ikisini net bir şekilde ayırmak mümkün değildir. Genel bir tanım olarak; gerilim bozulmaları şebeke merkezli oluşur ve potansiyel olarak tüketicileri etkiler, akım bozulmaları ise tüketici merkezli oluşur ve potansiyel olarak şebekeyi etkiler. Bu sınıflandırmanın da hala eksik yönleri mevcuttur, örnek olarak büyük güçlü bir indüksiyon motorunun kalkışı düşünülürse; bu durum şebekeden aşırı akım çekilmesine neden olur. Şebeke tarafından bakıldığında bu durum bir akım bozulması olarak görülür. Bununla birlikte oluşan gerilim düşmesi aynı baradan beslenen diğer bir tüketici için gerilim bozulması olarak görünür. Şebeke işletmecisi açısından bu durum bir akım bozulmasıdır, ancak diğer tüketici için ise bir gerilim bozulmasını ifade etmektedir. Görüldüğü gibi yüksek güçlü bir motorun devreye alınması sonucu oluşan etki, farklı tüketiciler için konumlarına göre farklı bozulma çeşitlerini ortaya çıkarmaktadır. Bu kavram karmaşası nedeniyle literatürde, ayrı ayrı gerilim ve akım bozulması kavramları kullanmak yerine *güç kalitesi* terimi tercih edilmektedir [4].

Güç kalitesi incelemelerinde, bozulmalara ilişkin bir diğer önemli ayırım da olaylar (*events*) ve değişimler (*variations*) arasındadır. Bu çalışmada güç kalitesi bozulma olaylarını ifade etmek için “*olay*” kavramı kullanılmıştır. Olaylar, başlangıcı ve bitişi tanımlı olan belirli süreli bozulmalardır. Değişimler ise, sürekli durum ya da yarı sürekli durum bozulmalarıdır ve bu nedenle zamanın her anında ölçülebilmektedir. Şekil 2.1, bu sınıflandırmaya ait blok şemasını göstermektedir.




Şekil 2.1: Güç kalitesi bozulmalarının kavramsal sınıflandırması

Güç kalitesi bozulma değişimine tipik bir örnek olarak sistem frekansındaki değişimler gösterilebilir. Ülkemizde anma frekans değeri 50 Hz’dir, ancak bu değer daima ± 1 Hz’i bulabilen bir farkla değişim gösterir. Güç kalitesi bozulma olayına tipik bir örnek olarak ise “kesinti” verilebilir. Kesinti olayı süresince tüketici tarafındaki gerilim sıfırdır ya da standartlarda belirtilmiş olan alt sınır değerinin altındadır. Kesinti olayını ortaya koyabilmek ve izleyebilmek için bir kesinti olana dek beklenmelidir. Oysa değişimler zamanın her anında ölçülebilir.

2.2. Güç Kalitesi Bozulma Olayları

Olaylarla ilgili bilgiler verilmeden önce, IEEE 1159–2009 standardının önerdiği ve gerilim çukuru, tepesi ve kesintisi ile ilgili genlik–süre değerlerini gösteren bölütlemenin sunulmasının uygun olacağı düşünülmüştür. Şekil 2.2 ile görülebileceği üzere:



Şekil 2.2: IEEE 1159 Standardının önerdiği genlik-süre düzleminde olayların sınıflandırılması

- ✓ “Ani” sınıflama etiketi 0,5 – 30 periyot süresince,
- ✓ “Anlık” sınıflama etiketi 30 periyot – 3 s süresince,
- ✓ “Geçici” sınıflama etiketi 3 s – 1 dk. süresince,
- ✓ “Sürekli” sınıflama etiketi ise 1 dakikadan daha uzun süre boyunca,

gerçekleşen olaylar için kullanılmaktadır. İzleyen alt başlıklarda, güç kalitesi olay türleri “gerilim olayları” özelinde anlatılmıştır.

2.2.1. Gerilim Çukuru

Gerilim çukuru (“*Voltage Sag*” ya da “*Voltage Dip*”), IEEE 1159–2009 standardında; nominal gerilimin etkin değerinin %10 – %90’ı arasına düştüğü bir bantta, 0,5 periyottan 1 dakikaya kadar süre ile bulunduğu durum olarak tanımlanmaktadır [14].


Gerilim çukuru olayı, Şekil 2.2’de gösterildiği gibi ani, anlık ve geçici olmak üzere üç sınıfa ayrılmaktadır. Uluslararası teknik komitelerin önerdiği bu süreler, sahada kullanılan koruma cihazlarının işletme şartlarına da yansıtılmıştır. Gerilim çukuru, ilgili standartlarda genlik değeri ölçütü ile incelenmektedir. IEEE 1159–2009 standardına özgü değerler 0,1 pu (birim değer - per unit) ve 0,9 pu olarak belirtilmiştir. Herhangi bir unsurun pu değeri (2.1) kullanılarak hesaplanır.

$$pu \text{ deęer} = \frac{\text{Geręek deęer}}{\text{Baz deęer}} \quad (2.1)$$

Çukur genlięini tarif ederken kullanılan terminoloji kafa karıştııcı bir hal alabilmektedir. Şöyle ki; “%20 genlikli” bir çukur, etkin deęeri 0,8 pu ya da 0,2 pu olan bir gerilim olayına işaret edebilir. IEEE ve IEC organizasyonları, oluřturdukları standartlarda bu durum için *arda kalan* ya da *artık* gerilimin kullanılmasını işaret etmişlerdir. Tıpkı, herhangi bir özel durum belirtilmeden verilen bir gerilim deęerinin faz–faz gerilimine karşılık gelmesi gibi, yüzdelik deęerle verilen bir çukur genlięi de olay sırasında seyreden artık gerilim deęerine karşılık gelir. Örnek olarak, %80 genlikli bir çukur, olay sırasında 0,8 pu deęerinde bir gerilim seviyesinin oluřtuęunu belirtir. Burada, genlik hesabında kullanılan nominal ya da referans deęerin hangi deęer kabul edileceęi hakkında bir soru işareti oluřmaktadır. İlgili standartlarda ortaya konmuş yönelim; AG hatlarda, belirtilen nominal deęerin kullanılması, OG ve YG hatlarda ise hattın tanımlanmış gerilim seviyesi deęerinin kullanılması gerektięi yönündedir. Örneęin, 380 kV olarak bilinen bir iletim hattında meydana gelen %80’lik gerilim çukuru, olay sırasında 304 kV seviyesine kadar inen bir artık gerilimle sonuçlanan bozulmayı ifade etmektedir [14].

Çukur olayı, ticari ve endüstriyel tüketicileri geniş çapta etkileyen güç kalitesi problemlerinin en sık görüleni ve en önemlisi olarak kabul edilmektedir. Çoęu zaman aydınlatma şiddetindeki azalmalar dışında gözlemlenemeyen yapıları olsa da, özellikle endüstriyel süreçleri duruřa geçirecek kadar güçlü sonuçlar doğurabilmektedir.


Gerilim çukurlarının olası etkileri arasında; sistemi duruřa geçirebilmeleri, verimi azaltmaları ve alıcıların–özellikle de elektrik motorlarının–çalışma ömürlerinin azalmasına neden olmaları gibi problemler sayılabilir. Bu nedenle bu tür bozulmalar endüstriyel süreçlerde ciddi bir maliyet kaybına neden olabilmektedir [44]. Şekil 2.3, gerilim çukuru olayına örnek teşkil eden gerçek bir dalga şeklini göstermektedir. TEİAŞ güç kalitesi izleme yazılımında *kısa süreli çukur* olarak kayıtlara geçen bu olay sahada 34,5 kV barada, tek faz toprak arızası sonucu meydana gelmiştir. Arızanın gerçekteşmedięi b ve c fazlarında da gerilim tepesi oluřmuştur.




Şekil 2.3: Örnek bir çukur olayı

Gerilim çukur olayları genellikle doğal olaylardan ve sistemde kullanılan donanımların hasar görmesinden kaynaklanır [4]. Bu tip problemler çoğu zaman iletim ya da dağıtım hat-tında arıza oluşmasına neden olurlar. Örnek olarak, paralel fider devresinde meydana gelen bir arıza, şalt sahası baraları ve diğer fiderlerin tümünde gerilim düşmesi meydana getirebilir ve bu durum arıza düzeltilene kadar devam eder. Aynı durum, iletim hattının herhangi bir yerinde meydana gelen bir arıza için de söz konusu olacaktır. İletim ve dağıtım hatlarında oluşan arızaların çoğu *tek faz toprak* arızalarıdır ki, bu durum gerilim çukuru olayının önemli nedenlerinden birisidir.

Gerilim çukurları ayrıca büyük güçlü yüklerin anahtarlanması ve büyük ölçekli elektrik motorlarının kalkışı sırasında da meydana gelmektedir [4]. Şekil 2.4 ve Şekil 2.5, [60] ça-lışmasında ayrıntıları belirtilen benzetim modelinden elde edilen ve asenkron motor kalkışı sırasında meydana gelen gerilim çökmesi olayına ait grafikleri göstermektedir. Sırasıyla, 3 faz gerilim dalga şekilleri ve rms değişimlerinin verildiği grafiklerde olayın zamanın 0,1 sa-niye değerinde başladığı görülebilmektedir. İlgili çalışmada belirtildiği üzere, verilen örnek olay, AG baradan beslenen 75 kW (100Hp) 3 fazlı bir asenkron motorun yol verme anında 11 kV OG barada oluşturduğu çukur olayını benzetimler.



Şekil 2.4: Asenkron motor kalkışı ile oluşan çukur olayı 3 faz gerilim değişimleri



Şekil 2.5: Asenkron motor kalkışı ile oluşan çukur olayı 3 faz gerilim rms değişimleri

Tablo 2.1, gerilim çukuru ile ilgili özet bilgileri ve bu olayı engelleyebilmek adına başvurulabilecek bazı çözüm önerilerini sunmaktadır. Sahada en sık karşılaşılan arızaların sonucunda gerçekleşen gerilim çukuru olayını kavramsal olarak iletim ve dağıtım hatlarını kesintisiz güç kaynakları ile destekleyerek ortadan kaldıracabileceği savı söylene de bu çözüm alternatifinin ekonomik açıdan uygulanabilirliği bulunmamaktadır.

Tablo 2.1: Gerilim çukur olayına ait özet bilgiler

Genlik	: 0,1 - 0,9 pu
Kaynak	: Sistem arızaları ve son kullanıcılar tarafından büyük yüklerin devreye alınması
Süre	: ½ periyot - 1 dakika
Belirtiler	: Arıza ya da duruşa geçme
Çözümler	: Sabit Gerilim Transformatörleri, Kesintisiz Güç Kaynakları, Dinamik Gerilim Düzenleyiciler

2.2.2. Gerilim Tepesi

Gerilim tepesi (*Voltage Swell*), şebeke frekansındaki gerilimin rms değerinde meydana gelen, 0,5 periyot ila 1 dakika süresince gerçekleşen, 1,1 pu değeri üzerindeki bir artış olarak tanımlanmaktadır. Temel olarak gerilim çökmesi olayının tam tersi bir karakteristiğe sahiptir. Genel olarak genlik değerlerinin 1,1 pu ve 1,2 pu olduğu söylenebilir [14].


Gerilim tepe olayları, meydana geldikleri sürenin yanı sıra genliklerine göre de sınıflandırılırlar. Tablo 2.2 ile IEEE 1159–2009 standardının önerdiği sınıflandırma gösterilmiştir.

Tablo 2.2: Gerilim tepesi kategorileri (IEEE 1159–2009)

Gerilim Tepe Türü	Genlik	Süre
Ani	1,1 - 1,8 pu	0,5 - 30 periyot
Anlık	1,1 - 1,4 pu	30 periyot - 3 s
Geçici	1,1 - 1,2 pu	3 s - 1 dk.

Sistemde gerçekleşen herhangi bir arıza boyunca güç kalitesi bozulmalarının önemli bileşenleri; sistem empedans fonksiyonu, arızanın oluşma yeri ve devre topraklama yapısıdır. Gerilim tepesinin şiddeti de bu bileşenlere bağlı olarak değişir. Topraklamasız bir sistemde *tek faz toprak* arızası süresince, arızasız hatların faz gerilimleri 1,8 pu değerini aşabilmektedir. Diğer taraftan şalt sahası transformatörleri çoğunlukla üçgen-yıldız biçiminde bağlıdır ve bu bağlantı tipi arıza akımının izlediği sıfır dizi yolu boyunca düşük bir empedans oluşumunu sağlayacaktır. Bu nedenle, şalt sahasına yakın tesis edilmiş topraklı bir sistemde arızasız fazlarda herhangi bir gerilim yükselmesi oluşmamaktadır [4].

Şekil 2.6, örnek bir gerilim tepesi dalga şeklini göstermektedir. Bu olay 34,5 kV kademesinde gerçekleşmiş ve TEİAŞ güç kalitesi izleme sistemine *kısa süreli gerilim tepesi* olarak kaydedilmiş gerçek bir tepe olayıdır.



Şekil 2.6: Örnek bir tepe olayı

Gerilim çukuru olaylarına benzer şekilde, gerilim tepeleri de sistem arızalarına bağlı olarak ortaya çıkmaktadır. Özellikle büyük yükler devre dışı kalırken veya büyük kapasitör grupları devreye girerken gerilim tepeleri meydana gelmektedir. Bununla beraber gerilim tepelerinin görülme sıklığı gerilim çukurları kadar yoğun değildir [14, 61].

Gerilim tepesinin belirtileri, çökme gibi kolay fark edilebilir olmasa da tesislere verdiği zarar ondan çok daha yıkıcıdır. Sebep olabildiği aşırı ısınma senaryoları işletmeler için tehdit edici bir unsurdur.


Tablo 2.3 ile gerilim tepesine ilişkin özet bilgileri içeren bir dizin verilmiştir.

Tablo 2.3: Gerilim tepesi olayına ait özet bilgiler


Genlik	: 1,1 - 1,8 pu
Kaynak	: Sistem arızaları ve son kullanıcılar tarafından büyük yüklerin devreden çıkarılması
Süre	: ½ periyot - 1 dakika
Belirtiler	: Arıza ya da kapama
Çözümler	: Sabit Gerilim Transformatörleri, Dinamik Gerilim Düzenleyiciler

2.2.3. Gerilim Kesintisi

Kesintiler, IEEE 1159–2009 standardında anlık ve uzun süreli olmak üzere, oluşum süresine göre sınıflandırılırlar. Bununla birlikte *kesinti* kavramı sıklıkla “anlık kesinti” kavramını ifade etmek için kullanılır. Uzun süreli kesinti ise “sürekli kesinti” olarak ifade edilir [4, 14]. Kesintilerin sürelerine göre sınıflandırılmalarının nedeni, kesinti boyunca gerilim genliği nominal değerinin %10’unun altında kalmasıdır. EN 50160 standardında ise 3 dk.’dan kısa süren kesintiler *kısa kesinti*, 3 dk.’dan uzun süren kesintiler ise *uzun kesinti* olarak tanımlanmıştır. IEEE 1159–2009 standardında detaylı olarak 3 sınıfa ayrılabilirler: Ani (0,5 periyot–30 periyot arası), anlık (30 periyot–3 s arası) ve geçici (3 s–1 dk.) kesintiler. Şekil 2.7, gerilim kesintisi olayı için örnek bir dalga şekli göstermektedir. Verilen gerilim kesintisi örneği, TEİAŞ güç kalitesi izleme sistemine kısa süreli kesinti olarak kaydedilen ve kısa devre arızası sonucu meydana gelen yaklaşık 0,85 s süresince devam eden gerçek bir kesinti olayını göstermektedir. Ayrıca Şekil 2.8, uzun süreli bir gerilim kesintisi olayını örneklemek amacıyla, TEİAŞ güç kalitesi izleme sistemlerinde kaydedilmiş bir uzun süreli kesintiye ait dalga şeklini sunmaktadır. Burada olayın süresi ölçüm pencere genişliği olan 3 saniyelik dilimi kapsamaktadır.



Şekil 2.7: Örnek bir kesinti olayı



Şekil 2.8: Örnek bir uzun süreli kesinti olayı

Gerilim kesintisi, tesisler üzerindeki hissedilir etkisi en fazla olan güç kalitesi olayıdır. Gerilim kesintileri bütün alıcıları enerjisiz bırakır ve özellikle endüstriyel tesislerde üretimin aksamasına neden olacağından, büyük maddi kayıplara neden olabilmektedir. Kısa süreli kesintiler, 1 dakikaya kadar olan, gerilimin nominal genlik değerini %10'un altına düşüren bozulmalar olarak tanımlanmaktadır. Süre olarak 1 dakikalık bir kesintinin oluşması dahi endüstriyel ortamlarda ciddi maddi kayıpların oluşmasına yol açabilmektedir.

Kesintiler genellikle, devre kesicilerin bir arıza sonucu oluşan gerilim çukurlarını algılayıp devreyi kesmelerini takiben meydana gelirler. Kısa süreli arızanın düzeltilmesi sırasında, koruma cihazlarının yeniden kapama kapasitesine bağlı olarak gerilim kesintisi olayının süresi sınırlanacaktır. Genellikle 30 periyottan az süren ve kalıcı olmayan bir arızanın sebep olduğu devre kesme ve ani tekrar kapama işlemleri sırasında oluşabilecek kesinti, bu süre dahilinde sınırlanabilmektedir. Koruma cihazının gecikmeli tekrar kapaması ise, anlık ve geçici kesintiye sebep olabilmektedir [12, 59, 62].

Kesintilerin olumsuz etkileri genel olarak aşağıdaki maddelerde özetlenebilir:

- ✓ Özellikle hassas elektronik devre/cihazların zarar görmesi,
- ✓ Koruma cihazlarının gereksiz olarak arıza açması gerçekleştirilmesi,
- ✓ Bilgi kaybı,

- ✓ Bilgi işleyen donanımların zarar görmesi gibi olumsuz sonuçlara neden olabilirler.

Tablo 2.4 ile gerilim kesintisine özgü genel bilgileri içeren açıklamalar verilmiştir.

Tablo 2.4: Gerilim kesintisi olayına ait özet bilgiler

Genlik	: 0,0 - 0,1 pu
Kaynak	: Sistem arızaları, Arıza sonrası yeniden kapama
Süre	: ½ periyot - 1 dakika
Belirtiler	: Tesisin devreden çıkması
Çözümler	: Kesintisiz güç kaynakları, Lokal enerji üretimi, Enerji depolama


2.2.4. Harmonikler

Elektrik güç sistemlerinde bulunan doğrusal olmayan yükler, iletim ve dağıtım sistemlerinde önemli harmonik kirliliklere neden olmakta ve tüketiciye sunulan enerji kalitesini olumsuz etkilemektedir [63]. Doğrusal olmayan bir yük, uygulanan gerilime karşılık empedans değeri değişen bir yapıda olduğu için bu yükün çektiği akım da doğrusal olmayan bir yapıdadır.

1893 yılında, Birleşik Devletlerin Connecticut eyaletinin başkenti Hartford şehrinde kurulu bir elektrik motorundaki ısınma sorununa yoğunlaşan mühendisler, sorunun asıl kaynağının motoru besleyen güç sistemindeki rezonans olduğunu gözlemlediler. Bu rezonans, motor ve 20 km ötede kurulu olan generatör arasında oluşmuştu. Sistemdeki bu rezonansa harmoniklerin neden olduğunu tespit etmişlerdi. Bu tarihten önce aynı bölgedeki başka bir şehir olan Portland'da elektrikçiler, hat frekans harmoniklerinin oluşturduğu farklı bir iletim hattı sorunu ile uğraşmışlardı. Bu olaylar, yazılı tarihlerde kayıtlı ilk güç sistemi harmonik analizleridir. Avrupa'da bulunan elektrik üreticileri o dönemlerde yüksek frekans kullanmadıklarından dolayı bu sorunlardan etkilenmemişlerdir. Gelişen teknoloji ile birlikte harmonik problemi dünya çapında bir sorun haline gelmeye başlamıştır. Sonraki dönemlerde, harmonikli dalgaların tespit edilmesi ve engellenmesi için çeşitli yöntemler geliştirilmiştir [64, 65].

Elektrik tesislerinde, akım ve gerilimin dalga şekli sinüzoidal ve temel frekanslı bir değişime sahip olmalıdır. Bunun sağlanması için şebekeye bağlı yüklerin sinüzoidal bir kaynaktan beslenmesi ve doğrusal yapıda olması gerekmektedir. Doğrusal yüklerde akım ve

gerilimin dalga şekli birbirleriyle uyumlu olmasına rağmen doğrusal olmayan yüklerde şebekeden çekilen akım ve gerilimin dalga şekli sinüzoidal yapıdan uzaklaşır [64, 66].



Şekil 2.9: Saf sinüzoidal gerilim ve örnek harmonik bileşenler

Alternatif akım şebekesindeki sinüzoidal akım ve gerilim dalgaları periyodik dalga şekillerine birer örnek teşkil etmektedir. Tüm periyodik dalgalar kendi frekanslarının katlarındaki sinüs dalgalarının toplamına eşittir. Periyodik dalgayı oluşturan bu parçaların her birine *harmonik* denilmektedir. Temel bileşen olarak adlandırılan birinci harmonik, ana dalga ile aynı frekanstadır. İkinci harmonik ana dalga frekansının iki katı değerinde bir frekansa sahiptir. Özet olarak n . harmoniğin frekans değeri ana frekansın n katı değere sahiptir. Ülkemizde temel frekans 50 Hz değerinde olduğu için bu frekans değerinde harmonikler 50 Hz değerinin tam katlarında oluşmaktadır. Şekil 2.9, harmonik içerikli örnek bir gerilim dalga şeklini ve ona ait temel saf sinüzoidal bileşenle birlikte 3. ve 5. harmonik dalga şeklini göstermektedir. Grafikler matematiksel hesaplamalar kullanılarak oluşturulmuştur.

Endüstride yaygın olarak kullanılan harmonik kaynağı doğrusal olmayan yükler ve diğer harmonik kaynakları aşağıda listelenmiştir [67–69]:


- ✓ Doğrultucular, eviriciler, kaynak makineleri, ark fırınları, pota ocakları, gerilim regülâtörleri ve frekans çeviriciler,
- ✓ Motor hız denetim cihazları,

- ✓ Doğru akım ile enerji iletimi,
- ✓ Kesintisiz güç kaynakları,
- ✓ Elektrikli taşıtların yaygın kullanımıyla, bu cihazların akü şarj devrelerinin etkileri,
- ✓ Enerji tasarrufu amacıyla kullanılan çeşitli yöntemler,
- ✓ Özel uygulamalarda kullanılan ve doğrudan frekans çeviricilerle beslenen momenti büyük, düşük hızlı motorlar,
- ✓ Gaz deşarjlı aydınlatma elemanları,
- ✓ Statik VAR generatörleri,
- ✓ Elektronik balastlar,
- ✓ Fotovoltaik sistemler.

Harmonikler, her bileşenin genlik ve faz açıları ile sunumundan oluşan *harmonik spektrumu* ile gösterildikleri gibi standartlarda, harmonik bozulmaların sayısal olarak ifade edilmesinde Toplam Harmonik Bozulma (THB) kavramı kullanılmaktadır. THB kavramında oluşabilen bazı dezavantajlar neticesinde IEEE-519 harmonik standardı, Toplam Talep Bozulması (TTB) olarak başka bir terim tanımlamıştır. Bu terim THB ile aynı amacı taşımakla birlikte; bozulma, seçilen bir yük akımının yüzdesi olarak ifade edilmektedir. Harmonik bozulma ile ilgili detayları tarifler, akım ve gerilim için bozulma seviyeleri IEEE 519–1992 standardı ile sunulmuştur [14].

2.2.5. Gerilim Kırpışmaları

Gerilim kırpışması, genliği nominal gerilimin 0,95–1,05 pu değerleri arasında olan hızlı ve sistematik gerilim değişimleridir. Ana dalgaya etki eden bozucu etkilerinin hızları 25 Hz değerinden aşağıdadır. Bu güç kalitesi olayının en belirgin etkisi aydınlatma kaynaklarının ışığında kırpışma oluşturmalarıdır [14]. Şekil 2.10, bu olaya ait örnek bir dalga şeklini göstermektedir. Örnek dalga şekli, TEİAŞ güç kalitesi izleme sistemi kayıtlarından alınan, beslediği yükler arasında ark fırını varlığı yoğun olan bir 34,5 kV baradaki a fazının kırpışma etkisini sunmaktadır.



Şekil 2.10: Örnek bir gerilim kırpışması olayı

Ark fırınları, kaynak makineleri gibi yük akımında ve reaktif bileşende ani ve hızlı değişimler meydana getiren cihazlar gerilim salınımlarına (*flicker*) neden olurlar. Bu terimin kullanılmasının nedeni, olayın sahaya yansıyan temel sonuçlarından olan aydınlatma cihazlarındaki ışık yoğunluğunun *kırpışma* etkisinin insan gözüyle görülebilecek şekilde farkedilir kırpışmalar oluşturmalarıdır [12, 14]. Aşağıda listelenen yüklerin de kırpışma oluşturmaya etkisi vardır:

- ✓ Doğrultucular, eviriciler, kaynak makineleri, ark fırınları, pota ocakları, gerilim regülâtörleri ve frekans çeviriciler,
- ✓ Güç elektroniği dönüştürücüleri,
- ✓ Döner fırın sürücüleri,
- ✓ Sarıcı düzenekler,
- ✓ Büyük güçlü motorlar.

Bu güç kalitesi bozulma olayının ortaya çıkarabileceği olası etkiler aşağıda şu şekilde sıralanmıştır:

- ✓ Elektrik ve elektronik donanımların zarar görmesine neden olarak büyük maliyetli sorunlara yol açabilmektedir,

- ✓ Röle ve kontaktörlerin yanlış çalışması sonucunda gereksiz arıza açmalarına neden olabilmektedir,
- ✓ Kesintisiz güç kaynaklarını istenmeyen yönde tetikleyerek bataryadan beslenir hale getirebilmekte ve bunun sonucunda sabit gerilime ihtiyaç duyan hassas elektronik cihazların problemli çalışmasına neden olabilmektedir.

Tablo 2.5 ile gerilim kırışması ile ilgili özet bilgiler sunulmuştur.

Tablo 2.5: Gerilim kırışması olayına ait özet bilgiler

Genlik	: 0,95 - 1,05 pu
Kaynak	: Hızlı akım değişimi gösteren yükler, Reaktif bileşenin hızlı değişmesi
Süre	: Aralıklı
Belirtiler	: Işık kırışması ve elektriksel cihazların zarar görmesi
Çözümler	: Seri kapasitörler, Statik Var Kompanzatörler, STATCOM yapıları

2.3. Düşük Güç Kalitesi ve Sahada Ortaya Koyduğu Olumsuz Etkiler

Günümüz üretim teknolojilerinin otomasyon kavramı ötesinde bireyden bağımsızlığının da endüstri 4.0 ile birlikte tartışılıyor olmasıyla, elektrik enerjisinin sürekliliğinin önemi vazgeçilmez başlıklar arasına girmiştir. Enerji kullanıcıları kabaca sınıflandığında; yerleşim yerleri, endüstriyel alanlar ve devlet/ticari hizmet sektörü gruplarından oluşmaktadır. Gruplanan bu tüketicilerin akıllı uygulamaları geniş anlamda kullanır hale gelmesiyle, kesinti ya da düşük güç kalitesi sonucunda oluşabilecek maddi kayıpların da kaydının tutulduğu daha belirgin bir süreç gelişmektedir. Üretim sistemlerinde, düşük güç kalitesi sonucunda meydana gelen önemli maddi kayıplar ya da teçhizatların zarar görmesi durumlarında firmalar, zararlarının tanzim edilmesine yönelik adımları kullandıkları akıllı analizör cihazlarla tespit ederek, sistem sağlayıcılarına fatura etme sınırına dek götürebilmektedir. Zararın tanzim edilmesine yönelik bu süreç zincirleme olarak, dağıtım firmalarından iletim ağı sistem işletmecisi kuruluşuna dek uzanabilmektedir. Ülkemizde elektrik iletim altyapısında, sistemin hem sahibi hem de işletmecisi olarak TEİAŞ görev yapmaktadır. Elektrik dağıtım altyapısı ise 21 farklı bölgeye ayrılarak özelleştirilmiş ve günümüzde tamamen özel sektör tarafından

işletilmektedir. Şekil 2.11, bu 21 bölgede dağıtım şebekesi tesis, bakım ve işletmesi görevini üstlenmiş enerji dağıtım şirketleri haritasını göstermektedir [70].




Şekil 2.11: Türkiye geneli elektrik dağıtım şirketleri haritası [70]

Elektrik iletim ve dağıtım alt yapısındaki bu yeni yapılanma ve müşteri portföyünün düne göre çeşitlilik kazanması neticesinde, düşük güç kalitesinin sahada ortaya koyabileceği olumsuz etkiler zincirleme olarak tüm taraflara yansımaktadır. Gerek dağıtım firmalarının müşterilerine karşı gerekse iletim tarafının firmalara karşı sorumlulukları sistemi son derece dinamik ve karmaşık bir hale dönüştürmüştür. Öyle ki meydana gelen bir arızanın müşteri, dağıtım firması ya da iletim tarafında oluşup sisteme yansması neticesinde arızanın kaynağının hangi tarafta olduğunu tespit etmek adına gelişmiş izleme sistemleri ve analizler gerekmektedir. Kesintiler, gerilim çukurları ya da diğer olayların ortaya çıkarabileceği maddi kayıplar sistemdeki her oyuncu için büyük önem teşkil etmektedir. Bu nedenle, düşük güç kalitesinin etkilerini her yönden ortaya koyan bir çok çalışma ve analiz raporu oluşturulmuştur [71–77].

Şekil 2.12 ile [77] çalışmasında özetlenen bir analize ait sonuçlar gösterilmiştir. Burada, güç kalitesi olay türlerine dayalı görülme sıklıkları yüzde değer olarak verilmiştir. Kaynağı EPRI tarafından yapılan bir çalışmaya dayanan bu analiz; Birleşik Devletler genelinde, 10 yılın üzerinde bir zaman dilimi süresince ticari ve endüstriyel tüketicilerden elde edilen güç kalitesi problemlerinin yorumlanması sonucunda ortaya çıkmıştır [78]. Tüketici tarafında meydana gelen güç kalitesi problemlerinin yaklaşık olarak yarısının gerilim düşmesi ya da yükselmesi kaynaklı olduğu görülmektedir. Takip eden problemlerin ilk sırasına harmonik

bozulmalar yerleşmiştir ve bunu sırasıyla kablolama ve topraklama problemleri, anahtarlama sonucunda meydana gelen geçici rejimler, yüklerin etkileşimi ve diğer nedenler takip etmektedir.




Şekil 2.12: Güç kalitesi problemlerinin türlerine göre görülme sıklıkları

2003 yılı verilerine göre Birleşik Devletler ve Avrupa Ülkeleri sanayi sektöründeki güç kalitesi problemleri, sırasıyla yılda 170 milyar dolar ve 55 milyar dolar seviyelerinde maliyet değerleri ortaya çıkarmıştır [77]. Ülkemiz özelinde meydana gelen güç kalitesi problemlerinin sektörel analizine ışık tutmak için hazırlanan [77] çalışması ile Türkiye'nin güneyinde bulunan endüstriyel bölgelerde gerçekleştirilen araştırma sonuçları sunulmuştur. Çalışma ayrıca, işletmelerdeki güç kalitesi farkındalık derecesini de ölçmeyi amaçlamıştır. Çalışmada; demir-çelik, enerji santrali, tekstil, kimyasal, gıda, plastik, otomotiv ve kağıt sektörleri içerisinden belirlenen 24 farklı endüstriyel işletme ile anket yapılmış ve cevaplar yorumlanmıştır. Cevaplara göre, yüzde 86 değerinde bir oranla işletmelerin gerilim düşümleri ve kesilmeleri kaynaklı güç kalitesi problemi yaşadığı, buna bağlı olarak üretim kaybı ve ekonomik zararlar yüz yüze kaldığı kanısına varılmıştır. Gerilim düşümü ve kesilmesi problemlerinin işletmelerde bir yıl içinde ortalama meydana gelme sıklığı, sırasıyla 78 ve 15 kez olarak kaydedilmiştir. Demir-çelik sektörü gibi büyük güçlü işletmelerde oluşabilecek ürün kaybı ciddi ekonomik kayıpları ortaya çıkarabilmektedir. Değerlendirilen birçok işletmenin gelişen teknolojiye ayak uydurmaya istekli olması çalışmanın umut veren bir sonucu olarak kaydedilmiştir [77].

Güç kalitesi bozulmaları ve düşük güç kalitesi, özellikle endüstriyel üretim süreçlerinin kesintili ya da uzun süreli durması, üretim çıktısında kalitesizliğe ve kayıplara, sürecin önemli parçası olan otomasyon cihazlarının sık arızalanmasına veya verim düşüklüğü gibi

önemli maddi kayıplara neden olabilmektedir. İletim ve dağıtım sistemlerinde kurulu olan kesici ve trafolar da düşük güç kalitesinden dolayı oluşan arızalara maruz kalmaktadır. 2004 yılında, tarım alanlarını yoğun olarak besleyen bir iletim bölgesinde, sulama yüklerinden kaynaklanan güç kalitesi problemleri sonucunda TEİAŞ 1,16 Milyon TL değerine ulaşan bir enerji satış kaybına maruz kalmıştır [79].

Şekil 2.13 ile TEİAŞ bünyesinde bulunan ve güç kalitesi bozulmaları nedeniyle kullanım dışı kalan trafolarla ait sayısal bilgiler verilmiştir. Trafo güç değerleri incelendiğinde, meydana gelen zararın büyüklüğü açık bir şekilde görülmektedir [79]. Söz konusu güç trafoları olduğunda satın alma maliyetlerinin katlanarak artması da sorunun boyutunu ortaya koymaya yetmektedir.



Şekil 2.13: Kullanım dışı kalan trafo verileri

Bu bölümde, güç kalitesi olay tanımları ilgili standartlar çerçevesinde anlatılmıştır. Ek olarak, düşük güç kalitesinin sahada oluşturabileceği olumsuz etkiler bir takım veriler ışığında aktarılmıştır. Yukarıda özetlenenlerle sınırlı olmayacak kadar büyük ölçüde faturalar ortaya çıkaran güç kalitesi problemlerini ülke çapında en aza indirmek için büyük ölçekli yatırım planları tasarlanmalıdır. Son yıllarda, TEİAŞ bünyesinde gerçekleştirilen araştırma faaliyetleri umut vaat eder niteliktedir. Ülkemizdeki iletim ve dağıtım hatlarından oluşan bütüncül sistemin tamamen akıllı şebeke özelliği taşıması için gerekli çalışmaların hız kazanması gerekliliği de ortadadır.

3. GÜÇ KALİTESİ OLAYLARI VERİ SETİ

Akıllı bir örüntü tanıma sisteminin temel yapı taşını, işlenen *veri seti* oluşturmaktadır. Tez çalışmasının bu bölümünde, önerilen yöntemlerin hazırlık sürecinde ve devamında kullanılan veri setleri detaylı olarak açıklanacaktır. Bölümün ilk alt başlığında, tez çalışmasının hazırlık sürecinde oluşturulan kapsamlı bir benzetim model ile elde edilmiş sentetik GKO üretici tanıtılacaktır. Çalışmanın başlangıç süreçlerinin test edildiği bu kapsamlı model ile önerilen algoritmaların uygunluğuna ait ön çalışmalar gerçekleştirilmiştir. Bölümün son alt başlığında ise Türkiye elektrik iletim sistemine ait önemli özellikler güncel veriler ışığında anlatılacak ve devamında tez çalışmasının bulgularının elde edildiği ve çıktıların üretmek üzere kullanılan veri seti detaylandırılacaktır. TEİAŞ ile gerçekleştirilen ikili bir anlaşma bağlayıcılığında elde edilen bu gerçek veri seti, 2009 yılında tamamlanan Milli Güç Kalitesi Projesi kapsamında temelleri atılan güç kalitesi izleme merkezinde görevli çalışma ekibinin işbirliği ile Türkiye genelindeki bir çok trafo merkezinin analizinin yapılması sonucunda oluşturulmuştur. Gerçek verilerin elde edilip, işlenecek son haline getirilmesine kadar olan süreçteki ön çalışmalar, yazılım ortamında oluşturulan kapsamlı benzetim model üzerinde test edilmiştir.

3.1. Olay Üretici Benzetim Modeli ile Oluşturulan Yapay Veriler

Olay verilerinin elde edilmesi işlemini gerçekleştiren benzetim çalışması ile ilgili parametreler Tablo 3.1 ile sunulmuştur.


GKO benzetim modeli 3 aşamalı olarak çalışmaktadır: (1) Olayların matematiksel eşitlikler yardımıyla üretilmesi, (2) Normalizasyon ve (3) İşlenecek son veri setinin oluşturulması. Her üç tasarım adımı da *MATLAB* yazılımı kullanılarak inşa edilmiştir. Oluşturulan benzetim modeli; çukur, tepe, kesinti, harmonik içerikli gerilim ve kırpışma olarak 5 temel olayı kullanıcının özgürce değiştirebileceği parametreleriyle oluşturabilmektedir. Benzetim modeli ile bunların yanı sıra, normal çalışma koşullarını betimleyen referans dalga şekli olarak saf sinüs işareti üretilmekte ve harmonik içerikli çukur ve harmonik içerikli tepe gibi iki birleşik olayı da kapsayarak toplamda 9 farklı sınıfa ulaşabilen bir veri seti tasarımı yapılabilmektedir. Oluşturulan tüm GKO türleri literatürde önerilen matematiksel eşitliklerin ışığında üretilmiştir [80, 81].

Tablo 3.1: GKO üreticine ait genel parametreler


Yöntem	: Matematiksel Model
Yazılım Ortamı	: MATLAB
Örnekleme ve Şebeke Frekansı	: 10 kHz ve 50 Hz
Periyot Başına Örnek Sayısı	: 200 Örnek/periyot
Olay Pencere Uzunluğu	: 1 saniye
Pencere Toplam Örnek Sayısı	: 10.001 Örnek
Olay Tür Sayısı	: 8 Tür Olay + Saf Sinüs
Pencere Tanımı	: Olay Öncesi+Olay+Olay Sonrası
Eklenebilen Gürültü	: 10 – 50 dB Arası

GKO üretici, 10 kHz anahtarlama frekansı ile örneklenmiştir. Burada örnekleme frekansı değeri, sahada ölçüm yapan cihazın çalışma frekansı olarak düşünülmüştür. Şebeke frekans değeri, ülkemizde kullanılan 50 Hz değeridir böylece bir periyot için üretilen işaret 200 örnekten oluşmaktadır. Her olay verisi, pencere mantığı kullanılarak oluşturulmuştur ve ölçüm süresi 1 saniye olarak belirlenmiştir. Bu parametreler sonucunda bir olay penceresinde 10.001 adet örnek bulunmaktadır. 1 saniyelik olay penceresi; olay öncesi süre, olay süresi ve olay sonrası süre olmak üzere üç porsiyondan oluşmaktadır. Burada her olay için pencere süresi eşit ve 1 saniye olmakla birlikte her veri satırı için olay süreleri otomatik olarak değiştirilmektedir. Olay süresi periyot aralığı, kullanıcı tarafından belirlenmekte ve böylece veri setini oluşturan her olay satırının birbirinden eşsiz özellikte oluşması sağlanmaktadır. Veri setinin gerçeklik vurgusunu arttırmak ve sınıflandırıcıların etkin değerlendirilmesini sağlamak amacıyla benzetim modelinde gürültü değeri atama seçeneği de bulunmaktadır. Kullanıcılar, 10 dB ve 50 dB aralığında gürültü değeri atayabilmektedir. Üretilen olay işaretlerini tek bir dosyada depolayan yazılımda, görsel çıktılarına da yer verilmiştir.


Aşağıda, Şekil 3.1–3.4 arasında sırasıyla çukur, tepe, kesinti ve kırpışma olaylarına ait örnek dalga şekilleri gösterilmiştir. 30 dB gürültü değeri için oluşturulmuş veri setinden elde edilen görseller olayın oluş anına odaklanmış şekilde gösterilmiştir.




Şekil 3.1: Benzetim model: Örnek gerilim çukur olayı



Şekil 3.2: Benzetim model: Örnek gerilim tepe olayı



Şekil 3.3: Benzetim model: Örnek gerilim kesinti olayı



Şekil 3.4: Benzetim model: Örnek gerilim kırışma olayı

Tez çalışmasında oluşturulan ve gerçek verilere çok yakın GKO işaretleri üretebilen benzetim modeli, kod dizini şeklinde hazırlanmıştır. Gelecek çalışmalarda üretece ait kod yapısı, kapsamlı bir grafiksel kullanıcı arayüzü şeklinde düzenlenecektir.

3.2. Türkiye İletim Hattı Olay Verileri

Tez çalışmasının bu alt bölümünde, Türkiye iletim hatlarından elde edilen gerçek veri setine ait tanımlar ve teknik detaylar verilmiştir. Veri seti oluşturma sürecine ait detaylar verilirken TEİAŞ ortaklığında yürütülen başlıklardan ve iletim hattına ait bazı kavramlardan söz edilecektir. Bu nedenle, anlatımlara başlarken Türkiye Elektrik iletim sistemine ait özet bilgilerin öncelikli olarak verilmesi tercih edilmiştir. Böylece, veri setinin temelini oluşturan ana yapının yani iletim sisteminin genel hatlarının betimlenmesi hedeflenmiştir. Takip eden alt başlıklarda, Türkiye elektrik iletim sistemi sahnesine ait detayların verilmesinin ardından, TEİAŞ Genel Müdürlük bünyesinde kurulu olan güç kalitesi izleme merkezinden elde edilen güç kalitesi olaylarına ait gerçek veri setinin detaylı tanıtımı yapılmıştır.

3.2.1. Türkiye Elektrik İletim Sistemi

Türkiye çapında, elektrik iletim sisteminin mülkiyet sahibi (Uluslararası literatürde, *Transmission Network Owner*) ve işletme sorumlusu (Uluslararası literatürde, *Transmission System Operator*) olarak TEİAŞ görev yapmaktadır. TEİAŞ sorumluluk alanı, ülke genelindeki elektrik enerjisine olan talebe zamanında karşılık vermek, kesintisiz ve aynı kalitede

devam eden bir elektrik enerjisi sağlamak ve 400 kV Çok Yüksek Gerilim (ÇYG) ile 154 kV yüksek gerilim (YG) elektrik sisteminin işletilmesini sağlamak olarak özetlenmiştir. Bunun yanı sıra, elektrik piyasasını mali olarak sağlıklı bir işleyiş içinde sürdürmek amacıyla Dengeleme Güç Piyasasının işletme sorumluluğu da kurumun faaliyetleri arasına girmektedir [82]. TEİAŞ ayrıca, iletim sistemine ait genişleme ve yenilenme çalışmalarına ait yatırımları da planlayıp uygulamaktadır. Gelecek planlamalar için hayati bir öneme sahip olan üretim kapasite vizyonu da kurum bünyesinde hazırlanmaktadır. Türkiye, kendi içine dönük ve kapalı bir elektrik iletim sistemine sahip olmadığı ve komşu ülkelerle olan enerji ticareti ilişkilerinde aktif olduğu için TEİAŞ, uluslararası enterkonneksiyon çalışmalarını da yürütmektedir.


İletim sistemi, üretim santrallerinden başlayarak gerilim seviyesi 36 kV üzerindeki enerji nakil hatları ile elektrik enerjisinin iletildiği tesislerden oluşmaktadır. 400 kV seviyesindeki ÇYG ve 154 kV seviyesindeki YG iletim hatlarına ek olarak sistemin ana aktörleri arasında 400/154 kV oto-trafolar ve 154/OG indirici trafolar sayılabilir. Türkiye iletim sisteminde, teknik ve ekonomik yönden sağladıkları katkılar nedeniyle kullanılan şönt reaktör, seri ve şönt kapasitör donanımı da mevcuttur. 2017 yılı TEİAŞ sektör raporunun verdiği bilgilerde, İletim sistemi gerilim seviyelerinin 400 kV ve 154 kV değerleri ile sınırlandırıldığı görülmektedir. Uluslararası enterkonneksiyon hatları ile bağlantılı olunan Gürcistan ve Ermenistan hatlarında gerilim seviyesi bu ülkelere uygun olarak 220 kV seviyesindedir [82].

Türkiye elektrik üretim ve iletim sisteminin yönetilmesinde, ana merkez Ankara ili Gölbaşı ilçesinde bulunan Milli Yük Tevzi İşletme Müdürlüğüdür. Bu merkezle koordineli olarak çalışan ve Kuzey Batı Anadolu, Orta Karadeniz, Güney Doğu Anadolu, Batı Anadolu, Orta Anadolu, Trakya, Doğu Anadolu, Doğu Akdeniz ve Batı Akdeniz olarak isimlendirilen 9 Bölgesel Yük Tevzi İşletme Müdürlüğü bulunmaktadır. Güç sistemi işletme otomasyon altyapısı, TEİAŞ SCADA / Enerji Yönetim Sistemi (EMS) adı verilen sistemdir. Bu otomasyon ve izleme sistemi, 400 kV gerilim seviyeli merkezlerin 154 tanesini, 154 kV gerilim seviyeli merkezlerin ise 493 tanesini kapsamaktadır. Ayrıca elektrik şebekesi ulusal yapısına iletim seviyesinden bağlanmış olan OG santrallerin ise büyük bir kısmını kapsamaktadır. 2017 yılı sonunda, SCADA sistemine entegre trafo merkezi sayısı 668'e ulaşmıştır [82].

Türkiye çapındaki ulusal elektrik iletim şebekesi; 2017 yılı sonu verilerine göre, 66.285 km uzunluğunda enerji iletim hattı, 727 adet iletim kademesi trafo merkezi, 1.750 adet büyük güç trafosu ve 163.181 MVA değerinde trafo gücü ile birlikte ülkemiz komşularıyla olan

transferi sağlayan 11 adet enterkonneksiyon iletim hattından meydana gelmektedir [82].

2017 yılı sonu verilerine göre TEİAŞ; 46.926,3 MW termik, 1063,7 MW jeotermal, 27.273,1 MW hidrolik, 6.516,2 MW rüzgar ve 3420,7 MW güneş olmak üzere toplamda 85.200 MW Türkiye toplam kurulu gücünü, 47.660 MW ani puant güç talebini, 295,5 milyar kWh elektrik enerjisi üretimi gerçekleştiren enterkonnekte sistemi kaliteli, kesintisiz ve sürdürülebilir olarak işletmektedir. TEİAŞ istatistiklerinden alınmış Şekil 3.5 ile gösterilen grafikte kurulu gücün 2006 – 2016 yılları arasındaki değişimi gösterilmiştir. 2017 yılı sektör raporunda belirtilen yıl sonu kurulu güç değerinin 85.200 MW olduğu göz önüne alındığında, bir yıllık artışın %8 seviyelerinde gerçekleştiği hesaplanabilir [82]. İstatistiklere yansıyan elektrik enerjisindeki kurulu güç artışının son yıllarda meydana gelen endüstriyel büyümeye de işaret ettiği söylenebilir. Bununla beraber, ülke bütününde yenilenebilir enerji potansiyelini kullanma yönünde sağlanacak artışla birlikte, ilerleyen yıllarda gerçekleşecek olan talep artışlarını da karşılama oranında yükselme kaydedilecektir.



Şekil 3.5: Türkiye kurulu güç değerinin yıllara göre değişimi [82].

Yıllara göre artma yönünde değişim gösteren elektrik dağıtım bölgeleriyle birlikte üretim santrallerinde de çok sayıda artış olmuştur. Bunun sonucunda kurulu iletim sistemi hatlarında da yıllara göre değişimler ve artışlar meydana gelmiştir. Tablo 3.2 ile 2006 – 2016 yılları arasında iletim hattı gerilim seviyelerine göre hat uzunluklarındaki değişim gösterilmiştir. Buradan görüldüğü üzere 66 kV seviyesindeki iletim hatlarında ciddi bir düşüş yaşanmıştır. Bu durum 66 kV hatların 33 kV seviyesine düşürülmesi neticesinde ortaya çıkmıştır. 220 kV seviyesindeki iletim hatlarına yeni yatırımları yapılmadığı da görülmektedir. Bunun yanı sıra, 154 kV ve 380 kV hatlarındaki artış da göze çarpmaktadır [82].

Tablo 3.2: İletim hattı uzunluklarındaki yıllara göre değişim

Yıllar	Gerilim kademelerine göre hat uzunlukları (km)				
	66 kV	154 kV	220 kV	380 kV	Toplam
2006	477,4	31.163,4	84,5	14.307,3	46.032,6
2007	477,4	31.383,0	84,5	14.338,4	46.283,3
2008	508,5	31.653,9	84,5	14.420,4	46.667,3
2009	508,5	31.931,7	84,5	14.622,9	47.147,6
2010	508,5	32.906,4	84,5	15.734,2	49.233,6
2011	509,4	32.878,4	84,5	15.978,4	49.450,7
2012	509,4	33.480,8	84,5	16.343,7	50.418,4
2013	509,4	33.942,5	84,5	16.808,3	51.344,7
2014	509,4	35.132,0	84,5	17.682,8	53.408,7
2015	139,7	37.449,1	84,5	19.070,9	56.744,2
2016	138,6	38.682,3	84,6	21.028,9	59.934,4

3.2.2. TEİAŞ Güç Kalitesi İzleme Merkezi Gerçek Veri Seti

Ulusal düzeyde gerçekleştirilen güç kalitesi izleme projelerinin ilki ve en kapsamlısı 2009 yılında tamamlanan ve kurumlar ile TEİAŞ ortaklığında gerçekleşen *Milli Güç Kalitesi Projesidir* (MGKP). Bu tez çalışmasında kullanılan temel veri seti, MGKP kapsamında üretilmiş ve Türkiye genelindeki trafo merkezlerinden ölçümler alan cihazların topladığı gerçek olay verilerinden oluşmuştur. MGKP içerisinde gerçekleştirilen *Türkiye Elektrik İletim Sistemi Güç Kalitesi İzleme* alt projesinde bütüncül bir güç kalitesi izleme sistemi oluşturulmuş ve ölçüm cihazından izleme yazılımı arayüzüne kadar tüm bileşenler proje ekibi tarafından hazırlanmıştır [83]. Proje bitiminden bugüne kadar artan sayıda ölçüm cihazı, Türkiye geneli iletim sisteminde kurulu olan trafo merkezlerine yerleştirilmiştir. Bu bölümde, proje ve projede tasarlanmış olan ölçüm ve izleme sistemi hakkındaki teknik detaylara değinilmemiştir. Bu başlıklar hakkındaki ayrıntılar [79, 84] çalışmalarından elde edilebilir. Bölümün takip eden kısmında TEİAŞ ile yapılan ikili antlaşma çerçevesinde elde edilen ve Türkiye genelinden toplanan GKO veri setine, sürecin başından sonuna dek uygulanan işlem basamakları detaylı bir şekilde açıklanmıştır.

Öncelikle, Güç Kalitesi İzleme Merkezi (GKİM) mühendisleri ile koordinasyon içerisinde olan hazırlık çalışmaları yürütülmüştür. Devamında gerçekleştirilen detaylı görüşmelerde, Türkiye geneli trafo merkezleri hakkında özellikle GKO temelinde bilgiler alınmış ve hangi trafo merkezlerinden veri alınacağı üzerine nihai karara ulaşılmıştır. Şekil 3.6 ile sunulan haritada, gerçek veri setini oluşturmak için tercih edilen trafo merkezlerinin ülke geneli dağılımı gösterilmiştir.



Şekil 3.6: GKO verileri alınan trafo merkezleri


Bu dağılımdaki trafo merkezleri seçilirken, endüstriyel ortam yoğunluğu baz alınmakla birlikte, yoğun yaşam alanlarını besleyen trafo merkezleri de kapsama dahil edilmiştir. Yıllık analizlerin önemine dayanarak tüm veriler antlaşmanın yapıldığı yıldan bir önceki takvim yılı olan 2015 yılı tamamı için indirilmiştir.

Tablo 3.3, belirlenen bu trafo merkezlerinden indirilen olayların sayıları ve ölçü aletlerinin bağlı olduğu fiderlere ait gerilim kademelerini özetlemektedir. Trafo merkezleri bölgesel olarak ve rakam kodları ile gösterilmiştir. MGKP kapsamında hazırlanan izleme yazılımı olay verilerini çukur, tepe ve kesinti başlıkları altında dış ortama verebilmektedir. Bunların yanı sıra veri setinde, normal çalışma koşullarını temsil eden saf sinüs şebeke gerilimi ve harmonik içerikli gerilim işaretleri de bulunmaktadır. Son iki tür olay gerçek verilerin içerisinden gözle seçilerek oluşturulmuştur. Sistemin harmonik olayları dışa aktarma yeteneğine sahip olmaması bir dezavantaj olarak not edilebilir.

Tablo 3.3: İndirilen olaylara ait bazı nitelik ve nicelikler

2015 YILI İÇİN İNDİRİLEN OLAY VERİ SAYILARI				
Trafo Merkezleri	Gerilim Kademeleri	Olay Türleri		
		Çukur	Tepe	Kesinti
1	<154kV	1101	668	145
2	<154kV	483	6	487
2	154kV	465	12	62
3	154kV	1100	489	7
4	380kV	378	-	51
5	380kV	340	73	28
6	154kV	-	148	97
7	<154kV	6450	5455	304

Oluşturulan veri seti, tek faz gerilim olaylarının bir araya getirilmesiyle ortaya çıkarılmıştır. Tüm süreç boyunca gerçekleştirilen işlemler, otomasyon yazılımları ile mümkün olduğu kadar ileri düzeyde tasarlanmış ve olay verilerinin indirilme ve depolama süreci de üçüncü parti bir paket program sayesinde yine otomatik olarak gerçekleştirilmiştir. Bir yıllık süreç düşünüldüğünde, sayıları on binleri bulan olayların analizinin daha detaylı gerçekleştirilmesi için olayların tek tek sistemden indirilmesi ve kaydedilip anlamlı bir veri dosyasına çevrilmesi gerekmektedir. Bu tez çalışmasında kullanılan ve üzerinde detaylı incelemelerin gerçekleştirildiği TEİAŞ GKİM bünyesinden indirilen olay veri seti, geçmiş çalışmalardan farklı olarak, tüm adımlarında elle yapılacak işlemlerden arındırılmış ve otomasyon yapısı haline getirilmiştir. Böylece kullanıcı müdahalesi en aza indirgenerek, iş gücü ve hesapsal yükten büyük oranda tasarruf edilmiştir.



Şekil 3.7: GKO gerçek veri seti hazırlama blok sürecine ait blok şema


Şekil 3.7 ile özetlenen veri seti oluşturma süreci genel olarak aşağıda listelenen adımları içermektedir:

1. **TEİAŞ ile ikili antlaşmanın imzalanması:** Birimlerin yetkilileri arasında gerçekleştirilen bu antlaşma ile veri seti oluşturma sürecindeki ilk adım atılmıştır. Antlaşmada bulunan gizlilik şartlarından dolayı, trafo merkezleri ile ilgili konum ve tanımlayıcı diğer detay bilgilere tez boyunca yer verilmemiştir.
2. **Verilerin indirilmesi:** GKİM çalışma ekibinin işbirliği ile Türkiye genelinde tespit edilmiş ve yukarıda detayları verilen trafo merkezlerine ve iletim hattı gerilim kademelerine göre 2015 yılına ait olay verilerinin bilgisayar ortamına indirilerek depolanması gerçekleştirilmiştir. MGKP güç kalitesi izleme yazılımı verileri tekil olarak dışarı

vermektedir, yığın veri transferine olanak tanımamaktadır. Bu nedenle üçüncü parti bir paket program kullanarak, tüm yıla ait veriler otomatik olarak indirilmiştir. Zaman ve iş gücü bakımından büyük oranda tasarruf sağlanarak, verilerin indirilmesi ve diğer bürokratik işlemler süresince, önerilen algoritmaların yapay veri kullanılarak testlerinin yapılması sağlanmıştır.

3. **Ham veri dosya tipinin değiştirilmesi:** MGKP kapsamında hazırlanan arayüz, GKO verilerine ait tekil çıktıları *txt* dosyası olarak dış ortama aktarmaktadır. Bu nedenle her olay verisine, dosya tipi dönüştürme işlemi uygulanmıştır. Tez çalışmasında kullanılan temel yazılım olan MATLAB programı ile ham verileri tek tek okuyup ilgili dosya tipine otomatik olarak dönüştüren ve ayrı ayrı isimlerle depolayan bir *veri okuma ve dönüştürme otomasyonu* hazırlanmıştır. Bu otomasyon, adreslenen klasörlerdeki *txt* uzantılı ham veri dosyalarını otomatik olarak tarayarak, MATLAB dosya tipi olan *mat* uzantılı dosyaları oluşturur ve adreslenen başka bir klasöre kayıt işlemini gerçekleştirir.
4. **Tarama–Segmentasyon–Normalizasyon işlemlerinin yapılması:** Her olay verisi için indirilen dosyada; ilgili iletim hattının olay anındaki üç faz gerilim ve akımları, nötr hat akımı ve zaman damgası bilgileri bulunmaktadır. Bu şekilde yapılandırılmış olan bir ham veri dosyası 8 veri sütunundan oluşmaktadır. Sistemin çevrimiçi mantığa da uygun olarak çalışması düşünüldüğünden, oluşturulan otomasyon sistemi her olay verisini tek tek tarayarak bozulma olan fazı tespit edebilecek şekilde tasarlanmıştır. Tarama ve segmentasyon işlemi, Bölüm 2 içerisinde detaylandırılan tanımlar ve standartlar çerçevesinde tasarlanmıştır. Hesaplama kolaylığı açısından veriler ayrıca maksimum değer bilgilerine göre pu değere dönüştürülmüştür. Tez çalışması süresince kullanılan gerçek “veri seti” matrisi tek faz gerilim işaretlerinden oluşmaktadır. Faz ve nötr akımları kaydedilmiş ancak analizleri yapılmamıştır.

Şekil 3.8 ile segmentasyon sürecine ait akış şeması gösterilmiştir.



Şekil 3.8: GKO gerçek veri seti segmentasyon akış şeması

Tablo 3.4 ile gerçek veri setine ait önemli parametreler özetlenmiştir. Buradan görülebileceği üzere, toplanan veriler yüksek çözünürlüklü bir ölçüme sahiptir. Segmentasyon süreci, işaretlerin boyutunu daraltması nedeniyle hesaplamaların oluşturacağı işlem yükünü azaltmada kilit bir role sahiptir. MGKP kapsamında oluşturulan güç kalitesi ölçüm cihazları 25,6 kHz örnekleme frekans değerine sahiptir ve 50 Hz şebeke frekans değerinde periyot başına

512 örnek kaydedilir. Sistemdeki ölçüm cihazları, A sınıfı olarak yapılandırıldığı için IEC 61000-4-30 standardında önerilen ölçüm pencere süresini sağlamaktadır. Bu da her olayın 3–saniye zaman ölçekli pencereler ile kaydediliyor olması demektir. Böylece, pencere toplam örnek sayısı 76.800 değerine ulaşmaktadır. Gerçek verilerde ayrıca gürültü ve harmonik bozulma değerleri de analiz edilmiştir. Çukur, tepe, kesinti ve saf sinüs (normal çalışma koşulları) verileri incelendiğinde %2 – %3 THB değerine sahip oldukları görülmektedir. Güç kalitesi izleme programının dış ortama aktarmadığı ve elle seçilerek veri setine eklenen harmonik bozulmalarda THB değeri %20 – %25 seviyelerine ulaşabilmektedir.

Tablo 3.4: Gerçek veri setine ait önemli parametreler

İletim Hattı Gerilim Kademeleri	: 380 kV–154 kV ve 154 kV altı
Yazılım Ortamı	: MGKP Güç Kalitesi İzleme Arayüzü
Örnekleme ve Şebeke Frekansı	: 25,6 kHz ve 50 Hz
Periyot Başına Örnek Sayısı	: 512 Örnek/periyot
Olay Pencere Uzunluğu	: 3 saniye
Pencere Toplam Örnek Sayısı	: 76.800 Örnek
Olay Tür Sayısı	: 3 Tür Olay + Saf Sinüs
Toplam Harmonik Bozulma	: %2 – %3 (harmonik sınıfında %20 – %25)
Gürültü Seviyesi	: 47 – 55 dB Arası

Segmentasyon işlemine ait algoritmik işlem basamakları, şekil 3.9 ile gösterilmiştir. Burada; kullanıcı tarafından verileri okunan iletim hattına ait faz gerilimi ve tepe değerleri, standartlarda tanımlanmış olan olay eşik değerleri ve segmentasyon penceresinin uzunluk değeri giriş olarak tanımlanmıştır. Tespit etme (*detection*) ve segmentasyon (*segmentation*) algoritması çıkış olarak çukur, tepe ve kesinti olaylarının sayısının ve tanımlanmış pencere boyutunda olaylardan oluşan bütünleşik veri setini oluşturmaktadır. Algoritmada özetlenen kod yapısı, bir faz için gerçekleşen süreci ifade etmektedir. Yapılan bir dizi işlem, her üç faz işaretinde her üç olay tipi için ayrı ayrı taramalar gerçekleştirilerek tekrarlanmıştır. Böylece sistem 3 faz analiz sürecinden bağımsız hale getirilerek, her fazın ayrı yorumlanması ile hem kullanıcı için geniş bakış açısı getirmiş hem de hesaplama yükü iyileştirilmiştir.

Giriş:

- 1: Gerilim seviyeleri,
- 2: Yukarı eşik = $th_u = 0,9pu$, Aşağı eşik = $th_d = 0,1pu$, Tepe eşiği = $th_s = 1,1pu$
- 3: Segmentasyon Pencere Genişliği = w {Tanımlı değer 4096 örnektir}

Çıkış: Segmentasyon işlemi gerçekleştirilmiş bütünleşik veri seti

Olay Tespit Etme (Detection):

- 4: Olay verisi yükle (V)
 - 5: Verilerden şebeke frekansı ve örnekleme frekansını oku
 - 6: İletim hattı gerilim seviyesi maksimum değerini kullanarak işareti pu değere dönüştür
 - 7: Standartlarda belirtilen yarım-periyot kayar pencere kullanarak rms hesapla
 - 8: Örnek = k {işaretin her bir örneği}, $N = 76.800$ {örnek sayısı}
 - 9: **for** $i = 1$ **to** N **do**
 - 10: **if** $(k - 1) > th_u$ **and** $k < th_u$ **and** $k > th_d$ **then**
 - 11: çukur başlama indisi= k
 - 12: **else if** $(k - 1) > th_d$ **and** $k < th_d$ **then**
 - 13: kesinti başlama indisi= k
 - 14: **else if** $(k - 1) < th_s$ **and** $k > th_s$ **then**
 - 15: tepe başlama indisi= k
 - 16: **else**
 - 17: Normal çalışma (Olay yok)
 - 18: **end if**
 - 19: **end for**
-

Segmentasyon (Segmentation):

- 20: Çukur kaydet - $V(\text{çukur başlama indisi} - (w/2) : \text{çukur başlama indisi} + (w/2))$
 - 21: Kesinti kaydet - $V(\text{kesinti başlama indisi} - (w/2) : \text{kesinti başlama indisi} + (w/2))$
 - 22: Tepe kaydet - $V(\text{tepe başlama indisi} - (w/2) : \text{tepe başlama indisi} + (w/2))$
 - 23: Çukur-Tepe-Kesinti birleştirilmiş tek veri setini oluştur
-


Şekil 3.9: Çalışmada kullanılan segmentasyon algoritma özeti

Tez çalışmasında, olay tespit etme ve segmentasyon süreçlerinde rms değer analizi kullanılmıştır. Bu analiz sade ve kolay uygulanabilir olması ile literatürde çokça tercih edilen yöntemler arasındadır [4]. IEC 61000-4-30 test ve ölçüm teknikleri standardında belirtildiği üzere, normal gerilim ölçümleri (50 Hz şebeke frekansı için) 10 periyot ve olaylar yarım-periyot (half-cycle) rms hesabı ile ölçülürler [4, 83]. rms olarak ifade edilen *etkin değer*, alternatif bir gerilim bileşeninin doğru gerilim bileşenine eş değer özellikte olanıdır. Çalışmada kullanılan örneksel rms hesabında (3.1) ifadesi kullanılmıştır [4].

$$V_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N v_i^2} \quad (3.1)$$


Burada gerilimin hesaplanan rms değerini V_{rms} , rms hesabı yapılan penceredeki örnek sayısını N ve gerilim işaret dizisindeki her bir örneği de v_i temsil etmektedir. Etkin değer baz alınarak yapılan tespit yöntemindeki temel unsur, hesabın yapıldığı kayar pencere aralığıdır. Gerilim işaretlerindeki hızlı değişimleri de yakalayabilmek adına literatürde yaygın olarak yarım-periyot rms hesabı tercih edilmektedir [4]. Bu çalışmadaki rms hesabında, yarım-periyot uzunluklu kayar pencere ile işlem yapan ve her örnek için yenilenen *yarım periyot rms yöntemi* kullanılmıştır.

Şekil 3.10 ile Türkiye genelinde meydana gelen gerçek olaylardan oluşturulan veri setinden seçilmiş bir işarete ait görsel sunulmuştur. Burada, 154 kV gerilim seviyesindeki bir iletim hattının 3 faz dalga şekilleri görülmektedir. Şekil 3.10 ayrıca, kısa süreli bir çukur olayı örneği de sunmaktadır. Güç kalitesi izleme ara yüzü tarafından dışa aktarılan işareti betimleyen veri görseli, ölçü aleti örnekleme frekansı büyük olduğu için 3 saniye pencere süresince gösterilmemiştir.




Şekil 3.10: 3 faz gerilimleri: 154 kV iletim hattında bir çukur olayı

Şekil 3.11 ile örnek çukur olayının V_a fazına ait detaylı bir görünüm verilmiştir. Burada, V_a fazında meydana gelen olayın başlangıç ve bitiş noktaları açık bir şekilde görülebilmektedir.




Şekil 3.11: Örnek çukur olayına ait Faz-A gerilimi

Şekil 3.12, V_a fazına ait anlık dalga şeklini, rms değişimini ve olay tespiti için belirlenen eşik değerlerini göstermektedir. Burada yukarı eşik değeri, nominal gerilim rms değerinin %90'ı ve aşağı eşik değeri de nominal gerilim rms değerinin %10'u olarak belirlenmiştir.




Şekil 3.12: Çukur olayı detaylı görünüm: rms değişimi ve eşik değerleri

Şekil 3.12 detaylı olarak incelendiğinde, işaretin eşik değerler tarafından sınırlanmış çukur bölgesine girmesiyle birlikte çukur olayının başladığı görülmektedir. Tez çalışmasında tercih edilen rms yöntemi ile olay tespiti ve bunu temel alarak oluşturulan segmentasyon işlemi, tüm olay verileri için sorunsuz şekilde gerçekleştirilmiştir. Bunun sonucunda 76.800 örnek içeren bir olay verisi 4097 boyutlu son haline indirgenerek, yaklaşık olarak 19 kat değerinde bir boyut azalımı sağlanmıştır. Segmentasyon işlemi sonucunda her veri için olayın başladığı örnek öncesi ve sonrasında 4 periyotluk dilimler alınarak toplamda 8 periyotluk bir boyut değeri oluşturulmuştur.




Şekil 3.13: Son halini alan veri setinden örnek çukur olayı


Şekil 3.13 ile son halini almış veri setinden bir çukur olayına ait örnek dalga şekli gösterilmiştir. Buradan incelenebileceği üzere gerilim genlikleri de son halinde pu değer olarak kaydedilmiştir. Tüm işlemlerin sonunda oluşan veri seti, sınıflandırıcı yapılarına giriş olarak verileceğinden, pu değer tercihi öznitelik çıkarımı ve sınıflandırma öncesi gerçekleştirilecek normalizasyon işlemlerine de kolaylık sağlamaktadır. Takip eden şekiller olan Şekil 3.14, Şekil 3.15 ve Şekil 3.16 ile gerçek veri setinin son halinden sırasıyla tepe, kesinti ve harmonik olaylarına ait örnek dalga şekilleri gösterilmiştir.



Şekil 3.14: Örnek bir tepe olayı (Gerçek veri son hali)



Şekil 3.15: Örnek bir kesinti olayı (Gerçek veri son hali)



Şekil 3.16: Örnek bir harmonik olayı (Gerçek veri son hali)

Yapılan tüm bu işlemlerle, önerilen metodoloji çerçevesinde sınıflandırması yapılmış olan güç kalitesi veri seti, tüm ortamlarda işlenmek için hazır hale getirilmiştir. GKİM ekibi, yıllık verilerin sistemden indirildiği ve bunlara ait incelemelerin gerçekleştirildiği önemli tarama çalışmaları gerçekleştirmektedir. Bu bölümde anlatılan ön hazırlık işlemlerini gerçekleştiren otomasyon programları, GKİM çalışma ekibinin de yaptığı analizler için hızlı çözüm üretecek şekilde tasarlanmıştır. Böylece, gerçekleştirilen dönemsel analizlerin hızlı olarak yorumlanabileceği bir alt sistem ortaya çıkarılmıştır.


Bu bölüm boyunca, tez çalışmasında kullanılan veri setlerine ait detaylı bilgiler sunulmuştur. İlk olarak, matematiksel ifadeler yardımıyla oluşturulan benzetim modelinin tasarım süreci açıklanmıştır. Hazırlanan bu kapsamlı güç kalitesi olay üretici sayesinde, gerçek veriler elde edilene dek geçen süreçte, metodolojinin test edilmesi sağlanmıştır.

Bölümün takip eden kısmında, tez çalışmasında kullanılan temel veri yapısı olan *güç kalitesi olayları gerçek veri seti* detaylı bir şekilde anlatılarak, gerçek veri setinin tüm özelliklerinin okuyucuya aktarılması sağlanmıştır. TEİAŞ ile tez ekibi arasında süren bürokratik işlemlerden başlayarak, gerçek veri setinin son şeklini aldığı veri seti oluşum sürecine kadar her aşamadaki teknik detay tanımlanmıştır. İndirilen veri seti hacmi, ileri çalışmalarda *büyük veri* kapsamında yapılacak uygulamalar için de gerekli şartları taşımaktadır.

4. AKILLI ÖRÜNTÜ TANIMA METODOLOJİSİ

Akıllı bir örüntü tanıma sisteminin temel yapı taşını, incelenen veri seti oluşturmaktadır. Bu temel üzerine inşa edilen metodolojik süreçler ise ham verilerden anlamlı ve ayırt edici vurguların elde edildiği *öznitelik çıkarım süreci* ve akıllı bir sınıflandırıcı kullanılarak bu özniteliklerin sınıflandırıldığı *karar sürecidir*. Tez çalışmasının bu bölümünde, öznitelik çıkarımı ve akıllı sınıflandırıcı başlıkları altında, önerilen güç kalitesi tanılama ve sınıflandırma akıllı örüntü tanıma sisteminin metodolojisi açıklanacaktır.

Şekil 4.1 ile bir örüntü tanıma sistemine ait temel blok şeması gösterilmiştir. Bu tez çalışmasında önerilen akıllı örüntü tanıma sisteminin amacı, Türkiye iletim sisteminden elde edilmiş gerçek güç kalitesi olaylarından oluşan veri setini, düzenli bir öznitelik seti elde ederek, makine öğrenme tabanlı akıllı sınıflandırıcılar ile eğitmenli öğrenme (*supervised learning*) tabanlı sınıflandırmasını gerçekleştirmektir.



Şekil 4.1: Örüntü tanıma sistemi genel şeması

Bu tez çalışması ile literatüre kazandırılan bütüncül akıllı sistemde hem geleneksel metodoloji alt yapısından faydalanılmış, hem de çalışma önerisinde sözü edilen yeni yöntemlerin uygulanmasıyla öznitelik çıkarım ve karar süreci zenginleştirilmiştir. Literatüre kazandırılan bu bütüncül güç kalitesi olay tanılama ve sınıflandırma sisteminin her iki sürece de yansıttığı katkılarla, güç kalitesi izleme sistemlerinde donanımsal olarak kullanılmak üzere yeni bir yapı ortaya çıkmıştır. Öznitelik sürecinde, geleneksel Ayırık Dalgacık Dönüşümü

(Discrete Wavelet Transform–DWT) ve temel istatistiksel yöntemlerin yanı sıra literatüre katkı sağlayan Histogram, anlık zaman bölgesi özellikleri, Permütasyon Entropi (PE) ve yerel tepe noktaları yöntemleri ile oluşturulan ayırt edici öznitelikler; Uç Öğrenme Makinesi (ELM) tabanlı akıllı yapılar ile sınıflandırılmıştır. Literatürde çok çeşitli alanlarda kullanımı tercih edilen ELM yapıları detaylı olarak açıklanmış ve temel ELM yapısının dezavantajlarını gideren ağırlıklandırılmış ELM ve seyrek-Bayes ELM yapıları ile etkin bir süreç elde edilmiştir. Bölümün takip eden öznitelik çıkarımı ve akıllı sınıflandırıcı ana başlıkları altında tüm metodoloji öğeleri detaylı olarak açıklanacaktır.

4.1. Öznitelik Çıkarımı

Örüntü tanıma kavramı, giriş verisini yine verinin kendi öz yapısından elde edilmiş ayırt edici *öznitelikler* kullanarak sınıflara ya da tanımlı nesnelere ayırmak, sınıflandırmak olarak tanımlanır. Duda ve çalışma ekibi tarafından hazırlanan “Pattern Classification–Örüntü Sınıflandırma” isimli kitapta, günlük yaşamdan alınan örneklerle bahsedildiği üzere; karşılaşılan bir yüzü tanıma, konuşulan bir cümledeki sözcükleri ayırt etme, el yazısındaki karakterleri okuyabilme ve hatta bir nesneyi örneğin araba anahtarını hissederek tanımlama gibi karmaşık süreçlerin tümü *örüntü tanıma* sisteminin kapsamına girmektedir. Tüm bu süreçlerde, ham veriden elde edilen belirgin özelliklerden yola çıkarak, örüntüleri kategorileme yolu takip edilmektedir ki insanoğlunun yaşam mücadelesini gerçekleştirdiği onlarca milyon yıldır, değişen koşullarda ve ortamlarda hayatta kalabilmesi için bu süreçler, elzem ölçüdeki gerekliliğini korumuştur [54]. Örüntü tanıma ve problemi kapsamına giren detay başlıklar bu tezin konusu dışında tutulmuştur, bu konudaki ayrıntılara yukarıda adı geçen [54] çalışmasından ulaşılabilir.

Veri seti oluşturma ve ön işleme süreçleri Bölüm 3 ile daha önce sunulmuştu. Segmentasyon işlemine tabi tutulmuş ham verilerin öylece sınıflandırıcıya verilmesi çok da akılcı bir uygulama olmadığından, bu verilerden ayırt edici özellikler tespit ederek *çoğu durumda* boyut azalımı sağlayan öznitelik çıkarım süreci ikinci adım olarak gelmektedir. Bu yüzden anlamlı öznitelikleri betimlemek ve seçmek iyi bir sınıflandırmaya giden yolda en önemli adımdır. Burada ulaşılmaya çalışılan hedef, güç kalitesi olay verilerini en iyi şekilde karakterize edecek ve farklı sınıfları birbirinden ayırt edebilecek bir öznitelik setine ulaşabilmektir. Öznitelik haritalama olarak da isimlendirilen bu süreç kabaca, seçilecek bileşenlerin dağılımlarında, sınıflar arası *geniş* ortalama uzaklık ve sınıf içinde ise *dar* ortalama uzaklık

aranması olarak tanımlanmaktadır. Bu özellikler aranırken öznitelik sayısının da gerekenden fazla arttırılmaması gerektiği de bilinmelidir. Bunların yanı sıra hesaba katılması gereken diğer önemli hususlar da matematiksel tanımlanabilirlik, numerik kararlılık ve gürültüye karşı duyarsızlık olarak özetlenebilir [4, 54].



Şekil 4.2: Öznitelik çıkarım aşaması

Şekil 4.2, takip eden alt başlıklarda açıklanacak olan öznitelik çıkarım yöntemleri listesini göstermektedir. Tez çalışmasında işlenen verilerden elde edilen öznitelikler, görüntü işleme uygulamalarında olduğu gibi yüksek boyutlu bir dizi değerine sahip olmadığı için öznitelik analizleri rahatlıkla yapılabilmiştir. Ek olarak, öznitelikler Fisher Vektör (FV) yöntemi ile kodlanarak bu ilgin (afin) dönüşüm yardımı ile farklı uzaya taşınarak daha düzgün bir dağılım elde edilmesi sağlanmış ve sınıflandırıcı yapısının başarımının arttırılması amaçlanmıştır. Genellikle görüntü işleme uygulamalarında kullanımı tercih edilen FV kodlama yöntemi, parametre değerlerine göre bir boyut artımı gerçekleştiriyor olsa da Fisher çekirdek (*kernel*) fonksiyonu ile uzayı değiştirilen öznitelik seti, daha düzgün bir dağılım oluşturduğu için sınıflandırıcı başarımını olumlu yönde etkilemektedir. Takip eden alt başlıklarda, tez çalışmasında kullanılan öznitelik çıkarım yöntemleri, Şekil 4.2 ile listelendiği sırada sunulacaktır. Tüm öznitelik çıkarım yöntemlerine ve FV kodlamaya ait matematiksel alt yapıya ayrıntılı olarak yer verilmiştir, bu yöntemlerle oluşturulan GKO öznitelik matrislerinin analizlerine sonraki bölümde yer verilecektir.

4.1.1. Ayrık Dalgacık Dönüşümü

Dalgacık Dönüşümü (Wavelet Transform–WT) yöntemi, işaret işleme alanında benzer yöntemlere artı olarak durağan olmayan yani zaman ekseninde değişken frekans değerlerine

sahip işaretlerin frekans–zaman ölçeğinde detaylarını sunan temel bir analiz yöntemidir. Bu başlıkta, tez çalışmasında kullanılan *ayrık* yapıdaki dönüşüme geçmeden önce WT hakkında genel bilgiler sunulacaktır.


Temelini 1909 yılında, Alman bilim adamı Alfred Haar’ın attığı WT, incelenen işaretin değişken ölçekli (düşük frekanslar için geniş, yüksek frekanslar için dar) bir analiz penceresi kullanarak frekans bileşenlerini ortaya çıkaran ve bu bileşenleri ilgili ölçekteki çözünürlüğü ile birlikte ortaya koyan yöntemdir. Şekil 4.3 ile verilen WT blok şemasında görülebileceği üzere, işarete WT analizi uygulandığında çıktı olarak zaman ve ölçek bilgisi elde edilmektedir. Güç kalitesi olay işaretleri de durağan olmayan özelliktedir, bu yapıdaki işaretlerde frekans ve zaman bilgilerinin birlikte verilmesi neticesinde etkili bir ayrıştırma gerçekleştirilmektedir. Literatürde uzun yıllardır kullanılmakta olan Fourier Dönüşümü (Fourier Transform–FT), uygulanan işaretin frekans bilgisini sunmakta ve sadece durağan işaretlere uygulanabilmektedir, FT yönteminin bu dezavantajı kısa zamanlı FT (Short Time Fourier Transform–STFT) yönteminin kullanılmasıyla çözülmüş olsa da, STFT yönteminde kullanılan analiz penceresinin sabit genişlikli olması sorununa son haliyle WT çözüm getirmiştir [85–87].



Şekil 4.3: Dalgacık dönüşümü blok şeması

FT yöntemi, incelenen işaretin sinüs ve kosinüs toplamlarından ifade edilmesi mantığına dayanmaktadır. Böylece işaretler, parça parça serilerden oluştuğu haliyle daha etkili analiz edilebilecektir. WT yönteminde, *ana dalgacık* denilen bir $\psi(t)$ fonksiyonunun zamanda ötelenme ve ölçeklenme işlemleriyle oluşturulan pencere fonksiyonlarına işaretin iz düşümü alınması ile analiz gerçekleştirilir. Buradaki en temel katkı, işlem penceresinin yüksek ve düşük frekans bileşenli parçaları analiz ederken değişen genişlik ölçeklerinde işlem yapıyor olmasıdır. Son hali ile işaret burada da dalgacık fonksiyonlarından oluşan bir seriye dönüştürülmüş olmaktadır [87]. Bir diğer değişle WT, büyük resmi analiz ederken kullandığı referans küçük resimlerle, tüm resmi belirli ölçeklerle tarayıp karşılaştırarak benzerlik

aramaya benzetilebilir. Şekil 4.4, literatürde güç kalitesi işaret işleme amaçlı kullanılan dalgacık fonksiyonları arasında büyük oranda tercih edilen [17] ve bu çalışmada da kullanılan ana dalgacık “db4” fonksiyonunu ve bu fonksiyona ait ölçekleme ifadesini grafiksel olarak göstermektedir.



Şekil 4.4: dB4 dalgacık ve ölçek fonksiyonu

Sürekli zaman işaretlerin analizi için kullanılan sürekli dalgacık dönüşümü (Continuous Wavelet Transform–CWT), Eşitlik (4.1) ve (4.2) ile şu şekilde verilmiştir:

$$CWT_{b,a} = (f, \psi_{b,a}) = \int_{-\infty}^{\infty} f(t) \psi_{b,a}^*(t) dt \quad (4.1)$$

Eşitlik (4.1) ifadesindeki ana dalgacık ifadesi,

$$\psi_{b,a} = \frac{1}{\sqrt{a}} \psi \left(\frac{t-b}{a} \right) \quad (4.2)$$

şeklinde ifade edilir. Burada, $CWT_{b,a}$ çıktı olarak dalgacık katsayılarını, $\psi_{b,a}$ sürekli dalgacık fonksiyonunu, b zamanda öteleme parametresini, a ise frekans ölçekleme parametresini göstermektedir. $\psi_{b,a}^*$ ise $\psi_{b,a}$ ifadesinin karmaşık eşleniğidir.

CWT yönteminin her frekans ölçeği için hesapladığı katsayıları hesaplamadan, bilgi

ve işlem yükünü hafifleten ve ayırık işaretlere uygulanan Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform–DWT) yönteminde, belirlenen ölçekleme ve öteleme parametreleri ikinin üstleri olarak seçilir ve böylece yöntem etkili ve hızlı bir biçimde çıktı üretir. Filtre kullanımı mantığına dayanan DWT yöntemi, 1988 yılında, Fransız matematikçi Stephane Mallat tarafından önerilmiştir. Bu işlemle işaret, detay ve yaklaşım bileşenlerine ayrıştırılmaktadır [87].

Sürekli dalgacıklar ile benzer özellik gösteren ayırık yapının en belirgin farkı, ölçek (a) ve konum (b) bileşenlerinin ayırık aralıklı yapıda olmasıdır. Buradaki en önemli unsurun, seçilen dalgacık fonksiyonlarının kendi içlerinde ve genişlemede ortogonal dönüşüme uygun yapıda bulunmaları gerekliliğidir. DWT yönteminin temel ifadesi (4.3) ile tanımlanır:

$$\psi_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} \psi\left(\frac{t - nb_0a_0^m}{a_0^m}\right) \quad (4.3)$$

burada, n zamanda olan kaymayı, m ise genişlemeyi göstermektedir. DWT yapısı uygulanırken de dalgacık fonksiyonuna bir ölçeklendirme fonksiyonu eşlik eder. Ölçekleme fonksiyonu için de ortogonal olma şartı geçerlidir. Ölçekleme fonksiyonu (4.4) ile ifade edilir [87]:

$$\phi_{m,n}(t) = 2^{-\frac{m}{n}} \phi\left((2^{-m})t - n\right) \quad (4.4)$$

DWT analizi gerçekleştirilecek işarete iç çarpım uygulanarak, dalgacıklar üzerinde iz düşüm ifadeleri elde edilir. Ölçeklendirme fonksiyonuna da uygulanan bu işlemlere ait detaylar $T_{m,n}$ ve $S_{m,n}$ ile sırasıyla dalgacık ve ölçekleme fonksiyonu için (4.5) ve (4.6) ile şu şekilde ifade edilmiştir:

$$T_{m,n} = \int_{-\infty}^{\infty} f(t) \psi_{m,n}(t) dt \quad (4.5)$$

$$S_{m,n} = \int_{-\infty}^{\infty} f(t) \phi_{m,n}(t) dt \quad (4.6)$$

Burada girdi işareti, dalgacık ve ölçekleme fonksiyonun doğrusal kombinasyonu ele alınarak (4.7) ile şöyle ifade edilir:


$$x(t) = \sum_{n=-\infty}^{\infty} S_{m,n} \phi_{m,n}(t) + \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} T_{m,n} \psi_{m,n}(t) \quad (4.7)$$

m ve n zamanda kayma ve genişleme parametreleri ile dalgacıklar bant geçiren filtre ve ölçekleme fonksiyonu ise Alçak Geçiren Filtre (AGF) özelliğindedir. Eşitlik (4.8) ve (4.9) sırasıyla DWT sonucu elde edilen detay ve yaklaşım vektörlerini ifade etmektedir:

$$d_m(t) = \sum_{n=-\infty}^{\infty} T_{m,n} \psi_{m,n}(t) \quad (4.8)$$

$$a_m(t) = \sum_{n=-\infty}^{\infty} S_{m,n} \phi_{m,n}(t) \quad (4.9)$$

DWT yönteminin temel mantığı olan filtreleme yapısı yani işareti filtrelerden geçirerek frekans bileşenlerine ayırma yapısının genel blok şeması Şekil 4.5 ile gösterilmiştir. Burada tek seviyeli bir analiz gerçekleştirilmiştir. Görüldüğü gibi işaret Yüksek Geçiren Filtre (YGF) ve AGF ile işleme tabi tutularak, yaklaşım (A) ve detay (D) katsayılarına ayrılmıştır. A katsayıları işaretin alçak frekans bilgisini verirken, D katsayıları ise yüksek frekans bilgisini vermektedir.




Şekil 4.5: DWT tek seviye dönüşüm blok şeması

DWT yönteminde, işaretler zaman boyutundan dalgacık boyutuna sayısal filtreler ile dönüştürülür. Giriş işareti, hem AGF hem de YGF işlemlerine tabi tutulur. Her filtreleme aşamasında işaretin örnek sayısı ikiye bölünerek yarıya düşürülür [87].

ADD yönteminde frekans bileşenlerine ayrıştırma işlemi çok seviyeli olarak da yapılabilir. Bu işlem sonucunda analizi yapılan işaret, daha az çözünürlüklü birçok alt bileşene ayrılacaktır. Literatürde bu kavram *çok çözünürlüklü ayrıştırma* (Multi Resolution Analyze—MRA) olarak yer almaktadır. Şekil 4.6, “m” seviyeli bir DWT MRA işlemine ait blok şemasını göstermektedir. Ayrıştırma işleminin açılabilceği seviye sayısı teorik olarak sınırsızdır. Uygulamada ise detaylar son örnek değerine inene dek ya da son piksel değerine ulaşana

dek devam ettirilebilir. En uygun ayrıştırma seviyesini belirlemek için işaretin yapısını ya da entropi gibi kriterleri incelemek gerekecektir [18].




Şekil 4.6: DWT çok seviye dönüşüm blok şeması

“m” seviyeli bir DWT MRA işleminde, herhangi bir X işaretinin yaklaşım ve detay vektörleri cinsinden ifadesi (4.10) ile şu şekilde gösterilebilir:


$$X = a_m + d_m + d_{m-1} + \dots + d_2 + d_1 \quad (4.10)$$

burada, d_1, d_2, d_{m-1} ve d_m detay vektörleri her seviyedeki yüksek frekanslı bileşen katsayılarını ve son seviyeye ait yaklaşım vektörü a_m ise düşük frekanslı bileşen katsayılarını ifade etmektedir. Elde edilen ayrıştırma işlemine ait detay ve yaklaşım vektörleri ile işaretin yeniden sentez edilerek oluşturulması sağlanabilmektedir.

DWT MRA işlemindeki her filtreleme sürecinden sonra elde edilen detay ve yaklaşım vektörlerine, örnek yarıya indirgeme yapılmadan da süreç işletilebilir [87]. Bu tez çalışmasında, örnek indirgeme işlemi olmaksızın elde edilen detay vektörlerine ait bilgiler kullanılmıştır. Şekil 4.7 ile örnek bir çukur işaretine uygulanan 8 seviye DWT MRA işlemine ait son seviye katsayıları gösterilmiştir. Burada, $cd8$ örnek yarıya indirgeme uygulanmış detay vektörünü, $D8$ ise bu işlem uygulanmadan elde edilmiş detay vektörünü ifade etmektedir. Grafiklerden görülebileceği üzere örnek yarıya indirgeme uygulanmamış durumdaki detay vektörü, işaret hakkında daha fazla bilgi sunmaktadır. Şekil 4.8, bu ayrıştırmaya ait seviyeleri, örnek sayıları ve anahtarlama frekans değerleriyle birlikte göstermektedir.



Şekil 4.7: DWT MRA katsayı karşılaştırmaları (8. seviye)



Şekil 4.8: DWT MRA ayrıştırma seviyeleri


DWT-MRA işlemi sonucunda elde edilen (sekiz seviye için sekiz adet) detay bileşeni, önce de belirtildiği üzere gerçek işarette aynı boyutta yani segmentasyon penceresi boyutuna eşit olan 4097 uzunluğunda bir satır vektörüdür. Elde edilen bu vektörler sınıflandırıcı yapılarına giriş olarak kullanılacak özellikte değildir. Bu nedenle literatürde DWT katsayılarını sadeleştirmek ve anlamlı öznitelikler çıkarmak için sıkça tercih edilen; “Entropi” ve “Enerji” ölçütleri de kullanılmıştır. Bunlara ek olarak, detayların standart sapma değerlerinden elde edilen “Delta Standart Sapma” (D_{STD}) yöntemi de kullanılmıştır [4, 12, 17].

Entropi kavramı, bir sistemin düzenliliğini ya da düzensizliğini ölçmek amacı ile termodinamikte iyi bilinen bir kavramdır. İşaret işlemede, özellikle haberleşme alanında, ilk olarak *Shannon* tarafından kullanılmıştır [88]. Entropi ölçüm yöntemi, durağan olmayan bir işaretin düzensizlik derecesini ölçmek için ideal bir araç olarak kullanılmaktadır. Ayrıca, entropi ifadesi bir olayın içerdiği bilginin ortalama miktarını ölçmek amacıyla da kullanılmaktadır [54].

İşaret işlemede yaygın olarak kullanılan entropi hesaplama türleri; Shannon, Norm, Eşik, Logaritmik Enerji ve Sure yöntemleridir [89]. Bunun dışında diğer entropi hesaplama teknikleri de bulunmaktadır. (4.11) ifadesinde, bu çalışmada kullanılan *Shannon* Entropi yöntemine ait eşitlik gösterilmiştir. Burada s , işareti; s_i ise işaretin i . katsayısını göstermektedir:

$$E(s) = - \sum_i s_i^2 \cdot \log_2(s_i^2) \quad (4.11)$$

Şekil 4.9, çukur ve tepe olmak üzere iki örnek dalga şekli için entropi özniteliklerini göstermektedir.




Şekil 4.9: Gerilim çukuru ve tepesine ait DWT Entropi değerleri

Bu çalışmada 8 seviye çoklu çözünürlük ayrıştırması neticesinde elde edilen DWT detaylarına ait entropi değerleri hesaplanarak her olay verisi için 8 adet öznitelik elde edilmiştir. Eğriler incelendiğinde entropi değerlerinin ilk 5 seviyede ayırt edicilik özelliklerinin daha az olduğu düşünülse de, tez çalışması sırasında hazırlanan [90] çalışmamızdaki analizler incelendiğinde, durumun görüldüğü gibi olmadığı saptanmıştır. İlgili çalışmada yapılan analizler sonucunda, tüm seviyelere ait entropi değerlerinden oluşan alt setin öznitelik verilerine dahil edilmesi sonucuna varılmıştır.

DWT detaylarından elde edilen öznitelik uzayını zenginleştirmek amacıyla, 8 seviye çoklu çözünürlük ayrıştırma işleminden elde edilen DWT detaylarının enerjileri de hesaplanmıştır. 8 adet detay vektörünün enerjilerinin ortalama değeri alınarak, öznitelik matrisine eklenmiştir. Ayrıca bir özellik olarak da yaklaşım işaretinin enerji değeri elde edilmiştir. N örnekli bir s işaretinin enerji hesabı (4.12) ifadesi ile gösterilebilir [54]:

$$S_{\text{Enerji}} = \sum_{i=1}^N |s_i|^2 \quad (4.12)$$

Şekil 4.10, veri setinden seçilmiş örnek bozulma olaylarına ait DWT enerji değerlerini göstermektedir.




Şekil 4.10: Bozulma türlerine göre DWT enerji değerleri

DWT MRA yöntemi yardımıyla elde edilen güç kalitesi bozulma olaylarına ait detay vektörlerinden faydalanarak oluşturulan öznelite setine son olarak, her detaya ait standart sapma değerleri de hesaplanıp eklenmiştir. Böylece her olay için 8 farklı ayırt edici özellik daha elde edilebilir. Standart sapma (STD) değerini veren ifade, (4.13) ile gösterilmiştir.

$$\sigma = \sqrt{\frac{\sum_{j=1}^N (d_j - \mu)^2}{N}} \quad (4.13)$$


burada σ standart sapmayı, d_j veri dağılımını, μ dağılıma ait ortalama değeri ve N ise örnek sayısını ifade etmektedir.

Şekil 4.11 ile saf sinüs (normal) dalga şekli, gerilim çukuru ve gerilim tepesi olaylarına ait örnek STD değerleri grafiksel olarak gösterilmiştir. Güç kalitesi olaylarına ait ayırt edici özellikleri ortaya koymada STD yöntemi oldukça etkilidir [91, 92].




Şekil 4.11: Örnek bozulma türlerine ait DWT STD detayları

Şekil 4.11 incelenirse, çukur ve tepe değerlerine ait STD değerlerinin, bazı genlikleri birbirine çok yakın değerler aldığıında, ayırt edici olma etkilerini yitirebilecekleri söylenebilir. Bunu önleyip, sınıflandırıcı girişine daha kapsamlı öznelite göndermek amacıyla, *delta standart sapma* (D_{STD}) hesaplaması önerilmiştir. D_{STD} hesaplaması; güç kalitesi olay verilerinin DWT detaylarından hesaplanan STD değerlerinin, saf sinüs dalga şekli DWT detaylarından hesaplanan STD değerleri ile karşılaştırılması ile elde edilmektedir. Şekil 4.12 ile bu anlatıma ait özet gösterim verilmiştir.



Şekil 4.12: DWT MRA tabanlı D_{STD} hesabı blok şeması

Şekil 4.13, örnek olarak seçilen gerilim çukuru ve gerilim tepesi olaylarına ait D_{STD} değerleri grafiksel olarak gösterilmiştir. Açıkça görülebileceği gibi, D_{STD} işlemi sonucunda; yanlış sınıflandırılma olasılığı en yüksek olan çukur ve tepe olaylarına ilişkin, yüksek oranda ayırt ediciliğe sahip öznitelikler elde edilmiştir.



Şekil 4.13: Örnek çukur ve tepe olaylarına ait DWT D_{STD} öznitelikleri

Tüm bunların sonucunda; DWT yönteminin farklı güç kalitesi olaylarının belirlenmesinde ve bozuk işaretin özniteliklerini tanımlamada büyük rol oynayan etkili bir matematiksel yöntem olduğu görülmektedir [93]. Çok çözünürlüklü DWT yönteminin işaret ayrıştırma özelliği kullanılarak, bozulan işareten önemli bilgilerin tanımlanabileceği görülmüştür. Bunu gerçekleştirmek için, tez çalışmasında DWT çoklu çözünürlük ayrıştırma katsayılarının; entropi, enerji değerleri, delta-standart sapma değerleri hesaplamalarına dayalı yöntemler kullanılarak elde edilen öznitelik seti de tercih edilerek analizleri gerçekleştirilmiştir.

4.1.2. İstatistiksel Verilere Dayalı Öznitelikler

GKO işaretlerinden ayırt edici öznitelikleri belirleme sürecine, bu başlık altında sunulan temel istatistiki verilere dayalı öznitelik seti tanımları verilerek devam edilmiştir. Herhangi bir dönüşüm yöntemine dayanmadan, Tablo 4.1 ile listelenen istatistik değer tanımları, ham olay verilerine uygulanarak toplamda 9 adet öznitelik içeren alt set oluşturulmuştur.

Tablo 4.1: İstatistiki özniteliklere ait detaylar

Temel İstatistik Tanımı	Öznitelik Etiketi	Öznitelik Sayısı
Etkin değer	rms	1
Minimum	min	1
Maksimum	max	1
Ortalama	mean	1
Ortanca	median	1
Mod değer	mode	1
Standart sapma	std	1
Çarpıklık	skewness	1
Basıklık	kurtosis	1
Toplam		9

Temel istatistiksel tanımlardan minimum (en küçük) değer, maksimum (en büyük) değer, veri dizisinin ortalama, standart sapma ve ortanca değerlerine ek olarak etkin (rms) değer, dizinin mod değeri, çarpıklık ve basıklık parametreleri de elde edilmiştir.

Bu öznitelik alt setinde kullanılan rms değer, elektriksel bakış açısından bağımsız olarak tanımlanan istatistiksel rms değeridir. Herhangi bir X olayı için hesaplanacak X_{rms} formülasyonunda, hesaplama penceresi tüm veri uzunluğunu (n örnek) içerdiği için (4.14) ifadesi sonucu elde edilen değer tek bir veriden oluşmaktadır.

$$X_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (4.14)$$

İstatistiksel alt öznitelik setinin bir elemanı da “mod” değeridir ki bir sayısal dizi içerisindeki en çok tekrar eden sayı değeri olarak ifade edilmektedir.

Tez çalışmasında kullanılan ham veri setinden temel istatistiksel bilgiler elde edilerek

oluşturulan öznitelik setinin son bileşenleri, çarpıklık (*skewness*) ve basıklık (*kurtosis*) ifadeleridir. Çarpıklık ifadesi bir veri dağılımının, ortalama değeri etrafındaki asimetri derecesini göstermektedir. Dağılımın şekilsel yapısını da ifade eden çarpıklık ifadesine ait matematiksel eşitlik (4.15) ile şu şekilde verilmiştir [94]:


$$\text{Skew}(x) = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^3 \quad (4.15)$$

burada $\text{Skew}(x)$ herhangi bir x veri dizisine ait çarpıklık değerini, n dizideki toplam örnek sayısını, x_i dizinin her bir örneğini, μ dizinin ortalama değerini ve σ ise dağılımın standart sapmasını göstermektedir. Pozitif değerli bir çarpıklık değeri dağılımın sağa çarpıklığını ortaya koyar, negatif çarpıklık değeri ise dağılımın sola doğru yığıldığını gösterir. Normal bir dağılıma sahip veri dizisinin çarpıklık değeri sıfırdır.

Kelime tanımı olarak basıklık (*kurtosis*) anlamına gelen istatistiki veri, bir dağılımın yatıklık ya da şişkinliğini ifade etmektedir. Yani normal dağılım baz alınır, basıklık ölçüsü verilerin ortalama değer etrafında ne derece yoğun bir dağılım sergilediğini ortaya koyar. Basıklık ($\text{Kurt}(x)$) ifadesinin genel tanımı (4.16) ile şu şekilde gösterilir:

$$\text{Kurt}(x) = \left\{ \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^4 \right\} - 3 \quad (4.16)$$


Eşitlik (4.16), çarpıklık ifadesi ile aynı terimleri içermekle birlikte burada moment derecesi dördtür. Normal bir dağılıma ait basıklık değeri 3 olduğu için genel gösterimlerde -3 eklenmesiyle, normal dağılım basıklık değeri “0” olarak sabitlenmiş olur. Şekil 4.14, normal dağılım referansına göre çarpıklık ve basıklık ifadelerinin genel gösterimlerini sunmaktadır. Daha ayrıntılı bilgiler için [94] çalışmasına başvurulabilir.



Şekil 4.14: Normal dağılıma göre çarpıklık ve basıklık genel gösterimleri [94].

4.1.3. Histogram

Bu tez çalışmasında kullanılan öznitelik vektörünü oluşturan alt setlerden bir tanesi de histogram yönteminden elde edilen değerleri içeren “Histogram öznitelikleri” alt setidir. Temel yapı taşları 1895 yılında Pearson tarafından ortaya atılan ve dönüşümden bağımsız bir yöntem olan histogram, herhangi bir veri dağılımının belirli kriterlere göre oluşturulmuş gruplarını, sütun grafik olarak göstermeye yarayan işlemler bütünüdür [95]. Güç kalitesi olay verileri de sayısal bir dağılımı ifade ettiği için bu veri dağılımının belirli adım değerlerindeki örnek sayılarını histogram işlemi ile elde ederek, bu sayılardan oluşan ve ayırt ediciliği son derece yüksek olan özniteliklerin elde edilmesi düşünülmüştür. Bu çalışma ile güç kalitesi olay verilerinde kullanmak üzere ilk defa analiz edilen bu yöntem, Şekil 4.15 ile sunulan grafiklerde görülebileceği üzere, analizi gerçekleştirilen olay işaretleri arasında ayırt ediciliği yüksek öznitelikler oluşturmıştır.



Şekil 4.15: Olay verilerine ait histogram çubuk grafikleri

Veri içerisindeki örneklerin gruplandırılma adımları gerilim genlik değerlerine göre yapılmıştır ki birim değere dönüştürme işlemi gerçekleştirildiği için bu değerler $[-1, 1]$ aralığındadır. Tez çalışmasında, histogram gruplandırma adımlarının seçimi [96] çalışmasında

ayrıntılı olarak verilmiş olan *Sturges kuralına* göre yapılmıştır. Buradan hareketle, (4.17) ile gösterilen eşitlikte verilen hesaplama göre histogram öznitelik sayıları her olay için 13 olarak belirlenmiştir.

$$C = 1 + 3,322 \log(k) \quad (4.17)$$

burada, C histogram adım sayısını, k ise her işaretin örnek sayısını göstermektedir ki bu çalışmada 4.097 olarak tanımlanmıştır.

Histogram yönteminin gömülü sistemlerde sayısal olarak gerçekleştirilmesi, uygulanabilirliği çok sade olan adımlardan oluşmaktadır. Herhangi bir dönüşüm temeliyle formüle edilmediği için yöntem son derece hızlı cevaplıdır. Histogram adım aralık sayıları m olarak belirlendikten sonra N örnekli bir veri dizisi için (4.18) ile gösterilen tanımlama gerçekleştirilir [94]:

$$p_i \equiv \frac{i}{m}, \quad i = 0, \dots, m \quad (4.18)$$

burada, eğer bir q_i değeri, p_i tanımında bir dağılım dilimi oluşturuyorsa i . adım q_i değerinden q_{i+1} değerine (4.19) eşitliğinden hesap edilecek bir h yüksekliği değerince çizdirilebilir:

$$h_i = N \left(\frac{p_{i+1} - p_i}{q_{i+1} - q_i} \right), \quad i = 0, \dots, m \quad (4.19)$$

Tez çalışması sırasında histogram öznitelikleri ile ilgili yapılan ön deneyler [90] çalışması ile yayımlanmıştır. Daha fazla bilgi için [90, 95–97] çalışmalarına başvurulabilir.

4.1.4. Permütasyon Entropi

Biyomedikal işaret işleme uygulamalarında sıklıkla kullanılan Permütasyon Entropi (PE) hesabı, Bandt ve Pompe tarafından önerilmiş ve zaman serisi özelliğindeki işaretlerin karmaşıklık durumunu, komşuluk değerlerine göre ortaya koyan bir yöntemdir [98]. Bu tez çalışmasında GKO verilerine uygulanarak öznitelik vektörüne katkı sağlamak amacıyla kullanılmıştır. PE yöntemi kullanarak elde edilen öznitelik seti, güç kalitesi işaret işleme alanına ilk olarak bu tez çalışmasıyla önerilmiştir. PE yönteminin hesap adımlarında başlangıç olarak, verilen bir $x(t), t = 1, 2, \dots, T$ zaman serisi işareti sembolik bir diziye dönüştürülür. Böylece, var olan değerler ve bir önceki değerler arasında, eşit uzaklıkta olan bir sabiti baz alan ilişki elde edilmiş olur [98, 99]. Dönüşüm yönteminin gömülü mantığına ait ifade (4.20)

ile şu şekilde gösterilir:

$$x(t) = [x(t), x(t+l) \dots x(t+ml)] \quad (4.20)$$

burada, m gömülü boyut parametresini, l ise zaman gecikme parametresini göstermektedir. Verilen bir m parametresi için $m!$ kadar π olası permütasyon elde edilebilir. Böylece, göreceli frekans değeri (4.21) ile şu şekilde gösterilebilir:

$$p(\pi) = \frac{f(\pi)}{T - (m-1)l} \quad (4.21)$$

burada, π sembolize frekansının $x(t)$ içerisindeki değerini $f(\pi)$ temsil etmektedir. PE değeri (4.22) eşitliği kullanılarak şu şekilde hesaplanabilir:


$$PE(m) = - \sum_{\pi=1}^{m!} p(\pi) \ln p(\pi) \quad (4.22)$$

Normalizasyon faktörü ($1/\ln(m!)$) dikkate alındığında, normalize edilmiş PE değeri son adımda, (4.23) eşitliği ile şu şekilde ifade edilir:

$$PE = \frac{PE(m)}{\ln(m!)} \quad (4.23)$$

m parametresinin seçimi PE hesabında önemli bir yer tutar [99]. Eğer m düşük bir değer olarak belirlenirse, yöntem düzgün çalışmayabilir. Bununla birlikte, m değerinin üst limit değerleri hesapsal karmaşa ve işlem yükü fazlalığından dolayı hafıza kullanım yetersizliği ortaya çıkarabilir [98, 99]. Bu tez çalışmasında, PE parametrelerinden $m = 3$ ve zaman gecikmesi $l = 1$ değerleri deneysel olarak belirlenmiştir.

Şekil 4.16, veri setinden seçilmiş örnek bozulma olaylarına ait PE değerlerini görsel olarak ifade etmektedir. PE öznitelik setini oluştururken, her olay işareti için birer adet PE öznitelik değeri ve 6 adet PE histogram dağılımından elde edilen PE_{hist} değeri ile birlikte toplam 7 öznitelik kullanılmıştır.




Şekil 4.16: Örnek bozulma olaylarına ait PE değerleri

4.1.5. Yerel Tepe Noktaları

Yerel tepe (Local Peaks–LP) noktaları öznitelik seti, zaman serisi işaretine ait yerel maksimumların sayısının tespit edilmesiyle oluşmaktadır. Güç kalitesi olay işaretleri için önerilen bir diğer öznitelik çıkarım yöntemi olan yerel tepe nokta sayıları tespiti, olay işaretlerinin durağan olmayan ve hızlı genlik değişimine sahip yapıda olmalarından dolayı tercih edilmiştir.

Yerel bir tepe noktası, kendisinden önceki ve sonraki komşu örnek değerlerinden daha büyük olan bir nokta olarak tanımlanabilir. Veri dizinindeki tepe noktalarını tespit etmek birçok işaret işleme uygulaması için önemli bir adımdır. Biyomedikal işaret işleme uygulamalarında, özellikle kalp ritmini ortaya koyan ya da beyin fonksiyonları ile ilgili olan işaretlerden yerel tepe nokta bilgisi almak, sistemin işleyişinde hayati bir yer tutabilir. Aynı şekilde, trafik yoğunluk tespit uygulamaları, güneş ve rüzgar enerjisi dalgalanmaları ile ilgili işaret işleme uygulamalarında da tepe noktası tespiti önemli bilgilere ışık tutacak özelliktedir. Konuya ait literatürde, tepe noktası tespiti için dönüşüm tabanlı yöntemlerden filtre merkezli veya akıllı sistem içerikli uygulamalara kadar geniş bir yelpazede önerilen birçok çalışma bulunmaktadır [100].

Tüm bunlardan hareketle; bu tez çalışmasında, her bir olay verisine ait yerel noktaların sayıları saptanarak, veri setindeki tüm işaretler için birer adet ayırt edici öznitelik elde edilmiştir. Elde edilen bu değerler ile LP öznitelikleri alt seti oluşturulmuştur. Çalışmada, tepe noktaları analizine ait detaylı işlemler yapılması kapsam dışı olduğu için MATLAB yazılımında oluşturulan sade sorgulama kod dizinleri ile tepe nokta tespitleri gerçekleştirilmiştir. Şekil 4.17, örnek bir veri dağılımından elde edilmiş yerel tepe noktalarına ait gösterim sunmaktadır.



Şekil 4.17: Örnek bir işarete ait yerel tepe noktaları

4.1.6. Anlık Zaman Bölgesi Öznitelikleri

Güç kalitesi olay verilerinin makine öğrenme tabanlı bir karar sürecinde akıllı olarak sınıflandırılmasının daha etkin olarak gerçekleştirilmesi için öznitelik setinin zengin bir ayırt edicilik yeteneğinin bulunması gerekmektedir. Bu amaçla adım adım oluşturulan öznitelik setine, çeşitli anlık zaman bölgesi parametreleri de hesap edilerek eklenmiştir. Burada tercih edilen öznitelikler, özellikle haberleşme alanında kullanılan ve sayısal modülasyon sınıflandırma süreçlerinde kullanılan bir takım parametrelerden elde edilmiştir [101].

Anlık zaman bölgesi (Instantaneous Time Domain-ITD) öznitelikleri, işaretin anlık genlik, faz ve frekans değişimlerine bağlı olarak belirlenmektedir. Modülasyon işaretlerinin taşıyıcı frekans, faz ve genlik gibi değişken karakterli yapıdaki özelliklerinden faydalanan ayırt edicilik sağlayan anlık zaman bölgesi parametreleri, güç kalitesi bozulma işaretlerinin

benzer özelliklerinden dolayı bu işaretler için önemli ölçüde ayırt edicilik sağlamaktadır. Bu amaçla tercih edilen özniteliklerden ilk ikisi Hilbert dönüşümü (Hilbert Transform–HT) tabanlıdır. Zaman serisi bir işaretten karmaşık değerlikli bir veri seti üretilmesine dayanan HT yöntemi, doğrusal ve durağan yapıda olmayan işaretlerin analizinde kullanılan ve anlık frekans belirlemeye dayalı bir yöntemdir [101].

Öznitelik setindeki parametre hesabında kullanılacak olan HT yöntemi ile zaman serisi işareti, gerçek ve sanal olarak iki bileşenli bir analitik işarete dönüştürülür. Gerçek bileşen özgün işaret bilgisini, sanal bileşen ise Hilbert dönüşüm parametrelerini içermektedir. Sanal bileşen, dönüşüme maruz kalan gerçek işaretle 90° faz farkına sahiptir. Yani dönüşüm bu haliyle sinüs işaretlerinin kosinüs eşdeğerine dönüştüğü bir yapıdır. HT sonucu elde edilen dönüştürülmüş işaret dizisi, özgün işaretle aynı genlik ve frekans içeriğine sahiptir ve özgün işaretin faz açısı değerine göre elde edilen bir faz bilgisi vermektedir. Bu yüzden HT, zaman serisi işaretlerinin anlık değerlerini elde etmede özellikle genlik ve frekans hesabında oldukça etkili bir yöntemdir [102].

Hilbert dönüşümünün ayırık işaretlere uyarlanan hesaplama yöntemi, dönüşümü yapılacak $x(t)$ işaretinin $(1/\pi t)$ fonksiyonu ile konvolüsyonu ile ifade edilir. Bu durum (4.24) ile şu şekilde gösterilmiştir [102]:

$$x_H(t) = x(t) * (1/\pi t) = \frac{1}{\pi} \int_{-\infty}^{\infty} x\left(\frac{\lambda}{(t-\lambda)}\right) d\lambda \quad (4.24)$$

burada, λ öteleme operatörüdür.

Elde edilen bu analitik işaret, özgün işaretin genlik ve fazı hakkında bilgi içermektedir ve aynı zamanda özgün $x(t)$ işaretinin 90° faz kaydırılmış halidir. Bu analitik işaret tanımı (4.25) eşitliği ile ifade edilebilir:

$$\hat{x}[k] = x[k] + jx_H(t) = |\hat{x}[k]| e^{j\theta(t)} \quad (4.25)$$

Buradan hareketle genlik (zarf–envelop) ifadesi (4.26) eşitliği şu şekilde hesaplanır:

$$|\hat{x}[k]| = \sqrt{x[k]^2 + x_H[t]^2} \quad (4.26)$$

Elde edilen ifadeler kullanılarak, anlık faz ve anlık frekans bilgilerine sırasıyla (4.27) ile şu

şekilde ulaşılır:

$$\begin{aligned}\theta[t] &= \arctan \frac{x_H[t]}{x[k]} \\ f[t] &= \frac{1}{2\pi} \frac{d\theta[t]}{dt}\end{aligned}\quad (4.27)$$

- Yukarıda hesaplanan parametreler ışığında HT tabanlı ilk öznitelik (HB_1), işaretin normalize edilmiş ve merkezlenmiş mutlak genlik ifadesinin standart sapması olarak ifade edilen ve (4.28) eşitliği ile hesaplanan parametresi olarak belirlenmiştir [101]:

$$HB_1 = \sigma_{aa} = \sqrt{\frac{1}{N_s} \left[\sum_{k=1}^{N_s} x_{cn}^2(k) \right] - \left[\frac{1}{N_s} \sum_{k=1}^{N_s} |x_{cn}(k)| \right]^2} \quad (4.28)$$

burada, $x_{cn}(k) = (x[k] / m_a)$ olarak ifade edilir ve m_a ifadesi de $x[k]$ işaretinin ortalama değerini temsil eder. N_s ise örnek sayısını ifade etmektedir.

- ITD verilerinden elde edilen özniteliklerin ikincisi (HB_2), bir P oranı ile verilen spektrum simetri parametresidir ve matematiksel olarak (4.29) ile gösterilir [101]:

$$HB_2 = P = \frac{P_L - P_U}{P_L + P_U} \quad (4.29)$$

P_L ve P_U ifadeleri, (4.30) eşitliğinde tanımlanmıştır:

$$\begin{aligned}P_L &= \sum_{k=1}^{fcn} |R(k)|^2 \\ P_U &= \sum_{k=1}^{fcn} |R(k + fcn + 1)|^2\end{aligned}\quad (4.30)$$

burada, fcn ifadesi örnek sayısına (N_s) göre bir f_c parametresi ile normalleştirilmiş örnekleme frekansını (f_s) ifade etmektedir ve matematiksel ifadesi (4.31) ile gösterilmiştir. Bu çalışmada ampirik olarak elde edilen f_c değeri 10.000 olarak tanımlanmıştır. $R(k)$ ifadesi ise $x[k]$ işaretinin Hızlı Fourier Dönüşümü (Fast Fourier Transform–FFT) çıktısını ifade eder [101]:

$$fcn = \frac{f_c N_s}{f_s} - 1 \quad (4.31)$$

- Zaman bölgesi öznitelik setinin son bileşeni (HB_3), normalize edilmiş ve merkezlenmiş anlık genlik ifadesinin güç spektrumunun (Power Spectral Density–PSD) maksimum değerini hesaplayarak elde edilir. Özellikle durağan olmayan işaretlerin detaylı olarak incelenmesi sürecinde kullanılan PSD, işaretlere ait önemli derecede ayırt edici vurgular içerebilmektedir. PSD hesabı için öncelikle işarete Ayırık Fourier Dönüşümü (Discrete Fourier Transform–DFT) uygulanır. Bu tanıma ait matematiksel eşitlik (4.32) ile şu şekilde verilmiştir [101]:

$$HB_3 = \gamma_{max} = \frac{\max |DFT(x_{cn}(k))|^2}{N_s} \quad (4.32)$$

burada, γ_{max} işaretlere ait genlik değerlerinin değişimini temsil eder ki güç kalitesi bozulma olaylarında bu durum sınıflar arası ayrım gerçekleştirmede önemli bir özelliktir. Bozulma olayları arasındaki genlik değişimi sınıfların ayırt edilmesi noktasında güçlü bir belirleyici unsurdur.

4.1.7. Fisher Vektör Kodlama

Bu tez çalışmasında, öznitelik setinin karar aşamasında daha etkin bir şekilde sınıflandırılması için Fisher Vektör (FV) kodlama yöntemi kullanılmıştır. Öznitelikleri, FV çekirdek fonksiyon yapısı ile haritalanmasıyla daha çok sayıda eleman içeren yüksek boyutlu bir dağılım elde edilmektedir. FV kodlama yapısı genellikle, çok sayıda öznitelik içeren görüntü işleme uygulamalarında kelimeler çantası (Bag of Words–BoW) görsel haritalama yöntemine alternatif olarak kullanılmaktadır [103, 104]. FV kodlama yöntemi, BoW haritalama yönteminin geliştirilmiş bir sürümü olarak da tanımlanır [105]. Literatürde, zaman serisi işaret analizi uygulamalarında da başarılı sınıflandırma sonuçlarını desteklediği gözlemlenmiştir [106, 107]. Bu nedenle tez çalışmasında, literatüre bir katkı olarak yöntemin güç kalitesi bozulma olaylarından elde edilen öznitelik setine uyarlanması önerilmiştir.

FV kodlama yönteminin temelinde, öznitelik setine parametrik bir model olan Gauss Karışım Model (Gaussian Mixture Model–GMM) uyarlaması yatmaktadır. FV kodlamada, GMM modele ait parametreler kullanılarak log–olabilirlik (log-likelihood) türevi hesaplanmaktadır [103, 105]. Böylece, öznitelik dağılımı ve GMM dağılımındaki merkezlerin her bir elemanı arasındaki birinci ve ikinci derece fark değerlerinin ortalamasını betimleyen bir gösterim ortaya çıkarılmış olur. En temel ve özet ifadesiyle FV kodlama, farkların belirli

parametrelerle kümelenmesi işlemini gerçekleştirmektedir [104, 105].

FV kodlama yönteminde giriş olarak, ham işaretlerden yukarıda da anlatımları verilen yöntemleri kullanarak elde edilebilecek bir $X = \{x_1, x_2, x_3, \dots, x_N\}$ ile tanımlı, N boyutlu öznitelik seti kullanılabilir. Giriş olarak kullanılan öznitelik vektörüne, çoklu Gauss dağılımlarının doğrusal birleşimi olarak ifade edilen bir olasılık yoğunluk fonksiyonu (Probability Density Function–PDF) olan GMM uygulanarak kod kitabı elde edilir [107]. N boyutlu X öznitelik giriş seti için uyarlanan GMM matematiksel ifadesi, Π_k önsel olasılık değerleri ile birlikte, (4.33) eşitliği yardımıyla şu şekilde sunulabilir:

$$p(x | \lambda) = \sum_{k=1}^K g(x | \mu_k, \Sigma_k) \Pi_k \quad (4.33)$$

burada, tamamlayıcı Gauss yoğunluklarını temsil eden $g(x | \mu_k, \Sigma_k)$ ifadesine ait açık gösterim, ortalama değer vektörü μ_k ve ortak varyans (kovaryans) Σ_k bileşenleriyle (4.34) kullanılarak verilir:

$$g(x | \mu_k, \Sigma_k) = \frac{1}{\sqrt{(2\pi)^N |\Sigma_k|}} \exp \left\{ -\frac{1}{2} (x - \mu_k)' \Sigma_k^{-1} (x - \mu_k) \right\}, \quad \text{Burada } \left(\exp: e^{(\cdot)} \right) \quad (4.34)$$

GMM yapısı, içerdiği parametrelerle birlikte $\lambda = (\mu_k, \Pi_k, \Sigma_k)$ olarak ifade edilir. Burada, $k = 1, 2, \dots, K$ olarak verilen dizi tanımı, tamamlayıcı Gauss yoğunluklarına ait küme sayısını temsil eder. μ_k ve Σ_k yukarıda da bahsedildiği üzere ortalama değer ve kovaryans değerleridir. GMM parametreleri, eğitim setinden elde edilen öznitelikler dahil edilerek, Beklenen değer–Maksimum değer (Expectation–Maximization–EM) algoritması ile kestirilebilir. EM yöntemi, gözlenemeyen yapıda değişkenler ve tahmin edilmesi gereken parametreler içeren bir modelin en büyük olabilirlik ya da en büyük sonsal olasılık tahmininde kullanılan dögüsel (iteratif) bir optimizasyon algoritması olarak tanımlanmıştır [9]. EM, beklenti adımında bir önceki dögüye ait veriler ışığında, logaritmik–olabilirlik fonksiyonunun alabileceği beklenen değer ile özgün olabilirlik fonksiyonu için bir taban değer tespit eder. Devamında, maksimize etme adımında ise bu değerlere göre optimizasyon işlemini gerçekleştirir. Giriş olarak verilen $X = \{x_1, x_2, x_3, \dots, x_N\}$ öznitelik vektöründeki N adet bileşen için sonsal olasılıklar q_{ik} olarak belirlenirse, modeldeki K adet Gauss yoğunluğu için yumuşak atama (soft

assignment) da denilen (4.35) ifadesi yazılabilir [107]:

$$q_{ki} = \frac{g(x_i | \mu_k, \Sigma_k) \Pi_k}{\sum_{j=1}^K g(x_i | \mu_j, \Sigma_j) \Pi_j}, \quad j = 1, 2, \dots, K \quad i = 1, 2, \dots, N \quad (4.35)$$

Buradan hareketle her k , ortalama (μ_k) ve kovaryans (Σ_k) sapma parametre değerleri için elde edilecek FV kodlama öznitelik vektörleri (4.36) ve (4.37) kullanılarak hesaplanır [107]:

$$u_k = \frac{1}{N\sqrt{\Pi_k}} \sum_{i=1}^N \frac{q_{ik}}{\sqrt{\Sigma_k}} (x_N - \mu_k) \quad (4.36)$$

$$v_k = \frac{1}{N\sqrt{\Pi_k}} \sum_{i=1}^N q_{ik} \left[\frac{(x_N - \mu_k)}{\Sigma_k} (x_N - \mu_k) \right] \quad (4.37)$$

Bu öznitelik vektörleri, Σ_k kovaryans matrislerinin diyagonal yapıda olduğu varsayımı ile daha az hesaplama süresi ile elde edilirler. Özniteliklerin FV kodlama ile yeniden oluşturulmuş hali u_k ve v_k ifadelerin birleştirilmesi ile her K Gauss dağılım merkezi için (4.38) eşitliğinde gösterildiği şekilde ifade edilebilir [107]:

$$f_{\text{Fisher}} = [u'_1, v'_1, \dots, u'_K, v'_K]' \quad (4.38)$$

FV kodlama sonucunda elde edilen yeni öznitelik setlerinin boyutları $2 \times K \times N$ değerindedir. Burada K , Gauss küme sayısını temsil etmektedir ve bu çalışmada tanımlı değer $K = 1$ olarak belirlenmiştir. N ise işlenen toplam öznitelik sayıdır. Bunun sonucunda tez çalışmasında, FV kodlama kullanarak öznitelik vektörünün boyut sayısı 2 kat arttırılmıştır.

FV kodlama yöntemine ait algoritma adımları konunun daha net bir büyük resimle sunulması adına, Şekil 4.18 ile özetlenmiştir. Ayrıca, Şekil 4.19 ile de bu anlatımın genel blok şeması gösterilmiştir. Algoritma işlem basamakları ve blok şemadaki adımlar incelendiğinde, veri setinden elde edilen özniteliklerin *eğitim* ve *test* olarak ikiye ayrıldıktan sonra sadece eğitim verileri kullanılarak GMM parametreleri elde edilmiş ve kod kitabı oluşturulmuştur. Bu işlem sonucunda $FV_{\text{eğitim}}$ öznitelik seti elde edilmiştir. Test verilerini oluşturacak öznitelik seti elde edilirken, eğitim veri dağılımından elde edilen GMM parametre değerleri kullanılmıştır. Tekrar hesap yapılmamıştır. Böylece, FV kodlama sonucu sınıflandırıcıya giriş olarak verilecek $FV_{\text{eğitim}}$ ve FV_{test} öznitelik vektörleri elde edilmiş olur.

Giriş:

- 1: $X_T = \{x_1, x_2, \dots, x_T\}$ $\{T$ boyutlu öznitelik vektörü: Eğitim Verisi}
- 2: $X_{\text{Test}} = \{x_{T+1}, x_{T+2}, \dots, x_{N-T}\}$ $\{N - T$ boyutlu Öznitelik vektörü: Test Verisi}
- 3: K {Gauss küme sayısı (Bu çalışmada tanımlı değer 1'dir.)}

Çıkış: $FV_{\text{eğitim}}$ ve FV_{test} {Elde edilecek FV Kodlu son öznitelik vektörleri}

EĞİTİM

GMM için model parametrelerinin belirlenerek kod kitabı oluşturulması :

- 4: Eğitim seti özniteliklerini yükle (X_T)
 - 5: GMM parametrelerini belirle $\lambda = (\mu_k, \Pi_k, \Sigma_k)$, eşitlik (4.35)
-


Eğitim işlemi için kullanılacak FV özniteliklerinin belirlenmesi :

- 6: **for** $k = 1$ **to** K **do**
 - 7: Adım (5) ile hesaplanan parametrelerden FV kodlu öznitelikleri hesapla, u_k ve v_k , eşitlik (4.36) ve (4.37)
 - 8: **end for**
 - 9: Eğitim işlemi öznitelik vektörünü hazırla, $FV_{\text{eğitim}}$ (4.38)
-

TEST

- 10: Test seti özniteliklerini yükle (X_{Test})
 - Test işlemi için kullanılacak FV özniteliklerinin belirlenmesi :*
 - 11: **for** $k = 1$ **to** K **do**
 - 12: Adım (5) ile hesaplanan parametrelerden FV kodlu öznitelikleri hesapla, u_k ve v_k , eşitlik (4.36) ve (4.37)
 - 13: **end for**
 - 14: Test işlemi öznitelik vektörünü hazırla, FV_{test} (4.38)
-

Şekil 4.18: Önerilen FV kodlama algoritma adımları



Şekil 4.19: Önerilen FV kodlamalı yöntemin blok şeması

4.2. Akıllı Sınıflandırıcı Yapıları

Bu bölümde, güç kalitesi bozulma olayları ile ilgili bir örüntü tanıma işleminin yapıldığı bu tez çalışmasında kullanılan makine öğrenme tabanlı akıllı sınıflandırıcılara ait genel bilgiler verilecektir. Önceki bölümde elde edilen öznitelik vektörü üç farklı sınıflandırıcı tarafından işlenecektir: Temel ELM, ağırlıklandırılmış W-ELM ve temel yapının aşağıda özetlenecek bir çok kısıtlamasını gideren Seyrek Bayes tabanlı SB-ELM. Bu bölümde, Şekil 4.20 ile gösterildiği sırada, bu üç yapıya ait yöntemler ayrıntılarıyla sunulacaktır. Bölüm girişinde makine öğrenme yöntemlerinin temel unsuru olan *sınıflandırma* kavramı ile ilgili özet tanımlar sunulacaktır.



Şekil 4.20: Çalışmada kullanılan sınıflandırıcı yapıları

Bu tez çalışmasında *eğitmenli öğrenme* yapısı temelli bir öğrenme yöntemi gerçekleştirilmiştir. Bu yapıda, makine öğrenmesi için giriş ve çıkış ifadelerinin her ikisi de sınıflandırma algoritmasına sunulmaktadır. Buradaki, belirli sayıda giriş vektörünü, yine belirli sayıda ayrık kategorilere atamayı amaçlayan işlem **sınıflandırma** (*classification*) problemi olarak adlandırılmaktadır. Bu işlemde öncelikle, bir x vektörü giriş olarak alınarak, K adet ayrık C_k sınıfından birine atanmaktadır, burada $k = 1, \dots, K$ ile tanımlıdır [8, 108]. Çoğu uygulama için geçerli olan sınıfların ayrık yapıda olması durumu, her girişin sadece bir tek sınıfa atanmış olduğunu ifade etmektedir.

Sınıflandırma işleminin gerçekleştiği karar uzayında, girişlerin atandıkları her bir elemanın bağlı olduğu kategoriler *sınıf* ve karar yapıcı algoritma da *sınıflandırıcı* olarak isimlendirilir. Literatürde makine öğrenmesi tabanlı, Bayes sınıflandırıcı, karar ağaçları, k-en yakın komşu algoritması, yapay sinir ağları, destek vektör makineleri, uç öğrenme makineleri gibi çeşitli sınıflandırıcı yapıları bulunmaktadır [4, 8]. Sınıflandırıcı yapısı bir başka

ifade ile *model*, öznitelik uzayında haritalanmış (*feature mapping*) giriş veri dizisini, önceki örneklerden çıkarsaması yapılan sınıflara doğru haritalama işlemini gerçekleştirir.


Bir sınıflandırma modeli, $\hat{o} : X \rightarrow S$, $S = \{S_1, \dots, S_N\}$ ifadesi ile matematiksel olarak özetlenebilir. Burada $\hat{o}(x)$ tanımı, $o(x)$ gerçek giriş örneğinin hangi sınıfa ait olduğunu bilinmeyip, tahmin edildiğini ifade etmektedir. İşlem sonunda giriş örnekleri, $(x, o(x))$ biçimini alır ve $o(x)$ gerçek sınıf değerlerine atanır [8].

Makine öğrenme yapısının temel işlevi olan sınıflandırma kavramı, bilinmeyen yapıdaki bir veri porsiyonunu bilinen kategorilere atama işini yapmaktadır. Sınıflandırmanın temel amacı, önceki örnekler merkez alınarak gerçekleştirilen öğrenme sürecinden sonra sisteme daha önce giriş olarak tanıtılmamış bilinmeyen örnekleri, en yüksek doğruluk değerinde ayrıştıracak modeli elde etmektir [8]. Makine öğrenme tabanlı sınıflandırma modeli, *akıllı sınıflandırıcı* olarak adlandırılmaktadır.

Olasılıksal sınıflandırıcılar olarak isimlendirilen bazı sınıflandırma modelleri, çıkış olarak giriş setindeki örneklerin sınıflara ait olma olasılıklarını üretirler. *Ayrık sınıflandırıcı* olarak isimlendirilen bir diğer grup ise çıkışta veri setindeki giriş örneklerine ait tahmini sınıf etiketini üretirler. Bu tez çalışmasında ikinci gruptaki sınıflandırıcı yapıları da ele alınmaktadır. Ayrık sınıflandırıcı yapısının ürettiği $\hat{o}$ çıkışında aşağıdaki seçeneklerden birisi gerçekleşmektedir [8]:

- **İkili sınıflandırma :** Giriş örneği, bir biri ile bağlantılı olmayan iki sınıftan sadece birisine dahildir.
- **Çoklu sınıflandırma :** Giriş örneği, bağlantılı olmayan m adet sınıftan sadece birisine dahildir.
- **Çok etiketli sınıflandırma :** Giriş örneği, bağlantılı olmayan m adet sınıftan birkaç tanesine dahildir.
- **Aşama sıralı sınıflandırma :** Giriş örneği, aşamalı olarak alt sınıflara ayrılan ya da üst sınıflara kategorize olabilen sınıflardan sadece birine dahildir.

Bu tez çalışmasında, güç kalitesi olay verilerinden oluşan gerçek veri seti, birbirinden bağımsız 5 farklı sınıfa ayrıldığı ve giriş işaretleri bu sınıflardan sadece bir tanesine dahil olduğu için *çoklu sınıflandırma* kapsamına giren çalışmalar yürütülmüştür.




Şekil 4.21: CRISP modeline ait süreç döngüsü [109].

Şekil 4.21 ile süreç döngüsü verilen yönetim modeli, iki yüzü aşkın profesyonelin, veri madenciliği ürün ve hizmet sağlayıcının desteği ile hazırlanan, Veri Madenciliğine Yönelik Karşılıklı Endüstri Standart Süreci (CRoss Industry Standard Process for Data Mining–CRISP) olarak adlandırılan CRISP modeli, veri madenciliği alanındaki çalışmalara bütüncül bir destek sunan yönetim şeması olarak kullanılmaktadır [8, 109]. Veri madenciliği ve makine öğrenme süreçlerinin benzerliği göz önüne alınırsa, veri madenciliği alanında verimli olarak kullanılan bu modelin referans alındığı çerçeveyi kullanmak yararlı olacaktır [8]. Bu tez çalışmasında gerçekleştirilen çoklu sınıflandırma yapısına dayanan makine öğrenme sisteminde CRISP modelinin ortaya koyduğu süreç işletilmiştir. Problem tanımı, veri tanımı ve veri hazırlama adımları önceki bölümlerde detaylı olarak anlatılmıştı. Bölümün devam eden kısmında, kullanılan sınıflandırıcı modellerine ait yöntemsel detaylar aktarılacak ve bulgular ve incelemelerin ele alındığı sonraki bölüm ile de değerlendirme ve model uygulama süreçlerine geçilecektir.

4.2.1. Uç Öğrenme Makinesi (ELM)

Huang ve ekibi tarafından önerilen ELM, Tek Gizli Katmanlı İleri Beslemeli (Single hidden Layer Feed-forward Neural network–SLFN) bir sinir ağı modeli için kullanılan öğrenme algoritmasıdır [110]. Gradyan temelli ileri beslemeli ağların aksine, ELM yönteminde giriş ağırlıkları ve eşik değerleri rastgele üretilirken, çıkış ağırlıklarının hesaplanmasında analitik yöntemler kullanılır. Bu yöntem sayesinde öğrenme süreci son derece hızlandırılmış olur. ELM hızlı öğrenebilme yeteneğinin yanı sıra geleneksel geriye yayılım algoritması ile öğrenen ileri beslemeli ağlara göre daha iyi genelleme başarımına sahiptir [53]. Şekil 4.22, bir SLFN yapısının genel mimarisini göstermektedir. ELM yönteminde, giriş ve gizli katman arası bağlantılar sabit değerlidir. Gizli katmanı çıkışa bağlayan bağlantılar ise ayarlanabilir yapıdadır [111].



Şekil 4.22: Tek katmanlı ileri beslemeli ağ yapısı

Bu ayrıtta, matematiksel anlatımı ve oluşturulmasında esinlenilen önceki öğrenme yapılarıyla birlikte tüm matematiksel detaylarına [110] çalışması ile ulaşılabilen ELM yöntemine ait temel matematiksel özelliklere değinilecektir. Tez çalışmasında kullanılan geliştirilmiş varyasyonlarının anlatımından önce en temel ELM yapısına değinerek açıklamalara başlanacaktır.

Eğitim sürecinde kullanılmak üzere N örnek sayısına sahip, $\mathcal{D} = (\mathbf{x}_i, \mathbf{t}_i)$, $i = 1 \cdots N$ şeklinde bir eğitim veri seti düşünölsün. Burada giriş vektörü $\mathbf{x}_i$ ve çıkış değeri $\mathbf{t}_i$ olarak verilmiştir ve d -boyutludur. Gizli katmanında L adet nöron bulunan bir ELM yapısına ait çıkış fonksiyonu (4.39) ile şu şekilde ifade edilebilir [56]:

$$f(\mathbf{x}) = \sum_{k=1}^L \beta_k h_k(\theta_k; \mathbf{x}) = \mathbf{h}(\Theta; \mathbf{x})\beta \quad (4.39)$$

burada, $\mathbf{h}(\Theta; \mathbf{x}) = [1, h_1(\theta_1; \mathbf{x}), \dots, h_L(\theta_L; \mathbf{x})]$ ifadesi, $\mathbf{x} \cdot \Theta = [\theta_1, \dots, \theta_L]$ giriş vektörü ve β çıkış ağırlık vektörüne bağılı olarak gizli katman özellik haritalaması gerçekleştiren bileşendir. Burada her $\mathbf{x} \cdot \Theta$ içsel çarpım ifadesine bias değeri de eklenmiştir. Gizli katman etkinleştirme (aktivasyon) fonksiyonunu $h_k(\cdot)$ temsil eder. Eşitlik (4.39) daha sade bir biçimde (4.40) ile gösterilir:

$$\mathbf{H}\beta = \mathbf{T} \quad (4.40)$$

burada, $\mathbf{H}$ özellik haritalama matrisidir ve $N \times L$ boyutundadır. $\mathbf{H}$ matrisine ait açık ifade (4.41) ile gösterilmiştir:

$$\mathbf{H} = \begin{bmatrix} 1 & h_1(\theta_1; \mathbf{x}_1) & \cdots & h_L(\theta_L; \mathbf{x}_1) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & h_1(\theta_1; \mathbf{x}_N) & \cdots & h_L(\theta_L; \mathbf{x}_N) \end{bmatrix} \quad (4.41)$$

burada, $\mathbf{H}$ matrisinin i . satırı bir x giriş örneğı için gizli katman çıkış vektörünü ifade eder. (4.40) eşitliğinin çözümüne dönölsün, çözüm ifadesi (4.42) ile gösterilen doğrusal sistem çözümü olarak ifade edilebilir:

$$\beta = \mathbf{H}^\zeta \mathbf{T}, \quad \mathbf{H}^\zeta = \left(\frac{\mathbf{I}}{C} + \mathbf{H}^T \mathbf{H} \right)^{-1} \mathbf{H}^T \quad (4.42)$$

burada, $\mathbf{H}^\zeta$ ile $\mathbf{H}$ matrisinin Moore–Penrose tersi [112] olarak ifade edilen genelleştirilmiş

tersi temsil edilmektedir. Pozitif değerli C katsayısı, ELM yönteminin çoklu sınıflandırma uygulamalarında daha etkili olabilmesi adına belirlenen bir düzenleme parametresidir [53]. Bu tez çalışmasında temel ELM yöntemi referans alındığı için C katsayısı kullanılmayan çözüm ifadesi tercih edilmiştir ($\mathbf{I}/C = 0$).

(4.42) eşitliği, çıkış değerlerini tanımlamak için gerekli sade yapıda bir çözüm ifadesini göstermektedir [110]. Geleneksel algoritmalarda, arzu edilen çıkışlara ulaşmak için döngüsel çözüm adımları gerekirken ELM yöntemi, herhangi bir döngüsel eyleme gerek bırakmaksızın çözüme tek seferde ulaşmayı deneyerek benzer problemle başa çıkar.

Optimizasyon bakış açısına dayanan ek bir anlatım ile daha ayrıntılı olarak belirtmek gerekirse, ELM süreci $\|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\|^2$ ve $\|\boldsymbol{\beta}\|$ ifadelerini minimize etmeyi hedefler. Böylece, (4.40) eşitliğinin çözümü, optimizasyon tanımlarıyla (4.43) ile şöyle sunulabilir [113]:

$$\begin{aligned} \text{Amaç (Minimize)} \quad L_{PELM} &= \frac{1}{2} \|\boldsymbol{\beta}\|^2 + C \frac{1}{2} \sum_{i=1}^N \|\boldsymbol{\xi}_i\|^2 \\ \text{Kısıtlar (Subject to)} \quad \mathbf{h}(\mathbf{x}_i)\boldsymbol{\beta} &= \mathbf{t}_i^T - \boldsymbol{\xi}_i^T, \quad i = 1, \dots, N \end{aligned} \quad (4.43)$$

burada, $\boldsymbol{\xi}_i = [\xi_{i,1}, \dots, \xi_{i,m}]$ vektörü, her $\mathbf{x}_i$ eğitim veri örneği için m çıkış düğümlerinin eğitim hata değeridir. Çözümü optimizasyon bakış açısı ile sürdürdüğümüzde, Karush–Kuhn–Tucker (KKT) teoremine dayalı çözüm işlemi de (4.42) ifadesinde verilenle aynı sonucu üretir [113].

ELM yöntemi aynı zamanda çoklu sınıflandırma süreçlerine de etkili şekilde cevap vermektedir. Örnek sayısı N olan $(\mathbf{x}_i, \mathbf{t}_i)$ eğitim giriş ve çıkış vektörleri, m farklı sınıf ile düşünülürse, her örnek için m uzunluğunda bir $\mathbf{t}_i$ vektörü (4.44) ile şu şekilde ifade edilebilir:

$$\mathbf{t}_i[j] = \begin{cases} 1 & \text{eğer } \mathbf{x}_i \in \text{sınıf } j \\ -1 & \text{eğer } \mathbf{x}_i \notin \text{sınıf } j \end{cases} \quad (4.44)$$

Buradan hareketle, verilen bir $\mathbf{x}$ örneği için ELM çıkış fonksiyonu, (4.45) ile şu şekilde türetilir [110, 113]:

$$\mathbf{f}(\mathbf{x}) = \mathbf{h}(\mathbf{x}) \left(\frac{\mathbf{I}}{C} + \mathbf{H}^T \mathbf{H} \right)^{-1} \mathbf{H}^T \mathbf{T}, \quad N \geq L \text{ durumunda} \quad (4.45)$$

burada, $\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), \dots, f_m(\mathbf{x})]$ çıkış fonksiyonu vektörüdür. Bir $\mathbf{x}$ tahmin örneğine bağlı

olarak yürütülecek test aşaması için (4.46) ile verilen maksimum argüman ifadesine başvurulabilir [113]:

$$\text{label}(\mathbf{x}) = \arg \max_i f_i(\mathbf{x}), \quad i \in [1, \dots, m] \quad (4.46)$$

4.2.2. Seyrek Bayes Tabanlı Uç Öğrenme Makinesi (SB-ELM)

Önerildiği ilk tarih olan 2006 yılından günümüze kadar ELM, makine öğrenme alanındaki popüler etkisini korumaktadır. Son derece düşük hesapsal maliyeti ve cevap süresinin de bir o kadar hızlı olmasının getirdiği avantajlarla ELM, birçok farklı alanda kullanılmaktadır [53]. Bu durum da, rastlantısal gizli katman parametrelili bir SLFN yapısının türevlenebilir (sürekli) bir etkinleştirme fonksiyonu kullanılmasıyla çıkışında hemen hemen tüm sürekli fonksiyonları yakınsayabileceğini göstermiştir [56]. Bununla birlikte, temel ELM yöntemi şu iki olumsuz durumun etkisindedir: 1) ELM yapısı, çıkış ağırlıklarını hesaplayan $\mathbf{H}\beta = \mathbf{T}$ eşitliğini, Moore–Penrose genelleştirilmiş matris tersini kullanarak çözer. Bu nokta, bir çeşit en küçük kareler minimizasyon öğrenme yöntemi olduğu için kolaylıkla aşırı uyum (*over fitting*) sorunsalından etkilenebilir. Bu olumsuzluk, eğitim setinin öğrenilecek verilerin karakteristiğini tam olarak temsil edemediği durumlarda daha kötü bir hal alabilmektedir. 2) ELM yönteminin sınıflandırma doğruluğu, belirlenen gizli katman nöron sayısından ciddi ölçüde etkilenir. Pratik uygulamalar için tasarlanan bir ELM modeli çoğu kez yüzlerce ya da binlerce sayıda gizli katman nöron sayısına sahip olabilir [56]. Bu durumun etkileyeceği ilk başlık tabi ki gerçek uygulamaların üzerinde çalıştığı gömülü sistemler ve sahip oldukları hafıza değerleridir. Düşük maliyetli bir uygulamada, büyük ölçekli ELM modelini çalıştıracak yüksek maliyetli bir hafıza yapısı istenmez. Bu yüzden, model çıkışındaki başarımdan ödün vermeden model boyutunun azaltılmasıyla elde edilecek çözüm adımları gerekmektedir [4, 56].

Bahsedilen ilk olumsuzluğun giderilmesi adına, L2 tip düzenlemeli ELM, çekirdek (*kernel*) ELM gibi yöntemler önerilmiş olsa da hesapsal maliyetleri ve iş yüklerinden dolayı büyük veriler içeren uygulamalarda kullanılmaları çok güç yöntemlerdir [56].

ELM gizli katmanındaki nöron sayısını optimize ederek en uygun sayıda nöron değerini bulmayı amaçlayan mevcut yöntemler, artımsal öğrenme yöntemi ortaya koyarlar ve bir çoğu sadece regresyon uygulamalarına hitap etmektedir. Daha sonraları geliştirilen Bayes yaklaşımını merkez alan Bayes ELM (BELM), çıkış ağırlıklarını yüksek genelleme başarımı

ile hesaplamak için makine öğrenme yöntemlerinde avantaj ortaya koyarak, çıkış değerlerinin olasılıksal dağılımını tahmin ederek aşırı uyumdan kaçınmıştır. Bu durum, karmaşık hesapları içermesi ve sınıflandırma işlemine uyarlanamadığı için ortaya tam bir çözüm koyamamıştır [56].

Bu tez çalışmasında [56] referansında önerilen Seyrek Bayes (SB) öğrenme yaklaşımını temel alan Seyrek Bayes Uç Öğrenme Makinesi (Sparse Bayesian ELM–SB-ELM), güç kalitesi olay sınıflandırma işlemi için uyarlanmıştır.

SB–ELM yapısı, geleneksel ELM yapısında olduğu gibi rastlantısal olarak üretilen gizli katman parametrelerini takiben, çıkış ağırlıklarının seyrek temsillerini bularak, gizli katman nöron sayısına ekleme ya da silme yapmadan çözüme ulaşan bir yöntemdir. Çıkış ağırlıkları olarak tespit edilen β_k ($k = 0, \dots, L$ ve L gizli katman nöron sayısı) değerlerinin seyrek tahminlerini bulmak amaçlanır. SB–ELM yönteminde, seyrekleştirme işlemi, Bayes istatistik yaklaşımında kullanılan otomatik ilgililik belirlenim (Automatic Relevance Determination–ARD) yöntemine dayanmaktadır. Burada, çıkış ağırlıkları β_k değerleri üzerinde üstün-önsel (hyper-prior) α_k dağılımı taranarak bazı β_k değerleri *sıfır* olarak ayarlanır. Üstün-önsel $p(\alpha_k)$ dağılımında ilgililik derecesine göre çıkış ağırlıklarından bir çoğuna seyrekleştirme işlemi uygulanır ve gizli katman nöronları budanarak sadeleştirme yapılmış olur. Tüm bunlar, SB–ELM yapısının hem SB öğrenme yaklaşımındaki yüksek genelleme ve seyreklik hem de ELM yapısındaki evrensel yaklaşıklama ve etkili öğrenme hızı gibi olumlu yönleri yapısında topladığını göstermektedir [56].

ELM sınıflandırıcı yapısı için Bayesçi Çıkarım

Burada, ELM öğrenme yapısından farklı olarak, β çıkış ağırlıkları vektörü Bayes yöntemi kullanılarak öğrenilir. Yani $\mathbf{H}^L$ genelleştirilmiş ters ifadesi direkt olarak hesaplanmaz. Artık SB–ELM için giriş vektörü, gizli katman çıkışı olan $\mathbf{H}$ ifadesidir. Yani, Bayes öğrenme tabanlı ELM yapısı için girişler (4.47) ile şu şekilde tanımlanır [56]:

$$\mathbf{H} = [\mathbf{h}_1(\Theta; \mathbf{x}_1), \dots, \mathbf{h}_N(\Theta; \mathbf{x}_N)]', \quad \mathbf{H} \in \mathbb{R}^{N \times L} \quad (4.47)$$

$$\mathbf{h}_i(\Theta; \mathbf{x}_i) = [1, h_1(\theta_1; \mathbf{x}_i), \dots, h_L(\theta_L; \mathbf{x}_i)], \quad i = 1, \dots, N$$

Burada genel anlatıma, temel sınıflandırma yapısı (*ikili sınıflandırma*) ile devam edilecektir. İkili sınıflandırmadaki her eğitim örneğinin bağımsız bir Bernoulli olayı olduğu ve Bernoulli dağılım olasılığının $p(t|\mathbf{x})$ olduğu düşünülebilir. Buradan hareketle, olabilirlik ifadesine ait

detaylar (4.48) ile şu şekilde yazılabilir:

$$\begin{aligned}
 p(\mathbf{t}|\boldsymbol{\beta}, \mathbf{h}) &= \prod_{i=1}^N \sigma\left\{\mathcal{Y}(\mathbf{h}_i; \boldsymbol{\beta})\right\}^{t_i} \left[1 - \sigma\left\{\mathcal{Y}(\mathbf{h}_i; \boldsymbol{\beta})\right\}\right]^{1-t_i} \\
 \sigma\left[\mathcal{Y}(\mathbf{h}_i; \boldsymbol{\beta})\right] &= \frac{1}{1 + e^{-\mathcal{Y}(\mathbf{h}_i; \boldsymbol{\beta})}} \\
 \mathcal{Y}(\mathbf{h}_i; \boldsymbol{\beta}) &= \mathbf{h}_i \boldsymbol{\beta}
 \end{aligned} \tag{4.48}$$

burada $\sigma(\cdot)$ sigmoid fonksiyonudur ve $\mathbf{t} = (t_1, \dots, t_N)'$, $t_i \in \{0, 1\}$ ve $\boldsymbol{\beta} = (\beta_0, \dots, \beta_L)'$ olarak tanımlanmıştır. ARD üstün-parametresi (hyperparameter) α_k değerini kullanarak, her β_k parametresi için bir sıfır-ortalama Gauss önsel dağılımı (4.49) ve (4.50) ile ifade edilebilir [56]:

$$(\beta_k | \alpha_k) = \mathcal{N}\left(\beta_k | 0, \alpha_k^{-1}\right) \tag{4.49}$$

$$p(\boldsymbol{\beta} | \boldsymbol{\alpha}) = \prod_{k=0}^L \frac{\alpha_k}{\sqrt{2\pi}} \exp\left(-\frac{\alpha_k \beta_k^2}{2}\right) \tag{4.50}$$

burada, $\boldsymbol{\alpha} = [\alpha_0, \alpha_1, \dots, \alpha_L]'$ olarak tanımlıdır. Bilinmesi gereken önemli bir nokta, her β_k ifadesine atanmış bağımsız bir α_k değerinin var olduğudur. ARD önsel ilgililik tarama yöntemi, β_k ağırlıklarının sıfır değerlerini kontrol ederek belirgin gizli nöronları seçme işlemini gerçekleştirir. Son adım olarak, çıkış sınıfları olan $\mathbf{t}$ şartları üzerinden $\boldsymbol{\alpha}$ ve $\mathbf{H}$ ifadelerine ait olabilirlik değerini tümleştirme işlemi gelmektedir. Burada $\boldsymbol{\alpha}$ değerlerinin belirlenmesi tümleşik olabilirlik değerini, $\boldsymbol{\beta}$ ağırlıklarının integrasyon işlemi neticesinde maksimize ederek gerçekleştirilir. Bu integral ifadesi (4.51) ile gösterilmiştir:

$$p(\mathbf{t} | \boldsymbol{\alpha}, \mathbf{H}) = \int p(\mathbf{t} | \boldsymbol{\beta}, \mathbf{H}) p(\boldsymbol{\beta} | \boldsymbol{\alpha}) d\boldsymbol{\beta} \tag{4.51}$$

Bu öğrenme yordamında, sürecin merkezini teşkil eden nokta, $p(\mathbf{t} | \boldsymbol{\alpha}, \mathbf{H})$ dağılımını ortaya koyarak tümleşik olabilirlik değerini maksimize edip $\boldsymbol{\alpha}$ parametresini belirlemektir. Bununla birlikte eşitlik (4.51) ile verilen integralin çözümü çok da sade adımlar içermemektedir. Bu nedenle, ARD yöntemi ile Laplace yaklaşım yöntemiyle bir Gauss yakınsaması gerçekleştirilerek çözüm adımlarına devam edilir [56]. Gauss yakınsama işlemi sonrasında logaritmik-sonsal fonksiyona ait bir karesel Taylor açılımı elde edilir. Burada yakınsanan

Gauss dağılımının ortalama ve ortak varyans (kovaryans) değerleri sırasıyla, Laplace açılımının mod değeri ve negatifi alınan ikinci türev değerine (*Hessian matrisi*) karşılık gelir. Özetlenen bu ifadeler matematiksel olarak (4.52) ile gösterilmiştir [56]:

$$\begin{aligned} & \ln \{p(\mathbf{t}|\boldsymbol{\beta}, \mathbf{H})p(\boldsymbol{\beta}|\boldsymbol{\alpha})\} \\ &= \ln \left\{ \prod_{i=1}^N y_i^{t_i} (1 - y_i)^{1-t_i} \right\} + \ln \left\{ \prod_{k=0}^L \frac{\alpha_k}{\sqrt{2\pi}} \exp \left(-\frac{\alpha_k \beta_k^2}{2} \right) \right\} \\ &= \sum_{i=1}^N \{t_i \ln y_i + (1 - t_i) \ln (1 - y_i)\} - \frac{1}{2} \boldsymbol{\beta}' \mathbf{A} \boldsymbol{\beta} + \text{sbt} \end{aligned} \quad (4.52)$$

burada, $y_i = \sigma \{ \mathcal{Y}(\mathbf{h}_i; \boldsymbol{\beta}) \}$ ve $\mathbf{A} = \text{diag}(\boldsymbol{\alpha})$ olarak tanımlıdır. Sabit katsayı değeri için belirlenebilecek değer de $\text{sbt} = \sum_{k=0}^L (\ln \alpha_k - 1/2 \ln 2\pi)$ olarak $\boldsymbol{\beta}$ değerinden bağımsız olarak atanabilir. Genel olarak, Laplace açılımının mod değeri olan $\hat{\boldsymbol{\beta}}$ parametresini, Newton–Raphson döngüsel yinelenmiş ağırlıklı en küçük kareler (Iterative Reweighted Least Squares–IRLS) yöntemi ile elde etmek akılcı olur. Verilen (4.52) eşitliğinin gradyen değeri $\nabla \mathbf{E}$ ve Hessian matrisi Φ ortaya çıkarılmalıdır. Her iki ifade sırasıyla (4.53) ve (4.54) ile verilmiştir:

$$\nabla \mathbf{E} = \nabla_{\boldsymbol{\beta}} \ln \{p(\mathbf{t}|\boldsymbol{\beta}, \mathbf{H})p(\boldsymbol{\beta}|\boldsymbol{\alpha})\} = \sum_{i=1}^N (t_i - y_i) \mathbf{h}_i - \mathbf{A} \boldsymbol{\beta} = \mathbf{H}'(\mathbf{t} - \mathbf{y}) - \mathbf{A} \boldsymbol{\beta} \quad (4.53)$$

$$\Phi = \nabla_{\boldsymbol{\beta}} \nabla_{\boldsymbol{\beta}} \ln \{p(\mathbf{t}|\boldsymbol{\beta}, \mathbf{H})p(\boldsymbol{\beta}|\boldsymbol{\alpha})\} = -(\mathbf{H}' \mathbf{W} \mathbf{H} + \mathbf{A}) \quad (4.54)$$

burada, $\mathbf{y} = [y_1, \dots, y_N]'$ olarak tanımlıdır, $\mathbf{W}$ bir $N \times N$ köşegen matristir ve elemanı $W_i = y_i(1 - y_i)$ bileşenidir ve $d\sigma/d\mathcal{Y} = \sigma(1 - \sigma)$ ile belirtilmiştir. Bu nedenle, IRLS yöntemi kullanılarak $\hat{\boldsymbol{\beta}}$ değeri (4.55) ifadesinde gösterildiği gibidir:

$$\boldsymbol{\beta}_{\text{yeni}} = \boldsymbol{\beta}_{\text{eski}} - \Phi^{-1} \nabla \mathbf{E} = (\mathbf{H}' \mathbf{W} \mathbf{H} + \mathbf{A})^{-1} \mathbf{H}' \mathbf{W} \hat{\mathbf{t}} \quad (4.55)$$

burada, $\hat{\mathbf{t}} = \mathbf{H} \boldsymbol{\beta} + \mathbf{W}^{-1}(\mathbf{t} - \mathbf{y})$ olarak verilmiştir. Gauss dağılımının merkez değeri $\hat{\boldsymbol{\beta}}$ ve ortak varyans matrisi $\boldsymbol{\Sigma}$, $\boldsymbol{\beta}$ değerine bağlı Laplace yaklaşıklığı ile (4.56) ve (4.57) ifadelerinde gösterildiği şekildedir:

$$\hat{\boldsymbol{\beta}} = \boldsymbol{\Sigma} \mathbf{H}' \mathbf{W} \hat{\mathbf{t}} \quad (4.56)$$

$$\boldsymbol{\Sigma} = (\mathbf{H}' \mathbf{W} \mathbf{H} + \mathbf{A})^{-1} \quad (4.57)$$

Bu adımlardan sonra, $p(\mathbf{t}|\boldsymbol{\beta}, \mathbf{H})p(\boldsymbol{\beta}|\boldsymbol{\alpha}) \propto \mathcal{N}(\hat{\boldsymbol{\beta}}, \boldsymbol{\Sigma})$ ifadesi elde edilir. $\boldsymbol{\beta}$ için bu Gauss yaklaşımının ortaya çıkarılmasından sonra (4.51) integral işlemi artık daha sade bir hale kavuşmuştur. Burada, logaritmik tümleşik olabilirlik ifadesi artık (4.58) ile gösterilen şekliyle yazılabilir:

$$\begin{aligned}\mathcal{L}(\boldsymbol{\alpha}) &= \ln p(\mathbf{t}|\boldsymbol{\alpha}, \mathbf{H}) \\ &= -\frac{1}{2} \left[N \ln(2\pi) + \ln |\mathbf{W} + \mathbf{H}\mathbf{A}\mathbf{H}'| + (\hat{\mathbf{t}})' (\mathbf{W} + \mathbf{H}\mathbf{A}\mathbf{H}')^{-1} \hat{\mathbf{t}} \right] \\ &= -\frac{1}{2} \left[N \ln(2\pi) + \ln |\mathbf{C}| + (\hat{\mathbf{t}})' \mathbf{C}^{-1} \hat{\mathbf{t}} \right]\end{aligned}\quad (4.58)$$

burada, $\mathbf{C} = \mathbf{W} + \mathbf{H}\mathbf{A}\mathbf{H}'$ olarak tanımlanmıştır. Şimdi $\mathcal{L}(\boldsymbol{\alpha})$ açılımının diferansiyel ifadesini α değerini *sıfıra* götürecek şekilde yazarsak (4.59) elde edilmiş olur [56]:

$$\begin{aligned}\frac{\partial \mathcal{L}(\boldsymbol{\alpha})}{\partial \alpha_k} &= \frac{1}{2\alpha_k} - \frac{1}{2} \Sigma_{kk} - \frac{1}{2} \hat{\beta}_k^2 = 0 \\ \Rightarrow \alpha_k^{\text{yeni}} &= \frac{1 - \alpha_k \Sigma_{kk}}{\hat{\beta}_k^2}\end{aligned}\quad (4.59)$$

Buraya kadar takip edilen adımlar sonrasında, β_k ve α_k parametrelerinin başlangıç değerleri olan $\hat{\boldsymbol{\beta}}$ ve $\boldsymbol{\Sigma}$ değerleri (4.56) ve (4.57) ile güncellenir. Bu iki değeri kullanarak $\boldsymbol{\alpha}$ parametresi (4.59) ifadesine dek yeniden güncellenir. Bu süreç, tümleşik olabilirlik fonksiyonu maksimize edilene dek devam eder. Son olarak olasılık dağılımı $p(t_{\text{yeni}}|\mathbf{x}_{\text{yeni}}, \hat{\boldsymbol{\beta}})$ ifadesi (4.48) kullanılarak tahmin edilir [56].

Bayesçi çıkarıma seyreklik özelliğinin katılması

Daha önce bilgisi verilen ARD önsel parametre tarama yöntemi, çıkış ağırlıklarının bir kısmının değerini *sıfır* olarak belirleyip bağlı oldukları gizli katman nöronlarını budama işlemi gerçekleştirir. Burada özetlenecek adımlarda, seyrekliği gerçekleştirme yoluna değinilecektir. (4.58) ifadesinde tanımlı olan $\mathbf{C}$ parametresi α_k terimine bağlı olarak ayrıştırılırsa, $\mathcal{L}(\boldsymbol{\alpha})$

(4.60) ile gösterildiği şekilde yeniden yazılır:

$$\begin{aligned}
\mathcal{L}(\alpha) &= -\frac{1}{2} \left[N \ln(2\pi) + \ln |\mathbf{C}_{-k}| + (\hat{\mathbf{t}})' \mathbf{C}_{-k}^{-1} \hat{\mathbf{t}} \right. \\
&\quad \left. - \ln \alpha_k + \ln \left(\alpha_k + \mathbf{h}_k' \mathbf{C}_{-k}^{-1} \mathbf{h}_k \right) - \frac{(\mathbf{h}_k' \mathbf{C}_{-k}^{-1} \hat{\mathbf{t}})^2}{\alpha_k + \mathbf{h}_k' \mathbf{C}_{-k}^{-1} \mathbf{h}_k} \right] \\
&= \mathcal{L}(\alpha_{-k}) + \frac{1}{2} \left[\ln \alpha_k - \ln(\alpha_k + s_k) + \frac{q_k^2}{\alpha_k + s_k} \right]
\end{aligned} \tag{4.60}$$

burada, $s_k = \mathbf{h}_k' \mathbf{C}_{-k}^{-1} \mathbf{h}_k$ olarak, $q_k = \mathbf{h}_k' \mathbf{C}_{-k}^{-1} \hat{\mathbf{t}}$ olarak tanımlıdır ve $\mathbf{h}_k$ ise $\mathbf{H}$ matrisin k . sütunu temsil eder. $\mathcal{L}(\alpha_{-k})$ ifadesi, α_k parametresinin dahil edilmediği tümleşik olabilirliktir. $\mathbf{C}_{-k}$ ifadesi ise $\mathbf{h}_k$ ve α_k parametrelerinin dahil edilmediği $\mathbf{C}$ matrisini temsil eder. Böylece $\mathcal{L}(\alpha_{-k})$, α_k ile ilgisizdir. $\mathcal{L}(\alpha)$ ifadesinin türevini α_k parametresini sıfıra götürecek şekilde yeniden düzenleyerek, durağan (kararlı) nokta şu şartlar altında elde edilmiş olur:

$$\hat{\alpha}_k = \begin{cases} \frac{s_k^2}{q_k^2 - s_k} & \text{eğer } q_k^2 > s_k \\ \infty & \text{eğer } q_k^2 \leq s_k \end{cases}$$

Tümleşik olabilirlik ifadesini maksimize etmek için α döngüsel işleminin gerçekleştirildiği süreçte, bazı α_k değerlerinin sonsuza gitme eğiliminde olduğu görülür. Bu durum ortalama değer $\hat{\beta}$ ve ortak varyans Σ değerlerini (4.61) ve (4.62) ile gösterildiği şekilde etkiler [56]:

$$\lim_{\alpha_k \rightarrow \infty} \Sigma_{kk} = \lim_{\alpha_k \rightarrow \infty} \left\{ \mathbf{h}_k' \mathbf{W}_i \mathbf{h}_k + \alpha_k \right\}^{-1} = 0 \tag{4.61}$$

$$\lim_{\alpha_k \rightarrow \infty} \hat{\beta}_k = \lim_{\alpha_k \rightarrow \infty} \left\{ \boldsymbol{\varepsilon}_k \mathbf{h}_k' \mathbf{W}_i \hat{\mathbf{t}}_i \right\} = 0 \tag{4.62}$$

burada, $\boldsymbol{\varepsilon}_k$ parametresi Σ matrisinin k . satırını temsil eder. (4.61) ve (4.62) limit değerleri $\beta_k \sim \mathcal{N}(0,0)$ benzerliğinin sıfıra eşit olduğunu gösterir. Bu nedenle karşılık gelen $h_k(\boldsymbol{\theta}_k; \mathbf{x})$ değerleri budanırken, $p(\mathbf{t}|\alpha, \mathbf{H})$ olabilirlik ifadesini en iyi şekilde maksimize eden değerler kalır ve böylece seyrekleştirme sağlanmış olur [56]. SB-ELM yapısına ait matematiksel anlatım her ne kadar işlemsel olarak karmaşık yapıda görünse de, ortaya koyduğu avantajlar neticesinde, SB-ELM ile eğitilmiş bir modelin seyrekleştirme işlemi ile çok daha az sayıda gizli katman nöronu içermesi hesapsal maliyeti olumlu anlamda etkilemektedir.

4.2.3. Ağırlıklandırılmış Uç Öğrenme Makinesi (W-ELM)

W-ELM yapısı, eğitim setinde dengesiz sınıf dağılımı içeriği ile ortaya çıkan ve dengesiz öğrenme (*imbalance-learning*) olarak adlandırılan soruna bir çözüm olarak ortaya atılmış ELM geliştirmesidir. Bununla beraber, dengeli öğrenme yapılarında da kullanılmaktadır.

W-ELM yönteminde, temel ELM yapısına göre artı değer ifade eden özellik, öğrenme aşamasında sınıflara ek bir ağırlıklandırma işlemi uygulanmasıdır yani her bir eğitim örneğine fazladan birer ağırlık ataması gerçekleştirilir. Teorik olarak, her eğitim örneği ($\mathbf{x}_i$) değerine, $N \times N$ boyutlu $\mathbf{W}$ köşegen ağırlık matrisi atanmaktadır. Ağırlıklandırma süreci, azınlık sınıfı teşkil eden örneklerin öğrenmedeki negatifliğini yenmek adına, bu sınıflara daha büyük değerli bir ağırlık ataması gerçekleştirirken, çoğunluk sınıf için bunun tam tersini uygular. Bu yaklaşım, W-ELM yapısının başarımını geleneksel mimariye göre üstün kıldığı gibi uyarlanabilir ağırlık karakteristiği ile hesapsal maliyeti de azaltır. W-ELM, tasarım olarak çoklu sınıflandırma uygulamalarına, temel ELM yapısına göre daha kolay adapte edilebilmekle birlikte daha düzenli ve uygun bir özellik haritalama ortaya koyar. Burada W-ELM yöntemine ait genel bilgiler verilecektir. Daha kapsamlı bilgiler [55, 113] kaynaklarından elde edilebilir.

Temel ELM yöntemindeki amacın (4.63) ifadesindeki bileşenleri minimize etmek olduğu belirtilmiştir.

$$\text{Amaç (Minimize)} \quad \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\|^2 \quad \text{ve} \quad \|\boldsymbol{\beta}\| \quad (4.63)$$

Bu çözümün optimizasyon bakış açısı ile ele alındığı ifadeye, belirlenen ek ağırlık matrisi $\mathbf{W}_a$ eklenip yeniden düzenlenirse, (4.64) ile verilen ifade elde edilir:

$$\text{Amaç (Minimize)} \quad L_{PELM} = \frac{1}{2}\|\boldsymbol{\beta}\|^2 + C\mathbf{W}_a \frac{1}{2} \sum_{i=1}^N \|\boldsymbol{\xi}_i\|^2 \quad (4.64)$$

$$\text{Kısıtlar (Subject to)} \quad \mathbf{h}(\mathbf{x}_i)\boldsymbol{\beta} = \mathbf{t}_i^T - \boldsymbol{\xi}_i^T, \quad i = 1, \dots, N$$

burada, $\boldsymbol{\xi}_i = [\xi_{i,1}, \dots, \xi_{i,m}]$ vektörü, her $\mathbf{x}_i$ eğitim veri örneği için m çıkış düğümlerine ait hata değeridir. $\mathbf{h}(\mathbf{x}_i)$ ifadesi gizli katmandaki özellik haritalamayı $\mathbf{x}_i$ ve $\boldsymbol{\beta}$ parametrelerine bağlı olarak oluşturur. (4.64) ifadesinin çözümü KKT teoremi kullanarak, N eğitim örnek sayılı ve gizli katmanında L adet nöron bulunan bir yapı için (4.65) ile şu şekilde belirtilir [113]:

$$\boldsymbol{\beta} = \mathbf{H}^L \mathbf{T} = \begin{cases} \mathbf{H}^T \left(\frac{\mathbf{I}}{C} + \mathbf{W}\mathbf{H}\mathbf{H}^T \right)^{-1} \mathbf{W}\mathbf{T} & N < L \text{ olması durumunda} \\ \left(\frac{\mathbf{I}}{C} + \mathbf{H}^T \mathbf{W}\mathbf{H} \right)^{-1} \mathbf{W}\mathbf{H}^T \mathbf{T} & N \geq L \text{ olması durumunda} \end{cases} \quad (4.65)$$

Yapıya eklenen $\mathbf{W}_a$ köşegen ağırlık matrisinin belirlenmesi, W-ELM yapısında önemli bir rol oynar. Bu çalışmada [55] çalışmasındaki ağırlıklandırma şeması kullanılmıştır. Bu yönelimde, ağırlık değerleri azınlık ve çoğunluk sınıflardaki örnek sayılarına göre otomatik olarak belirlenir. (4.66) ifadesi ile bu durum şu şekilde belirtilir:

$$\mathbf{W}_{a(\text{azınlık})} = \frac{1}{\#(t_i^-)} \quad \text{ve} \quad \mathbf{W}_{a(\text{çoğunluk})} = \frac{1}{\#(t_i^+)} \quad (4.66)$$

Burada ikili sınıflandırma için düşünülürse $\#(t_i^-)$ azınlık sınıftaki örnek sayısını, $\#(t_i^+)$ ise çoğunluk sınıftaki örnek sayısını temsil etmektedir. Çoklu sınıflandırma işleminde azınlık sınıf ifadesi, her sınıftaki ortalama örnek sayısının altında örnek içeren sınıf olarak tanımlanır. Bu sayının üzerinde örnek içeren sınıf ise çoğunluk sınıf olarak işlem görür ve o değere göre ağırlıklandırılır. Matematiksel anlatımı özetleyen algoritma adımlarına Şekil 4.23 ile ulaşılabilir. Daha detaylı açıklamalar [55, 113] çalışmalarından sağlanabilir.

Giriş:

1: Eğitim veri seti $\mathfrak{N} = \{(\mathbf{x}_i, \mathbf{t}_i), \mathbf{x}_i \in \mathcal{R}^n, \mathbf{t}_i \in \mathcal{R}^m, i = 1, 2, \dots, N\}$.

Çıkış:

2: ELM Çıkış Ağırlıkları: $\mathbf{T} = \mathbf{H}\boldsymbol{\beta}$ ile $\boldsymbol{\beta}$ hesabı.

Başlangıç :

- 3: Giriş ağırlıkları ve eşik değerlerinin rastlantısal olarak belirlenmesi.
 - 4: **for** $t = 1, 2, \dots, T$. **do**
 - 5: Azınlık ve çoğunluk sınıf sayılarının ek ağırlık değerleri için hesapla,
 - 6: Köşegen ek ağırlık matrisi $\mathbf{W}_i \quad i = 1, \dots, N$ hesapla,
 - 7: $\mathbf{H}$ matris hesapla,
 - 8: Çıkış ağırlıklarını (4.65) ile hesapla,
 - 9: **end for**
-

Test :

Sınıf etiketi belirli olmayan bir $\mathbf{x}$ örneğini (4.46) ile tahmin et.

Şekil 4.23: Önerilen W-ELM yöntemine ait algoritma adımları

Bu bölüm boyunca, tez çalışmasında güç kalitesi olayları sınıflandırma işlemi için önerilen akıllı örüntü tanıma sistemine ait metodoloji hakkında bilgiler verilmiştir. Tezin metodolojisi genel çerçeve olarak, iki ana başlıkta incelenmiştir: 1) Öznitelik Çıkarımı ve 2)

Akıllı Sınıflandırıcı Yapıları. Makine öğrenme tabanlı sınıflandırma uygulamalarında, işlenecek ham veri seti karar aşamasında kullanılacak yeterli bilgiye sahip değildir. Bu durum mümkün olsa dahi, veri setinin hacmi ve içeriği sınıflandırıcı yapısının işlem yükünü aşabilir ya da kullanılan donanımsal cihazın hafıza değerleri dışında kalabilir. Bu nedenle, işaret işleme alanında ortaya atılan istatistiksel, zaman–frekans alanı dönüşümleri, zaman–ölçek dönüşümleri, model tabanlı ve yine filtreleme ve dönüşüme dayalı diğer yöntemler toplu ya da tek tek kullanılarak, ham veriden anlamlı bilgiler elde edilir. Böylece hem öznitelik uzayında anlamlı bir dağılım elde edilmiş olur hem de boyut azalımı ile hesapsal işlem maliyetleri de en aza indirgenmiş olur. Bu tez çalışmasında, güç kalitesi olay sınıflandırması alanında kabul görmüş ve geleneksel yöntemler arasına girmiş **DWT–MRA** yöntemine ait özniteliklerin ve **temel istatistik** hesaplamalarından elde edilen özniteliklerin yanı sıra, bu alana kazandırılan ve güç kalitesi olay sınıflandırma işlemi için uyarlanan **Histogram, Permütasyon Entropi, Yerel Tepe Noktaları ve Anlık Zaman Bölgesi** özniteliklerini de kullanarak zengin bir öznitelik vektörü elde edilmiştir. Başarıma katkı sağlaması açısından, elde edilen öznitelik setlerine **Fisher Vektör kodlama** uygulanarak, sınıflandırıcı için daha doğrusal bir veri dağılımı oluşturmak amaçlanmıştır.

Bölümün ikinci kısmında, tez çalışmasında kullanılan makine öğrenme tabanlı sınıflandırıcı yapılarına ait yöntem altyapıları özetlenmiştir. Bu tez çalışmasında kullanılan ve detaylı olarak analizleri gerçekleştirilip bulguların elde edildiği üç ana sınıflandırıcı yapısı; Uç Öğrenme makinesi (**ELM**) ve bu yapının geliştirilmiş sürümleri olan, Seyrek Bayes Uç Öğrenme Makinesi (**SB–ELM**) ve Ağırlıklandırılmış Uç Öğrenme Makinesi (**W–ELM**) yöntemleri olarak sıralanmıştır. Önerilen yöntemlerin, güç kalitesi olay incelemeleri ile makine öğrenme alanları arasına köprü oluşturacak şekilde kullanılmasıyla, alana sağladığı altyapı katkısı da çalışma boyunca göz önünde tutulmuş ve değerlendirilmiştir. Temel yapının dezavantajlarını giderecek yönde geliştirilmiş SB–ELM ve W–ELM yapısının güç kalitesi olayları sınıflandırma işlemine uyarlandığı yöntem detaylarına bölümde genişçe yer verilmiştir.

5. BULGULAR ve İNCELEME

Bu tez çalışmasında, Türkiye iletim hatlarından elde edilmiş güç kalitesi olaylarından oluşan gerçek veri setinin incelemesi ve sınıflandırılması gerçekleştirilmiştir. Önerilen sistemin akışı boyunca sırasıyla gerçekleşen: Verilerin ön işleme süreci, ham verilerden öz-niteliklerin elde edilmesi ve karar aşamasında akıllı sınıflandırıcı yapısının olay işaretlerini tespit etmesi basamaklarından elde edilen bulgular, bu bölüm boyunca detaylı olarak sunulacaktır. Bulguların elde edilme sürecinde tezde önerilen makine öğrenme tabanlı temel sınıflandırıcı yapısı olan ELM yönteminden başlayarak, W-ELM ve SB-ELM akıllı sınıflandırıcı yapılarına ait sonuçlar kullanılmıştır. Bölümün ilk alt başlığında, daha önce tanımlanan öz-nitelik çıkarım metodolojisinden elde edilmiş bulgulara yer verilecektir. Önerilen her yöntemle ait öz-nitelik seti detaylı olarak sunulacaktır. Bölüm sonunda, akıllı sınıflandırıcı çıkışlarından elde edilen güç kalitesi olay belirleme bulguları verilmeden önce, kullanılan değerlendirme ölçütleri ve kriterler hakkında da özet bilgiler sunulacaktır. Tablo 5.1, çalışma kapsamında oluşturulmuş gerçek veri setinden seçilmiş, bulguların elde edilmesi ve incelemeler için tasarlanmış olan “*uygulama veri seti*” hakkında içerik ve sayı bilgisi sunmaktadır. Bölüm sonuna kadar, veri setindeki olay sınıfları burada verilen notasyona uygun şekilde kullanılacaktır.

Tablo 5.1: Olay Türleri ve Sınıf Kodları

Olay Türü	Sınıf Kodu	Veri Sayısı
Normal Sinüs	OS_1	300
Çukur	OS_2	300
Tepe	OS_3	300
Kesinti	OS_4	300
Harmonik	OS_5	300
Toplam		1500

5.1. Güç Kalitesi Olaylarına ait Öz-niteliklerin Analizi

Bu kısımda, tez çalışmasında kullanılan ve Bölüm 4.1 ile matematiksel özellikleri verilen öz-nitelik çıkarım yöntemlerine ait görsel ve sayısal veriler, öz-niteliklerin etiket bilgileri, kodlanmış kısaltmaları ve oluşan öz-nitelik setinin son durumda aldığı bütüncül yapısı sunulacaktır. Burada, tez çalışmasında kullanılan ve önerilen yöntemlere ait öz-nitelik bulguları

ayrıntılı olarak incelenecektir. Bu grafiksel ve sayısal gösterimlerle birlikte önerilen tüm öz-nitelik alt setlerine ait detaylı bilgiler tablolar halinde sunulacaktır.

Tablolarda verilecek olan işlem süreleri, tez çalışmasında kullanılan ve eşit sayıdaki 5 farklı sınıf etiketi ile toplamda 1.500 veriden oluşan gerçek güç kalitesi olaylarına ait zaman değerleridir. Tanım olarak, **toplam işlem süresi**, 1.500 adet olayın tümünün ilgili öz-nitelik çıkarım yöntemi ile işlendiği süreyi ve **tek olay ortalama işlem süresi** de toplam sürenin olay başına düşen ortalama değerini *saniye* (s) ve *mili saniye* (ms) birimi ile ifade etmektedir.


5.1.1. Ayrık Dalgacık Öz-nitelik Seti

Tablo 5.2 ile DWT–MRA tabanlı öz-nitelik alt setine ait bilgiler verilmiştir. 8 seviye olarak ayrıştırılan olay işaretlerinden toplamda 18 adet öz-nitelik elde edilmiştir. DWT–MRA yönteminden elde edilen detay vektörlerine, delta standart sapma (D) ölçütü, Entropi (E) ölçütü ve Enerji (Energy ve Engyuzde) ölçütleri uygulanarak ilgili öz-nitelik seti elde edilmiştir. Burada *engyuzde* ile etiketlenmiş öz-nitelik, yaklaşım işaretine ait enerji yüzdelik değeridir. Tüm olaylara ait toplam işlem süresine bakıldığında, yaklaşık olarak 24s değeri ile karşılaşmaktayız. Bu durum, DWT yönteminin filtreleme yapısından ve dönüşüm tabanlı bir yöntem olarak karşımıza çıkmasından kaynaklıdır.

Tablo 5.2: DWT–MRA tabanlı öz-nitelik alt seti


DWT MRA TABANLI ÖZNİTELİKLER		
Etiket	Tanım	Adet
D	STD	8
E	Entropi	8
Energy	Ortalama Enerji	1
Engyuzde	Yaklaşımın Enerjisi	1
Toplam sayı		18
Toplam işlem süresi (s)		23,659
Tek olay ortalama işlem süresi (s)		0,016

Takip eden grafiklerde, “db4” dalgacık fonksiyonu kullanılarak, 8 seviye olarak ayrıştırılmış DWT–MRA detay ve yaklaşım vektörlerine ait gösterimlere yer verilmiştir. Gösterimler öncesinde, DWT–MRA ayrıştırması yapılan örneğe ait dalga şekli verilmiştir. Grafiklerde, $d_1, \dots, d_8$ detay vektörlerini, a_8 yaklaşım vektörünü ve s ise orijinal işareti temsil etmektedir.




Şekil 5.1: DWT–MRA için örnek işaret: Normal sinüs

Şekil 5.1 ile DWT–MRA ayrıştırması gerçekleştirilmiş bir saf sinüs dalga şekli gösterilmiştir. Normal çalışma durumunu gösteren bu dalga şekline ait ayrıştırma detayları, Şekil 5.2 ile gösterilmiştir. Burada herhangi bir olay gerçekleşmediği için yüksek ya da düşük frekans bileşenlerinde herhangi bir belirgin değişme göze çarpmamaktadır.




Şekil 5.2: DWT–MRA normal sinüs detaylar




Şekil 5.3: DWT–MRA için örnek işaret: Çukur

Şekil 5.3 ile analizi gerçekleştirilen örnek bir çukur olayı verilmiştir. Bu olay işaretine, DWT–MRA uygulanması sonucu elde edilen detaylar Şekil 5.4 ile gösterilmiştir. Çukur olayının başlangıcı $d_1 - d_5$ arası yüksek frekanslı bileşenlerde açıkça görülmektedir. Burada olayın düzeldiği anın örnek sayısının yaklaşık 3.500 değerinde olduğu ana denk geldiği de tespit edilebilmektedir.




Şekil 5.4: DWT–MRA çukur olayı detaylar




Şekil 5.5: DWT–MRA için örnek işaret: Tepe

Burada incelenen olay, Şekil 5.5 ile dalga şekli verilen tepe olayıdır. Şekil 5.6 ile verilen DWT–MRA detaylarından incelenebileceği üzere yine olayın başladığı andaki, özellikle $d_3 - d_5$ arası detayların değişimleri karakteristik yapıdadır. Bu değişimler, bir yönüyle çukur olayını çağrıştırıyor olsa da, genlik değerlerinden dolayı ayırt edicilik oluşmaktadır.




Şekil 5.6: DWT–MRA tepe olayı detaylar




Şekil 5.7: DWT-MRA için örnek işaret: Kesinti

Analizi gerçekleştirilen kesinti olayına ait dalga şekli, Şekil 5.7 ile verilmiştir. Şekil 5.8 incelediğinde DWT-MRA katsayılarındaki değişimler, kesicinin açtığı, sistemin enerjisiz kaldığı noktayı açık bir şekilde göstermektedir.




Şekil 5.8: DWT-MRA kesinti olayı detaylar



Şekil 5.9: DWT–MRA için örnek işaret: Harmonik


Veri setinde bulunan olay sınıflarından sonuncusu, harmonik bozulmaları içermektedir. Şekil 5.9, analizi gerçekleştirilen dalga şeklini göstermektedir. Şekil 5.10 ile gösterilen DWT–MRA detaylarında, harmonik belirtilerin d_6 ve d_7 basamaklarında görüldüğü söylenebilir. Sırasıyla 450 – 250Hz bant değerlerine karşılık gelen bu detaylar ülkemizde özellikle yaz aylarında iletim kademesine dek yansıyan 5. ve 7. harmoniklere işaret etmektedir.



Şekil 5.10: DWT–MRA harmonik olayı detaylar

Buraya kadar verilen analizlerde, olay işaretlerine uygulanan DWT–MRA işlemine ait ham verilerin grafiksel gösterimleri verilmiştir. DWT–MRA öznitelik setinin analizine, detay vektörlerine uygulanan delta standart sapma, entropi ve enerji ölçütleri sonrası elde edilen öznitelikler ile devam edilecektir.


Detay vektörlerinin boyutunun azaltılarak, anlamlı özniteliklerin elde edilmesi adına kullanılan ilk adım D_{STD} yöntemi ile atılmıştır. Şekil 5.11 ile tüm D_{STD} özniteliklerinin sınıflara göre dağılımı gösterilmiştir. Grafikteki dikey belirteç çizgileri, her 300 adımda bir belirlenerek, sınıfların ayrımını ortaya koymaktadır. Özellikle ilk iki sınıf, yani saf sinüs ve çukur olaylarında $D1 - D5$ detaylarının ayırt ediciliği sorgulanır nitelikte olsa da [90] çalışması ile sunulan analizlerde, başarıma olan etkileri ölçülmüş ve pozitif katkı sağladıkları görülmüştür.




Şekil 5.11: DWT–MRA delta standart sapma öznitelikleri

Şekil 5.11 ile verilen grafikler incelendiğinde, $OS_3 - OS_5$ arası olay sınıflarına ait D_{STD} özniteliklerinin, dağılımda önemli ölçüde ayırt ediciliğe sahip olduğu görülmektedir.

Şekil 5.12 ile gösterilen grafiklerde, DWT–MRA detaylarına Entropi ölçütü uygulanması ile elde edilen özniteliklerin olay sınıflarına göre dağılımları verilmiştir. Buradan da görülebileceği üzere, sınıf içi öznitelik dağılımları homojen özellikte olsa da sınıflar arası dağılımlarda ayırt edici bir karakteristik ortaya konulmaktadır.




Şekil 5.12: DWT-MRA Entropi öznelikleri



Şekil 5.13: DWT-MRA Enerji öznelikleri

Şekil 5.13, detayların ortalama enerji değerlerinin hesaplanması ile elde edilen öznelikleri göstermektedir. Sınıflara göre çizilmiş bu dağılım grafiğinde, enerji özneliklerinin her sınıf için ayırt edici yapıda olduğu açık bir şekilde görülmektedir.



Şekil 5.14: DWT–MRA Yaklaşım işareti enerjisine ait öznitelikleri

Şekil 5.14, yaklaşım işaretine ait enerji yüzde değerlerini göstermektedir. Sınıf bazında dağılım incelendiğinde, bu öznitelik setinin sınıflara göre karakteristik olarak ayrıldığı görülmektedir. Kesinti ve harmonik sınıflarının yaklaşım enerjileri incelendiğinde birbirine yakın değerlerde olduğu görülmektedir.

5.1.2. Temel İstatistik Parametreleri Öznitelik Seti

Tablo 5.3 ile temel istatistik parametrelerinden faydalanarak oluşturulan alt öznitelik setine ait ayrıntılı bilgiler verilmiştir. Burada ham işarete, herhangi bir dönüşüm uygulanmadan doğrudan tablodaki istatistik tanımları uygulanmıştır. Bu yöntem sonucunda elde edilen öznitelik seti, 9 elemandan oluşmaktadır.


Burada dönüşüm tabanlı bir yöntem uygulanmadan, sadece istatistiksel hesaplar yapıldığı için, işlem süreleri DWT yöntemine göre daha küçük değerlerde kalmıştır. Temel yapıdaki istatistiksel hesaplamaların yanı sıra, çarpıklık ve basıklık yüksek dereceli moment değerleri de istatistik öznitelik setine eklenmiştir.

Veri dağılımı için de daha net bilgi vermesi açısından, istatistik tabanlı özniteliklerin gösteriminde, serinin son iki elemanına ait grafikler tercih edilmiştir. İstatistik öznitelik setinin 8. elemanı çarpıklık ve 9. elemanı ise basıklık öznitelikleridir.


Tablo 5.3: İstatistik tabanlı öznitelik alt seti

TEMEL İSTATİSTİK TABANLI ÖZNİTELİKLER (Ist)		
Etiket	Tanım	Adet
RMS	Etkin değer	1
min, maks	Minimum, Maksimum	2
mean	Ortalama	1
median	Ortanca	1
mode	Mod	1
std	Standart sapma	1
skw	Çarpıklık	1
kurt	Basıklık	1
Toplam sayı		9
Toplam işlem süresi (s)		2,077
Tek olay ortalama işlem süresi (ms)		1,385

Şekil 5.15, çarpıklık ifadesine ait öznitelik dağılımını göstermektedir. Görülebileceği üzere, saf sinüs yani normal şartları ifade eden sınıf dağılımındaki düzgünlük net bir şekilde görülmektedir. Gürültüler neticesinde arada bozucu etkilerin bulunduğu görülmektedir. Özellikle tepe, kesinti ve harmonik sınıflarında yükselen değerlerde çarpıklık görülmektedir. Bu farklılık da ilgili öznitelik seti için olumlu bir karakteristik oluşturmaktadır.



Şekil 5.15: İstatistik-8: Çarpıklık öznitelikleri



Şekil 5.16: İstatistik-9: Basıklık öznitelikleri


Şekil 5.16 ile istatistik tabanlı öznitelik setinin son elemanı olan, basıklık özniteliğine ait dağılım gösterilmiştir. Grafikteki dağılım sınıf bazında incelendiğinde, basıklık ölçütünün sınıflar arası önemli ayırt edicilik ortaya koyduğu söylenebilir. Göze çarpan bir diğer nokta, çukur ve tepe sınıflarının basıklık değerlerinin benzer değerlerde değişim gösteriyor olmasıdır.

5.1.3. Histogram Öznitelik Seti

Tablo 5.4, Histogram yönteminden elde edilen özniteliklere ait bilgileri göstermektedir. Histogram adımları 13 olarak belirlendiği için bu öznitelik seti de aynı sayıda elemandan oluşmaktadır. Burada, Histogram yönteminin işlem süreleri dikkate alındığında toplam işlem süresi ve ortalama olay işlem süresinde, diğer yöntemlere göre ciddi oranda azalma olduğu da gözlemlenmektedir.

Tablo 5.4: Histogram öznitelik alt seti

HİSTOGRAM TABANLI ÖZNİTELİKLER		
Etiket	Tanım	Adet
Hist	Histogram (13 aralıklı)	13
Toplam sayı		13
Toplam işlem süresi (s)		0,288
Tek olay ortalama işlem süresi (ms)		0,192



Şekil 5.17: Histogram öznitelikleri

Şekil 5.17, gerçek veri setinden seçilmiş olay örneklerine ait histogram öznitelik değerlerinin grafiksel gösterimini sunmaktadır. Grafiklerin yorumunda, x ekseninin öznitelik sayısına ve y ekseninin histogram değerlerine ait olduğu göz önüne alınmalıdır. Yani yatay eksen, histogram işleminde veri değerleri sayılırken kullanılan $[-\text{genlik}_{\text{tepe}}, +\text{genlik}_{\text{tepe}}]$ aralığındaki 13 adımı (öznitelik sayısını) ifade etmektedir. Düşey eksen ise bu adımlardaki genlik değerine sahip olan örneklerin toplam sayısını göstermektedir.

1 – 13 arası özniteliklerin minimum değerden maksimum değere yaklaşık olarak $[-1, +1]$ arası olduğu göz önüne alındığında, kesinti olayına ait grafikte 7. öznitelik değerine denk gelen genliğin *sıfır* noktası olduğu net bir şekilde anlaşılmaktadır. Kesinti olaylarında, sistem enerjisiz kaldığı için genliğin *sıfır* olduğu değerler çoğunluktadır. Olay genlikleri, sınıflar arası önemli ölçüde farklar içerdiğinden, histogram özniteliklerinin ayırt edicilik özellikleri de buna paralel olarak oluşmuştur.


5.1.4. Permütasyon Entropi Öznitelik seti

Tablo 5.5, Permütasyon Entropi (PE) ve Yerel Tepe Nokta Sayıları (Local Peaks–LP) özelliklerine ilişkin bilgileri sunmaktadır. İşlem kolaylığı açısından PE ve LP yöntemlerine ait öznitelik setleri birlikte ele alınarak analiz edilmiştir. Burada PE öznitelikleri, PE ve PE_{Hist} olarak iki farklı türdedir. PE, olay işaretlerine ait Permütasyon Entropi değerlerine işaret ederken, ikinci değer olan histogram ise PE hesabında kullanılan dağılım değerinin histogramını temel almıştır. Burada 6 adımlı dağılım kullanıldığı için adım sayısı ile aynı değerde öznitelik üretilmiştir. LP özniteliğinden her olay için birer adet üretilmiştir. Her olayda bulunan yerel tepe nokta sayısını sunan bu ifade, hesap hızı bakımından son derece verimli olmakla birlikte, burada işlem süresinin uzun olmasının ana kaynağı PE tabanlı özniteliklerle birlikte ele alınıyor olmasıdır. Bu sette toplamda 8 adet öznitelik bulunmaktadır.

Tablo 5.5: Permütasyon Entropi ve Yerel Tepe öznitelikleri alt seti


PE ve LP TABANLI ÖZNİTELİKLER		
Etiket	Tanım	Adet
PE	Permütasyon Entropi	1
PE_{Hist}	PE Histogram Dağılımı	6
LP	Yerel Tepe Sayısı	1
Toplam sayı		8
Toplam işlem süresi (s)		34,545
Tek olay ortalama işlem süresi (s)		0,023

Şekil 5.18 ile gösterilen dağılım, sınıf bazında PE özniteliklerine aittir. Yüksek PE değeri işaretin bozulma oranının arttığını ifade etmektedir. Burada, sınıf dağılımları incelendiğinde sınıf içi genel dağılımı bozan bazı örnekler görülmektedir. Grafikten görülebileceği üzere, çukur ve tepe sınıflarına dahil olan böylesi iki örnek mercek altına alınmıştır. Genel dağılımda sivrilen bu değerlerin, ham dalga şekilleri grafikte ayrıca gösterilmiştir. Şekil 5.18 ile verilen detaylardan görülebileceği üzere ilgili özniteliklerin kaynağı olan dalga şekillerinde bozulmalar mevcuttur, tepe işareti aynı zamanda harmonik bozulmaya da maruz kalmıştır.



Şekil 5.18: Permütasyon Entropi öznitelikleri

Şekil 5.19 ile verilen grafiksel gösterimde, LP özniteliklerine ait dağılım sunulmaktadır. Tepe noktası kavramının tanımına göre, bir noktanın bu kapsama girmesi için kendinden önceki ve sonraki örnek değerlerinden genlik olarak büyük değerde olması gerekmektedir. Burada saf sinüs ve çukur sınıflarında daha düzgün dağılımlar elde edilmişken, tepe, kesinti ve harmonik sınıflarında tepe noktalarının değişken ve daha çok sayıda olduğu gözle çarpmaktadır.



Şekil 5.19: Yerel tepe noktaları öznitelikleri


5.1.5. Anlık Zaman Bölgesi Öznitelik Seti

Tablo 5.6 ile anlık zaman bölgesi (ITD) özniteliklerine ait bilgiler verilmiştir. Burada Hilbert dönüşümü tabanlı 3 adet (HB_1, HB_2, HB_3) öznitelik, alt sete dahil edilmiştir. Öznitelik seti oluşumunda, toplam işlem süresinin DWT–MRA ve PE yöntemlerine göre daha alt değerde olduğu görülmektedir.

Tablo 5.6: Anlık Zaman Bölgesi öznitelik alt seti

ANLIK ZAMAN BÖLGESİ TABANLI ÖZNİTELİKLER		
Etiket	Tanım	Adet
$HB_{1,2,3}$	Hilbert Tabanlı - Zaman Bölgesi	3
Toplam sayı		3
Toplam işlem süresi (s)		5,951
Tek olay ortalama işlem süresi (s)		0,004

Şekil 5.20, anlık zaman bölgesi tabanlı öznitelik setine ait dağılım grafiklerini göstermektedir. Tüm sınıflara göre dağılım incelendiğinde, her üç öznitelik de sınıflar arası ayırt ediciliğe sahiptir. Burada HB_2 özniteliği, saf sinüs ve çukur sınıflarında benzer dağılım gösteriyor olsa da genlik farkları mevcuttur.




Şekil 5.20: Anlık zaman bölgesi öznitelikleri

5.2. Önerilen Modelde Uygulanan Değerlendirme Yöntemi ve Ölçütleri

Belirli bir sınıflandırma modelinin başarımını, seçilen öğrenme algoritmasının dışında; sınıfların dağılım payları, hatalı sınıflandırma veya eğitim ve test verilerinin tercih edilen büyüklüğü de etkileyebilir. Modelin eğitiminde, elde bulunan tüm verinin eğitim işleminde kullanılması etkili bir değerlendirme gerçekleştirilmesine yardımcı olamaz. Modelin eğitim esnasında görmediği verilerin test işlemine katılmasıyla yorumlanacak sonuçlar kayda değerdir. Tüm bu bağlayıcı unsurların etkisini ortadan kaldırmak amacıyla üçlü ayırma (eğitim-doğrulama-test), tabakalı örnekleme, çapraz geçerleme gibi bir çok değerlendirme yöntemi geliştirilmiştir [8].


Bu tez çalışmasında tercih edilen yöntem, **k–kat çapraz geçerleme** (*k–fold cross validation*) olarak adlandırılan değerlendirme yöntemidir. Çapraz geçerleme yöntemi, çok parametrelili bir modelin parametre değişimine göre başarımını ölçmek ve kıyaslamak amacıyla kullanılabilen etkili bir yöntemdir [8]. Burada kullanılan *k–kat çapraz geçerleme* işleminde, tüm veri seti k eşit parçaya ayrılır. Eşit sayıda veri içeren her k parçası döngüye alınır ve her döngüde bir k parçası test verisi olarak, geriye kalan $(k - 1)$ tanesi de eğitim verisi olarak işleme alınır. k adet döngü sonunda her döngü için birer adet olmak üzere k kadar başarımlar ya da hata değeri elde edilmiş olur. Modelin genel başarımını yorumlamak için bu değerlerin ortalaması alınır ve tek bir başarımlar ya da hata değeri elde edilir. Farklı öğrenme algoritmalarının değerlendirilmesinde, k kat işlem sonucunda elde edilen başarımlar dizisinin standart sapma değeri incelenerek de yorumlamalar yapılmaktadır [56].

Şekil 5.21, 5–kat çapraz geçerleme örneğinin iş akışını gösteren bir anlatım sunmaktadır. Kat değeri 5 olduğu için sınıflandırma algoritması bu sayıda döngü ile tekrarlı olarak çalıştırılır. Bu yöntemin somut tek dezavantajı da k kat sayısı kadar döngü ile tekrar eden işleme ihtiyaç duyuyor olunmasıdır.



Şekil 5.21: 5-kat çapraz geçerleme yöntemine ait örnek anlatım

Bu tez çalışmasına özgü olarak değerlendirme sürecinde, k–kat çapraz geçерleme yöntemine ek bir test işlemi daha düşünölmüştür. Belirlenen yöntemde, öncesinde anlatılan CRISP modeli ile özetlenen süreçte de gösterildiğı gibi model değeriendirme ve uygulama süreçlerinin sağılıklı olarak işletilmesi için gerekli işlem basamakları uygulanmıştır. Kullanılan değeriendirme yöntemine ait blok şeması Şekil 5.22 ile gösterilmiştir.



Şekil 5.22: Tez çalışmasında kullanılan değeriendirme yöntemi

Şekil 5.22 ile gösterildiği üzere öznitelik çıkarım süreci sonunda elde edilen 1500 örnekli ana veri seti; eğitim seti (1000 örnek) ve test seti (500 örnek) olmak üzere ikiye bölünmüştür. Her iki set de eşit sayıda dağılım gösteren 5 olay sınıfından meydana gelmiştir. Tez çalışmasında kullanılan model belirleme yönteminde, önerilen makine öğrenme algoritmalarının eğitim süreci 10–kat çapraz geçerleme yöntemi ile gerçekleştirilmiştir. Yani eğitim işlemi de kendi içerisinde bir doğrulama süreci içererek, yukarıda tarif edildiği üzere, 10–kat çapraz geçerleme yöntemi çerçevesinde hem eğitilip hem de test edilerek 10 farklı model ve başarımları elde edilmiştir.

Elde edilen ve sonuç üreten 10 model içerisinde, toplam başarımları en yüksek olan model tercih edilerek “*belirlenen model*” tespit edilmiştir. Elde edilen bu son modele, 10–kat çapraz geçerleme sırasında hiç gösterilmeyen test veri seti uygulanarak deneysel sonuçlar kaydedilmiştir. Böylece önerilen tüm algoritmalar en zor şartlar oluşturularak eğitim ve test sürecine tabi tutulmuştur. Ayrıca son kullanıcının problemine bütüncül bir çözüm oluşturan bir model önerisi ve uygulaması da böylece belirlenmiş olmaktadır. Tez çalışması sonucunda her algoritmanın değerlendirildiği her ayrı senaryo için bir model saklanmış ve bu modeller gömülü cihazlarda kullanılabilecek yapıda olduğundan son kullanıcıya hitap eder tarzda bir güç kalitesi olay sınıflandırıcı ürün paketi elde edilmiştir.

Önerilen model için kullanılan değerlendirme ölçütleri, kontenjans tablosu ya da hata matrisi (*confusion matrix*) olarak adlandırılan bir çizelgenin oluşturulmasına dayanan ve literatürde en çok tercih edilen ölçütler içerisinde seçilerek belirlenmiştir [8, 114, 115]. İkili bir sınıflandırma örneği düşünülerek anlatılan hata matrisi genel mantığına ait gösterim Şekil 5.23 ile verilmiştir.

		Gerçek Sınıf Etiketleri		
		Pozitif	Negatif	Toplam
Tahmin Sınıf Etiketleri	Pozitif	A Doğru Pozitif (True Positive) (TP)	B Yanlış Pozitif (False Positive) (FP)	A+B (Pozitif Tahmin) (PT)
	Negatif	C Yanlış Negatif (False Negative) (FN)	D Doğru Negatif (True Negative) (TN)	C+D (Negatif Tahmin) (NT)
	Toplam	A+C (Gerçek Pozitif) (GP)	B+D (Gerçek Negatif) (GN)	N (Toplam Veri)

Şekil 5.23: Örnek hata matrisi (confusion matrix) anlatımı

Şekil 5.23 ile gösterildiği üzere hata matrisinin satır ve sütunlarını tahmin edilen ve gerçek sınıf etiketleri oluşturmaktadır. Pozitif ve negatif olmak üzere ikili sınıflandırma üzerinden gerçekleştirilen bu özet anlatımda, hata matrisi 4 ana çıktı değeri üretmektedir. Bu değerler; pozitif sınıfların doğru tahmin edildiği doğru pozitif (True Positive–TP) ve yanlış tahmin edildiği yanlış pozitif (*False Positive–FP*) ile negatif sınıfların yanlış tahmin edildiği (*False Negative–FN*) ve doğru tahmin edildiği doğru negatif (True Negative–TN) ifadelerinden oluşmaktadır. Satırların toplamını sırasıyla Pozitif Tahmin (PT) ve Negatif Tahmin (NT) değerleri, sütunlarını toplamını da sırasıyla Gerçek Pozitif (GP) ve Gerçek Negatif (GN) değerleri oluşturmaktadır.

Hata matrisinden elde edilen bu özel indis değerlerinden faydalanarak, sınıflandırıcı başarımlarını tespit edip değerlendirilmesini sağlayan birçok başarımlar ölçütü bulunmaktadır [114]. Devam eden anlatımda, bu tez çalışmasında kullanılan ve Şekil 5.23 ile verilen indislere dayalı hesaplanan değerlendirme ölçütlerine değinilecektir.

Doğruluk (Accuracy): Modelin tüm veri seti üzerindeki genel başarımlar değerini göstermektedir. Matematiksel ifadesi (5.1) ile verilir. Ayrıca doğruluk ifadesinin birime tümleyen değerine ise hata oranı (*error rate*) olarak adlandırılır ve (5.2) ile hesaplanır:

$$\text{Doğruluk (Acc)} = \frac{TP + TN}{N} = \frac{(A + D)}{N} \quad (5.1)$$

$$\text{Hata oranı (Err)} = 1 - \text{Acc} \quad (5.2)$$

Duyarlılık (Sensitivity): Modelin sadece pozitif sınıf etiketleri üzerindeki başarımlar değerini göstermektedir. (5.3) ile şu şekilde hesaplanır:

$$\text{Duyarlılık (Sens)} = \frac{TP}{GP} = \frac{TP}{TP + FN} = \frac{A}{(A + C)} \quad (5.3)$$

Özgüllük (Specificity): Modelin sadece negatif sınıf etiketleri üzerindeki başarımlar değerini göstermektedir. Matematiksel gösterimi (5.4) ile verilmiştir:

$$\text{Özgüllük (Spec)} = \frac{TN}{GN} = \frac{TN}{FP + TN} = \frac{D}{(B + D)} \quad (5.4)$$

Bu tez çalışmasında, yukarıda bahsedilen başarımlar değerlendirme ölçütleri ve bunlara temel teşkil eden hata matrisleri deneysel çalışmalardan elde edilen bulguların yorumlanması

noktasında detaylı olarak verilecektir. Bu çalışmada kullanılan ve önerilen modeller, çoklu-sınıflandırma gerçekleştirdiği için [114] çalışmasında matematiksel ifadeleri verilen ve çoklu sınıflandırmaya göre uyarlanan değerlendirme ölçütlerine ait hesaplamalar denklem (5.5) ile sırasıyla verilmiştir, burada sınıf sayısı m ile gösterilmiştir, ayrıca μ ve M ise mikro ve makro ortalama değerlerini temsil etmektedir. Makro ortalama ve mikro ortalama değerleri sırasıyla, modelin başarımının veri setleri arası değerlendirilmesinde ve veri setinin değişkenlik gösterdiği durumlardaki başarımların değerlendirmesinde tercih edilmektedir [8].

$$\begin{aligned}
 \text{Ortalama doğruluk (AveAcc)} &= \frac{\sum_{i=1}^m \left(\frac{TP_i + TN_i}{TP_i + FN_i + FP_i + TN_i} \right)}{m} \\
 \text{Ortalama hata oranı (AveErr)} &= \frac{\sum_{i=1}^m \left(\frac{FP_i + FN_i}{TP_i + FN_i + FP_i + TN_i} \right)}{m} \\
 \text{Duyarlılık}_{\mu} (\text{mTP}) &= \frac{\sum_{i=1}^m TP_i}{\sum_{i=1}^m (TP_i + FN_i)} \\
 \text{Duyarlılık}_M (\text{MTP}) &= \frac{\sum_{i=1}^m \left(\frac{TP_i}{TP_i + FN_i} \right)}{m} \\
 \text{Özgüllük}_{\mu} (\text{mSpec}) &= \frac{\sum_{i=1}^m TN_i}{\sum_{i=1}^m (TN_i + FP_i)} \\
 \text{Özgüllük}_M (\text{MSpec}) &= \frac{\sum_{i=1}^m \left(\frac{TN_i}{TN_i + FP_i} \right)}{m}
 \end{aligned} \tag{5.5}$$

Çoklu sınıflandırma işleminde kullanılan örnek bir hata matrisi de Şekil 5.24 ile gösterilmiştir. Burada, yine satır ve sütun verileri sırasıyla tahmin edilen ve gerçek sınıf etiketlerini göstermektedir. Şekil 5.24 ile verilen hata matrisine ait n_{ij} ($1 \leq i, j \leq k$) elemanları, i sınıfına ait ve $\hat{S}_i$ sınıflandırıcısı tarafından üretilen fakat gerçekte j sınıfına ait olan yani S_j sınıflandırıcısı tarafından üretilen veri örnek sayısını ifade etmektedir.

	S_1	$\dots$	S_m
$\hat{S}_1$	n_{11}	$\dots$	n_{1k}
$\vdots$	$\vdots$	$\ddots$	$\vdots$
$\hat{S}_m$	n_{i1}	$\dots$	n_{ik}

Şekil 5.24: Örnek hata matrisi: Çoklu sınıflandırma

Çoklu sınıflandırma neticesinde elde edilen hata matrisi incelendiğinde, matrisin köşegen eksenindeki (diyagonal) elemanların ($i = j$) doğru sınıflandırılmış veri örnek sayılarını gösterdiği söylenebilir buna karşılık olarak köşegen eksen dışındaki (off-diagonal) tüm elemanların ($i \neq j$) ise yanlış sınıflandırılmış veri örneklerini göstermektedir.

Tüm makine öğrenme algoritmalarında, sınıflandırıcı için hazırlanan giriş verileri yani öznitelik matrisi, ilk hesap edildiği hali ile kullanılmaz. Ortaya çıkabilen sayısal değerlerin büyük olması, sınıflandırıcı performanslarını olumsuz yönde etkileyebileceği gibi böyle bir durum çıkış etiketlerinde baskınlık kurabilmektedir. Ayrıca sayısal değerlerin tümünün aynı aralıkta dağılım göstermesi de dengesiz durumların ortadan kalkmasına fayda sağlayacaktır. Bu olumsuzlukları yenebilmek adına verilere normalleştirme (*normalizasyon*) işlemi uygulanmaktadır [8]. Bu tez çalışmasında, sıfır ortalama birim varyans olarak da bilinen ve genellikle **z-değeri** (z-score) olarak adlandırılan normalleştirme yöntemi tercih edilmiştir. Gerek literatürde yapılan incelemelerde gerekse ELM başarımına olan etkisinin ampirik olarak incelenmesiyle tercih edilen bu yöntemle ait matematiksel ifade (5.6) ile verilmiştir.

$$z_i = \frac{x_i - \bar{X}}{s} \quad (5.6)$$

Buradaki z-değer (z_i) hesaplamasında, x_i örneklerinden oluşan veri dizisinin ortalama değerini $\bar{X}$ temsil etmektedir, s ise veri dağılımının standart sapmasıdır.

5.3. Deneysel Sonuçlar

Bu tez çalışmasında, güç kalitesi olaylarının sınıflandırılması amacıyla makine öğrenme tabanlı modeller oluşturulmuştur. Modellerin tasarımında, sahadan elde edilmiş gerçek güç kalitesi olay veri seti ve Bölüm 4.2 ile ayrıntıları verilen makine öğrenme tabanlı ELM sınıflandırıcı algoritmaları kullanılmıştır. Bu alt bölümde öncelikli olarak, yapılan deneylerin teknik alt yapıları sunulacaktır. Yani değerlendirme yöntemleri ve ölçütlerinin uygulama teknikleri ve farklı öznitelik setlerinin etkilerinin incelenmesi adına oluşturulan senaryoların tanıtımına ait uygulama detayları verilecektir. Bunları takiben, incelenen modellerin her biri için deneysel sonuçları sunan tablo ve grafiksel gösterimler detaylandırılacaktır.

İncelenen modellerde kullanılan algoritmaların etkili bir şekilde değerlendirilip kıyaslanabilmesi adına, Bölüm 5.2 ile detayları verilen ve bu tez çalışmasına özgü kurulan değerlendirme yöntemi tercih edilmiştir. Bu iş akışında, eğitim aşaması 10-kat çapraz geçirme ile oluşturulmuştur. Böylece sınıflandırıcıların yüzleşebileceği ezberleme ya da aşırı

öğrenme gibi olumsuzlukların önüne geçilerek başarımı en yüksek modelin tespit edilmesi sağlanmıştır. Devamında, eğitim sırasında hiç kullanılmamış olan ayrı bir veri seti ile de, belirlenen bu modele tek seferde test işlemi uygulanmıştır.

Her algoritmanın başarımlarını değerlendirme, Bölüm 5.2 ile verilen değerlendirme ölçütleri kullanılarak gerçekleştirilmiştir. Burada dikkat edilmesi gereken önemli ayrıntı, algoritmalara ait eğitim başarımlarının 10–kat çapraz geçerleme deneyleri sonucu elde edilen değerlerin ortalaması olduğudur. Geleneksel anlamda kullanılan, algoritmanın eğitim sürecinde gördüğü veriler kullanılarak elde edilen eğitim başarımları değil, bir *iç test* uygulaması sonucu elde edilen çıktılar kullanılmıştır. Bu başarımlar, tercih edilen ölçütlerin yanı sıra, hata matrisleri kullanılarak da görsel olarak aktarılmıştır. Hata matrislerinin analizleri bize, sınıflar arası ayırt etme başarımını daha net olarak ortaya koyacak değerlendirmeleri yapma olanağı sunmaktadır.

Tez çalışması boyunca yapılan tüm analizler, MATLAB programı “*editor*” ortamında yazılan kod dosyaları ve dizinleri ile gerçekleştirilmiştir. Buna, veri seti hazırlama ve ön işlem süreci de dahildir. Kodların üzerinde çalıştırıldığı iş istasyonu, 8 çekirdekli ve temel frekansı 2,1 GHz olan çift işlemciden oluşan, 32 GB hafıza (RAM) bileşenine sahip bir donanım mimarisinden oluşmaktadır.

5.3.1. Değerlendirme Senaryoları

Güç kalitesi işaretlerinin sınıflandırılması literatürüne bu tez çalışması ile katkı sağlayan histogram, permütasyon entropi, yerel tepe noktaları ve anlık zaman bölgesi yöntemleri belirlenirken, üretilecek öznitelik setinin en az sayıda eleman içermesine özen gösterilmiştir. İşlem hızı yönünden de sınıflandırıcı işleyişini olumlu etkileyecek bu anlayış ile özniteliklerin bütününe içeren *tam öznitelik seti*, 51 adet örnek içermektedir. Yani gerçek verilerin oluşturduğu ham veri setinden elde edilen ana öznitelik vektörü, yaklaşık 81 kat daha az bir boyutla sınıflandırıcı girişini oluşturacak yapıya kavuşmuştur.

Öznitelik vektörü eleman sayısının bu denli az bir değer ile ortaya çıkarılması neticesinde, model değerlendirmede öznitelik seçim işlemi, belirlenen bazı senaryolar ışığında gerçekleştirilmiştir. Böylece, uygulanan analizlerin değerlendirilmesi daha derinlemesine ve tüm yönleri ile ele alınarak yapılmıştır. Uygulanan deneylerin çeşitliliğini arttırarak, önerilen modeli daha etkin değerlendirmeyi sağlayan bu yönteme ait senaryoların anlatımı bu alt bölümde sunulmuştur.

Bölüm 4.1 ile ayrıntıları verilen yöntemlerden elde edilmiş özniteliklerin oluşturduğu tam öznitelik seti, Tablo 5.7 ile şu şekilde özetlenmiştir:

Tablo 5.7: Tam öznitelik setine ait detaylar

Tam Öznitelik Seti İçeriği	
Tanım	Adet
DWT Tabanlı	18
Temel İstatistik Tabanlı	9
Histogram	13
PE ve LP	8
Anlık Zaman Bölgesi	3
Toplam sayı	51
Toplam işlem süresi (s)	66,61
Tek olay ortalama işlem süresi (s)	0,04

Tablo 5.7 ile listelenen öznitelik alt setlerinden oluşan *tam öznitelik setinin* yanı sıra, tez çalışması boyunca uygulanan deneylerde kullanılan ve farklı öznitelik alt setlerinin birleşimi ile oluşturulmuş senaryolara ait detaylar Tablo 5.8 ile bir araya getirilmiştir (*Burada listelenen öznitelik setine ait etiket detayları için bakınız: Bölüm 5.1*).

Tablo 5.8: Deney senaryolarına ait detaylar

Çalışmada Kullanılan Öznitelik Birleşimleri					
(Deney Senaryoları)					
Senaryo	Tanım	Adet	Senaryo	Tanım	Adet
1	D	8	11	LP	1
2	E	8	12	PE+PE _{Hist} +LP	8
3	D+E	16	13	Hist+PE+PE _{Hist} +LP	21
4	DWT SET	18	14	DWT+PE+PE _{Hist} +LP	26
5	Ist	9	15	Hist+DWT+PE+PE _{Hist} +LP	39
6	Hist	13	16	HB	3
7	DWT+Hist	31	17	HB+Hist	16
8	DWT+Hist+Ist	40	18	HB+DWT	21
9	PE	1	19	HB+DWT+Hist	34
10	PE+PE _{Hist}	7	20	HB+Ist	12

Deneysel çalışmalarda, Bölüm 4.1.7 ile kullanım amacı ve altyapısı verilen FV kodlama yöntemi kullanılarak elde edilen öznitelik setlerinin de analizleri gerçekleştirilmiştir. FV kodlama uygulanan tam öznitelik setinin yanı sıra, Tablo 5.9 ile verilen FV kodlama uygulanmış diğer öznitelik senaryoları da deneysel çalışmalarda kullanılmıştır.

Tablo 5.9: Deney senaryolarına ait detaylar: FV kodlama öznitelikler

FV Kodlu Öznitelik Setleri		
(FV Deney Senaryoları)		
Senaryo	Tanım	Adet
1	FV-Tam Set	102
2	FV-HB	6
3	FV-Ist	18
4	FV-DWT	36
5	FV-Hist	26
6	FV-(PE+PE _{Hist})	14
7	FV-LP	2

Tablo 5.8 ile verilen senaryolarda, öznitelik seti boyutları ilk üretildikleri halde sabitken, FV kodlama uygulanmış özniteliklerin boyutları, Bölüm 4.1.7 ile detayları verildiği üzere 2 kat artmıştır. Bu durum FV kodlama işleminin doğasından kaynaklanmaktadır.

Bölümün devamında, buraya kadar genel resmi çizilen deney senaryolarına sadık kalınarak, tez çalışmasında kullanılan her üç model için ayrı ayrı olmak üzere deneysel çalışmalar çeşitli tablolar ve grafikler ışığında sunulacaktır.

5.3.2. ELM Yönteminden Elde Edilen Bulgular

Bölüm 5 ile sunulmaya başlanan tez çalışması bulgularında, bölüm girişinden buraya kadar verilen ayrıntılarda, öznitelik analizleri, öznitelik setlerinin kapsamlı tanıtımı, deneylerin uygulanması esnasında tercih edilen değerlendirme yöntemleri ve ölçütleri ile deneylerin yapılma sürecinde takip edilen senaryolara yer verilmiştir. Bu alt başlıktan itibaren, tez çalışmasında kullanılan sınıflandırıcılara ait bulguların verilmesine, ELM yönteminden elde edilen bulguların sunumu ile başlanmıştır.


Bölüm 4.2.1 ile teorik alt yapısına ait detaylar verilen ELM yöntemini kullanan bir

sınıflandırıcı tasarımında, belirlenmesi gereken parametre sayısı çok azdır. Bu durum yani modelde kullanılan parametre azlığı, yönetime ait bir avantaj olarak tanımlanabilir. ELM sınıflandırıcısına ait tasarım parametreleri, Tablo 5.10 ile verilmiştir.

Tablo 5.10: ELM sınıflandırıcı parametreleri

Yöntem	ELM
Gizli Katman Nöron Sayısı	375 nöron
Etkinleştirme Fonksiyonu	Tek kutuplu (unipolar) basamak (step) (<i>hardlim</i>)

Tablo 5.10 ile verilen parametreler, tam öznitelik setini giriş olarak uyguladığımız bir ELM sınıflandırıcı yapısının, ampirik olarak çalıştırılması sonucunda elde edilmiştir. Parametre belirlemek adına yapılan her deney 100 kez tekrar edilmiş ve başarımlar değerlendirilmeleri ortalama doğruluk verisine göre sıralanmıştır. Ayrıca her deneyde yine 10–kat çapraz geçerleme düzeni ile eğitim ve test işlemleri gerçekleştirilmiştir. Şekil 5.25 ile etkinleştirme (aktivasyon) fonksiyonu olarak MATLAB programında *hardlim* olarak tanımlı, tek kutuplu (unipolar) basamak (step) fonksiyonu kullanan bir ELM yapısının, gizli katman nöron sayısı değişimine karşılık gelen başarımları gösterilmiştir. Parametre olarak belirlenen 375 nörona sahip ELM sınıflandırıcı yapısının en yüksek başarımlar değerini yani ortalama doğruluk değerini ürettiği görülmektedir.



Şekil 5.25: ELM Parametreler: Gizli katman nöron sayısı değişimi

Burada kullanılabilecek olan türevlenebilir yapıdaki tanjant sigmoid (*tansig*), radyal bazlı (*radbas*) ve sigmoid (*sig*) fonksiyonları, deneysel olarak incelenmiş ve *hardlim* fonksiyonunun en iyi ortalama doğruluk değeri verdiği gözlemlenmiştir.

Tablo 5.11: ELM sınıflandırıcı yapısına ait genel başarımların değerleri

Senaryo	Sayı	Doğruluk (Acc)				Süre (s)		Duy.	Özg.
		Test	Eğitim	$\pm$	Var	Eğitim	Test		
TS	51	0,984	0,975	0,02	0,0003	0,9516	0,2656	0,9933	0,9900
1	8	0,884	0,892	0,02	0,0004	0,8359	0,0000	0,9867	0,8150
2	8	0,862	0,885	0,03	0,0009	0,8188	0,0000	0,9667	0,8500
3	16	0,916	0,934	0,03	0,0006	0,8359	0,0000	0,9933	0,9000
4	18	0,948	0,949	0,01	0,0001	0,9641	0,2500	0,9933	0,9500
5	9	0,948	0,941	0,03	0,0008	0,7734	0,0000	0,9767	0,9450
6	13	0,852	0,862	0,03	0,0009	0,7859	0,0000	0,9467	0,8900
7	31	0,968	0,954	0,01	0,0002	0,9547	0,0000	0,9900	0,9600
8	40	0,976	0,965	0,01	0,0001	0,8516	0,0000	0,9900	0,9850
9	1	0,670	0,585	0,04	0,0013	0,7313	0,0000	0,9800	0,7550
10	7	0,724	0,708	0,04	0,0019	0,8453	0,0000	0,9467	0,7700
11	1	0,666	0,671	0,05	0,0026	0,8078	0,0000	0,9833	0,8250
12	8	0,806	0,754	0,06	0,0034	0,9047	0,4531	0,9733	0,8300
13	21	0,886	0,896	0,04	0,0012	0,8813	0,2500	0,9733	0,8950
14	26	0,956	0,945	0,02	0,0005	0,9563	0,0000	0,9933	0,9500
15	39	0,968	0,960	0,02	0,0004	0,9688	0,4844	0,9900	0,9750
16	3	0,962	0,965	0,02	0,0005	0,7625	0,0000	0,9833	0,9500
17	16	0,954	0,947	0,03	0,0010	0,8109	0,0000	0,9767	0,9550
18	21	0,982	0,970	0,02	0,0006	0,8375	0,0000	0,9900	0,9850
19	34	0,980	0,975	0,02	0,0002	0,9906	0,0000	0,9900	0,9750
20	12	0,986	0,958	0,03	0,0007	0,8297	0,0000	0,9967	0,9800
FV1 (TS)	102	0,982	0,975	0,01	0,0001	0,9313	0,0000	0,9967	0,9800
FV2	6	0,968	0,967	0,01	0,0001	0,8234	0,2813	0,9833	0,9650
FV3	36	0,884	0,953	0,02	0,0006	0,8953	0,0000	0,9867	0,9400
FV4	26	0,824	0,870	0,03	0,0008	0,8484	0,2500	0,9333	0,8750
FV5	18	0,922	0,944	0,02	0,0003	0,8297	0,0000	0,9767	0,9200
FV6	2	0,562	0,675	0,03	0,0010	0,9531	0,0000	0,9333	0,8350
FV7	14	0,640	0,668	0,05	0,0022	0,8578	0,2500	0,9267	0,7300

Tablo 5.11, ELM genel başarımlarını göstermektedir. **Senaryo** sütununda, Tüm Set (TS) öznitelik vektöründen başlayarak, Tablo 5.8 ve Tablo 5.9 ile verilen senaryo sıralarına göre dizilen öznitelik alt setleri ve birleşimleri gösterilmiştir. **Sayı** sütunu, her öznitelik setinde bulunan eleman sayısını göstermektedir. **Doğruluk (Acc)** sütunlarında, 10–kat çapraz geçerlemeli ortalama *eğitim doğrulukları* ve bunlara ait *standart sapma* ($\pm$) ve *varyans* (*Var*) değerleri verilmiştir. Son iki sütunda ise sırasıyla **duyarlılık (Duy.)** ve **özgüllük (Özg.)** ölçütlerine yer verilmiştir.

Tablo 5.11 detaylı olarak incelendiğinde, test doğruluğu bakımından en yüksek başarımların senaryo–20 ile **HB+Ist** birleşiminin verdiği görülmektedir. Anlık zaman bölgesi ve istatistik tabanlı özniteliklerden oluşan bu alt set, duyarlılık ve özgüllük açısından da başarılı değerler ortaya koymuştur. Tüm senaryolara ait eğitim ve test süreleri kabul edilebilir değerlerdedir. Özellikle 1000 veriden oluşan eğitim seti düşünüldüğünde, eğitim sürelerine ait ortalama değerlerin özellikle en yüksek doğruluk veren set için 0,8297 saniye değerinde olması, ELM yönteminin hesapsal hız bakımından son derece etkili sonuçlar üretebildiğini ispatlamaktadır.

Genel sonuçlar içerisinde, test doğruluğu başarımlar diziliminin ikincilik sırasında tüm öznitelik seti (TS) bulunmaktadır ve 0,002 daha az bir başarımla sahiptir. Bunun yanında, duyarlılık ve özgüllük değerleri yorumlandığında, sınıfları ayırt etmede daha başarılı olduğu söylenebilir. Üçüncülük sırasında ise yine maksimum başarıma çok yakın bir sonuç üreten, FV kodlanmış TS (FV1–TS) öznitelikleri bulunmaktadır. FV kodlama işleminde öznitelik setindeki artış miktarının ELM yöntemi için ayırt ediciliğe olumsuz etkisi olduğu yorumuna ulaşılabilir.

Test doğruluğu sıralamasında, en düşük üç başarımların sondan başlayarak FV6 (LP), FV7 (PE) ve senaryo–12 ile LP öznitelik setleri oluşturmaktadır. Bu setler sırasıyla 2, 14 ve 1 eleman sayısına sahip olduğundan, eğitim ve test süresi açısından en hızlı işlenen setler arasında bulunmaktadır.

ELM yöntemine ait genel sonuçların daha detaylı incelenmesi adına test verisindeki sınıfların doğru sınıflandırılma sayısını gösteren, sınıflara göre başarımların değerleri tablosu da oluşturulmuştur. Burada, test verisi sınıf bazında 100 örnek içerdiğinden, doğru sınıflandırılan örnek sayısı bu değer üzerinden yüzde olarak okunabilmektedir. Bu yönde elde edilen bulgular Tablo 5.12 ile sunulmuştur. Buradan TS özniteliklerinin, **çukur** ve **kesinti** sınıflarının her ikisinde de tüm örnekleri doğru tahmin ettiği görülmektedir.

Tablo 5.12: ELM yönteminde sınıflara göre ortaya çıkan test başarımları

Senaryo	Sayı	SINIF TEST BAŞARIMLARI (%)				
		SAF	ÇUKUR	TEPE	KESİNTİ	HARM.
Tam Set	51	98	100	97	100	97
1	8	93	94	98	60	97
2	8	91	94	83	71	92
3	16	95	91	96	85	91
4	18	95	94	99	89	97
5	9	97	96	95	91	95
6	13	98	80	81	87	80
7	31	98	98	97	99	92
8	40	98	98	95	100	97
9	1	98	51	67	53	66
10	7	96	73	63	60	70
11	1	71	54	93	62	53
12	8	99	81	82	63	78
13	21	97	87	89	89	81
14	26	99	95	98	90	96
15	39	97	98	95	98	96
16	3	99	100	95	96	91
17	16	97	95	96	98	91
18	21	98	100	97	99	97
19	34	99	98	98	100	95
20	12	99	100	98	99	97
FV1 (TS)	102	97	100	99	99	96
FV2	6	99	100	95	96	94
FV3	36	66	100	94	87	95
FV4	26	97	77	81	87	70
FV5	18	86	98	95	92	90
FV6	2	0	88	79	66	48
FV7	14	82	63	68	51	56

Tahmin Sınıf Etiketleri	OS ₁	99	1	0	0	0	%99 %1
	OS ₂	0	100	0	0	0	%100 %0
	OS ₃	0	1	98	1	0	%98 %2
	OS ₄	0	0	1	99	0	%99 %1
	OS ₅	0	0	0	3	97	%97 %3
		%100 %0	%98 %2	%99 %1	%96,1 %3,9	%100 %0	%98,6 %1,4
		OS ₁	OS ₂	OS ₃	OS ₄	OS ₅	
		Gerçek Sınıf Etiketleri					

Şekil 5.26: ELM hata matrisi: Senaryo-20

Şekil 5.26 ile verilen hata matrisi, ELM yöntemi genel sonuçları içerisinde en yüksek başarımların üreten senaryo-20 ile elde edilmiştir. Burada hata matrisinin satırları tahmin edilen sınıflara ait örnek sayılarını göstermektedir, sütunları ise gerçek (doğru) sınıflara ait örnek değerlerini temsil etmektedir. Her satır/sütun doğruluk oranları, matriste alt ve en sağ kısımdaki hücrelerde yüzdelik değer olarak da özetlenmiştir. Bu oran ifadelerinin altında, yüzdelik hata değerlerine de yer verilmiştir. Burada dikkat edilmesi gereken bir nokta da şudur ki her sütunun doğruluk oranı bize esasen sınıflara ait duyarlılık değerini de vermektedir; her satıra ait doğruluk oranı ise her sınıfın bağımsız doğruluk değerlerini ifade etmektedir.

5.3.3. SB-ELM Yönteminden Elde Edilen Bulgular

Bölüm 4.2.2 ile matematiksel detayları verilen SB-ELM yönteminden elde edilen bulgulara bu bölümde yer verilmiştir. Temel ELM yönteminden farklı olarak SB-ELM, çıkış ağırlıkları bulma aşamalarında Bayesçi yaklaşım ile optimizasyon işlemi gerçekleştirerek, seyreklik mantığına dayanan bir aktif nöron sayısı önermektedir. Bu özelliği ile SB-ELM algoritması, belli bir gizli katman nöron sayısı aralığında gerçekleştirdiği optimizasyon neticesinde elde ettiği aktif nöron sayısı ile işlem yapmaktadır. Bu da gizli katman nöron sayısını ciddi şekilde düşürerek daha sade bir model elde etmeyi sağlamaktadır [56].

SB-ELM sınıflandırıcı yapısına ait deneylerde gizli katman etkinleştirme fonksiyonu olarak sigmoid fonksiyonu tercih edilmiştir ve $g(\mathbf{a}, b, x) = 1/(1 + \exp(-(\mathbf{a}x + b)))$ ile ifade

edilir. Burada, a ve b işlemin başında rastlantısal olarak belirlenen ağırlık (sinaps) ve her ağırlığa eklenen yanlılık (bias) değerlerini ifade etmektedir. Bu değerler $[-1, +1]$ aralığında tekdüze (uniform) bir dağılım yapısındadır. Pratikte bu rastlantısal parametreler, başarımlar üzerinde etki oluşturabilmektedir. Bu nedenle, SB-ELM algoritmasında çapraz geçerleme sırasında işlenen her döngüde bu değerler üzerinde bir iyileştirme gerçekleştirilmiş ve bir çekirdek (seed) tarama aralığı tanımlanarak, her çapraz geçerleme döngüsü bu aralıkta tek-raren çalıştırılmıştır.

Gizli katman nöron sayısı L ve rastlantısal ağırlık ve yanlılık değerlerini üretecek çekirdek tarama aralığı s ifadeleri $[L, s]$ ile gösterilecek olursa, SB-ELM deneyleri bu aralıkların $[20, 40, 60, \dots, 200] \times [1, 2, \dots, 5]$ olacak şekilde tanımlanarak, gizli katman nöronlarının her döngüde 20 artırılmasıyla çalıştırılmıştır. 10-kat çapraz geçerleme ile çalıştırılan deneylerde (eğitim aşamasında) tercih edilen bu 5 farklı nöron değerinin, 5 çekirdek tarama ile çalıştırılması başarımlar değerlerinin üretilmesi için yeterli olarak kabul edilmiştir. Parametre seçiminde ampirik sonuçların yanı sıra [56] çalışmasındaki öneriler de dikkate alınmıştır. Böylece, SB-ELM modeli her senaryo için $5 \times 5 \times 10 = 250$ kez çalıştırılarak deneylere ait bulgular elde edilmiştir. Kullanılan SB-ELM parametrelerine ilişkin bilgiler, Tablo 5.13 ile özet olarak sunulmuştur.

Tablo 5.13: SB-ELM sınıflandırıcı parametreleri

Yöntem	SB-ELM
Gizli Katman Nöron Sayısı (L)	[20 : 20 : 200] dizisi ile taranacak
Ağırlık ve Yanlılık Arama Aralığı	[1 : 1 : 5] dizisi
Etkinleştirme Fonksiyonu	Sigmoid fonksiyonu

SB-ELM yönteminin deneylerinde, tarama algoritmaları döngüsel (her deney 250 döngü) olarak çalıştığından dolayı eğitim sürelerinin özellikle temel ELM yöntemine göre çok daha uzun olacağı aşikardır. Yapılan optimizasyonlar neticesinde elde edilecek modelin sade bir yapıda ve temel ELM yapısına göre daha iyi genelleştirme ve doğruluk değeri üretebilme yeteneği kazanacağı düşünüldüğünde, model belirleme aşamasındaki bu tek seferlik gecikme göze alınabilir niteliktedir. Tablo 5.14 ile SB-ELM yöntemine ait genel başarımlar değerleri gösterilmektedir.

Tablo 5.14: SB–ELM sınıflandırıcı yapısına ait genel başarımların değerleri

Senaryo	Sayı	Doğruluk (Acc)				Süre (s)		Duy.	Özg.
		Test	Eğitim	$\pm$	Var	Eğitim	Test		
TS	51	0,986	0,986	0,01	0,0002	168,9844	0,0273	1,0000	0,9850
1	8	0,892	0,928	0,02	0,0003	164,4844	0,0243	0,9800	0,8500
2	8	0,928	0,944	0,02	0,0004	131,4219	0,0282	0,9867	0,9250
3	16	0,960	0,961	0,02	0,0004	138,9531	0,0252	0,9900	0,9600
4	18	0,978	0,973	0,01	0,0002	138,3750	0,0253	0,9933	0,9750
5	9	0,970	0,971	0,02	0,0003	147,4063	0,0246	0,9833	0,9600
6	13	0,900	0,902	0,03	0,0009	212,7656	0,0280	0,9700	0,9300
7	31	0,968	0,972	0,02	0,0006	153,5000	0,0266	0,9967	0,9450
8	40	0,978	0,977	0,03	0,0007	157,9375	0,0269	0,9967	0,9700
9	1	0,476	0,501	0,05	0,0025	63,1875	0,0241	0,9733	0,6750
10	7	0,696	0,674	0,05	0,0030	105,1719	0,0305	0,9767	0,7550
11	1	0,670	0,676	0,04	0,0014	87,3906	0,0249	0,9933	0,7950
12	8	0,782	0,788	0,03	0,0007	141,1250	0,0302	0,9867	0,8850
13	21	0,930	0,934	0,01	0,0002	194,0625	0,0294	0,9833	0,9500
14	26	0,974	0,969	0,01	0,0002	145,7031	0,0264	1,0000	0,9750
15	39	0,978	0,968	0,02	0,0005	170,2656	0,0279	0,9967	0,9650
16	3	0,986	0,974	0,01	0,0001	109,4688	0,0250	0,9867	0,9950
17	16	0,988	0,978	0,01	0,0001	160,0469	0,0251	0,9900	0,9950
18	21	0,994	0,992	0,01	0,0000	146,0781	0,0238	0,9967	0,9950
19	34	0,988	0,986	0,01	0,0001	153,5938	0,0257	1,0000	0,9800
20	12	0,992	0,982	0,01	0,0001	140,6719	0,0239	0,9900	1,0000
FV1 (TS)	102	0,980	0,978	0,01	0,0000	203,8281	0,0242	0,9967	0,9750
FV2	6	0,990	0,980	0,01	0,0001	150,4844	0,0237	0,9900	0,9950
FV3	36	0,888	0,975	0,01	0,0001	164,1875	0,0272	0,9900	0,9800
FV4	26	0,870	0,914	0,02	0,0005	233,8125	0,0284	0,9533	0,9200
FV5	18	0,946	0,963	0,02	0,0006	159,1719	0,0247	0,9667	0,9250
FV6	2	0,394	0,678	0,03	0,0011	109,7344	0,0284	0,6467	0,9550
FV7	14	0,602	0,713	0,03	0,0007	209,2500	0,0280	0,9867	0,7250

Tablo 5.14 detaylı olarak incelendiğinde, test doğruluğu bakımından en yüksek başarımların değerini senaryo–18 ile **HB+DWT** öznitelik seti birleşiminin verdiği görülmektedir. Anlık

zaman bölgesi ve ayırık dalgacık tabanlı özniteliklerden oluşan bu alt set, duyarlılık ve öz-güllük ölçütleri açısından da ciddi ölçüde yüksek başarımlar ortaya koymuştur. Tüm senaryolara ait eğitim süreleri incelendiğinde, temel ELM yapısına kıyasla önemli miktarda artış olduğu gözlemlenmektedir. Burada dikkatle vurgulanması gereken bir nokta, SB-ELM yapısında eğitim doğruluklarına ait standart sapma ve varyans değerlerinin son derece küçük olarak ortaya çıkmış olmasıdır. Bu durum bize SB-ELM yapısının daha kararlı ve gürbüz çalıştığını göstermektedir.

SB-ELM yöntemine ait genel sonuçlar incelendiğinde, test doğruluğuna göre yapılan sıralamada ikinci olarak senaryo-20 yer almaktadır. HB ve Ist özniteliklerinden oluşan bu birleşim, en yüksek başarımlar değerinden sadece 0,002 kadar geride ve eleman sayısı olarak 9 eksiktir. Özgülük değeri bakımından birinci sıradaki sete göre daha yüksek bir başarımlar kaydedilmiştir. Üçüncülük sırasında ise maksimum başarımlara yakın sonuç üretmiş olan, FV kodlanmış FV2-HB öznitelik seti bulunmaktadır. En yüksek üç başarımlar değeri içinde en az sayıda öznitelik bulunduran alt set FV2-HB öznitelik setidir.

Test doğruluğu sıralamasında, en düşük üç başarımlar değerini sondan başlayarak FV6 (LP), senaryo-9 ile PE ve FV7 (PE) öznitelik setleri oluşturmaktadır. Bu setler sırasıyla, 2, 1 ve 14 eleman sayısına sahip olduğundan, hızlı eğitim süresi değerlerine sahiptir. Bunun yanında, başarımlar değerleri kabul edilebilir seviyenin altındadır.

SB-ELM yönteminin daha sade bir modele sahip olduğunu gösteren bulgular, başarımlar en yüksek olan üç senaryoya ait aktif nöron sayılarının verildiği Tablo 5.15 ile sunulmuştur. Buradan incelenebileceği üzere, temel ELM yönteminde 375 olarak belirlenen gizli katman nöron sayısı, SB-ELM yönteminde çok küçük sayı değerlerine inerek 4 ve 3 olarak belirlenmiştir. Bu yüzden, SB-ELM yönteminde elde edilen test süreleri çok düşük değerde seyretmektedir.

Tablo 5.15: SB-ELM: Seçilen senaryolar için aktif nöron değerleri

Senaryo	Test Doğruluğu	Aktif Nöronlar	
		Test	Eğitim
18	0,994	4	4
20	0,992	4	4
FV2-HB	0,990	3	3

Tablo 5.16: SB–ELM yönteminde sınıflara göre ortaya çıkan test başarımları

Senaryo	Sayı	SINIF TEST BAŞARIMLARI (%)				
		SAF	ÇUKUR	TEPE	KESİNTİ	HARM.
TS	51	97	100	99	100	97
1	8	93	96	95	64	98
2	8	94	98	95	89	88
3	16	96	100	95	91	98
4	18	97	100	98	95	99
5	9	99	100	95	94	97
6	13	97	90	90	90	83
7	31	97	100	99	99	89
8	40	97	100	99	99	94
9	1	100	42	3	35	58
10	7	99	61	70	58	60
11	1	89	44	95	50	57
12	8	100	62	91	66	72
13	21	99	96	94	89	87
14	26	97	100	99	94	97
15	39	97	100	99	100	93
16	3	99	100	96	100	98
17	16	99	100	97	100	98
18	21	99	100	99	99	100
19	34	98	100	100	100	96
20	12	99	100	97	100	100
FV1 (TS)	102	97	100	99	98	96
FV2	6	99	100	97	100	99
FV3	36	54	100	97	95	98
FV4	26	97	91	84	83	80
FV5	18	98	98	92	94	91
FV6	2	100	0	0	92	5
FV7	14	100	7	76	55	63

Tablo 5.16 ile verilen bulgular, SB–ELM yönteminin sınıflar bazında ortaya koyduğu test doğruluklarını göstermektedir. Bu tablodan detaylı olarak incelenebileceği üzere, gerçekleştirilen 28 deneyin neredeyse yarısı ile elde edilmiş sonuçlarda, sınıf doğru tahmin oranının çok yüksek değerlerde olduğu yorumlanabilir. Özellikle **çukur** ve **kesinti** olaylarında %100 tahmin değerine ulaşan veri seti çok fazla sayıda bulunmaktadır.

Tahmin Sınıf Etiketleri	OS ₁	99	1	0	0	0	%99 %1
	OS ₂	0	100	0	0	0	%100 %0
	OS ₃	0	0	99	0	1	%99 %1
	OS ₄	0	0	1	99	0	%99 %1
	OS ₅	0	0	0	0	100	%100 %0
		%100 %0	%99 %1	%99 %1	%100 %0	%99 %1	%99,4 %0,6
		OS ₁	OS ₂	OS ₃	OS ₄	OS ₅	
		Gerçek Sınıf Etiketleri					

Şekil 5.27: SB–ELM hata matrisi: Senaryo–18

Şekil 5.27 ile verilen hata matrisi, SB–ELM yöntemi genel sonuçları içerisinde en yüksek başarımların ortaya koyan senaryo–18 ile elde edilmiştir. Verilen hata matrisi incelendiğinde, tüm sınıflara ait örnek sayılarının neredeyse tamamına yakınının doğru tahmin edildiği yorumuna ulaşılabilir. Görüldüğü üzere, sadece bir örnek için saf sinüs olayı çukur ile karıştırılmıştır. Benzer durum, kesinti ve harmonik olayları arasında da mevcuttur. Yine sadece bir adet tepe olayı, harmonik ile karıştırılarak yanlış sınıflandırılmıştır. Son olarak, bir örnek kesinti olayı ise tepe ile karıştırılmıştır. Sonuç olarak toplamda, sadece 3 adet yanlış sınıflamanın gerçekleştirildiği açık bir şekilde görülmektedir. Temel ELM yöntemine göre başarımların neredeyse tam değere yani *mükemmel sınıflandırma* seviyesine ulaştıran SB–ELM yöntemi, eğitim süresi açısından değerlendirildiğinde yavaş bir yapı ortaya koysa da doğruluk ve sınıflar arası ayırt etme göz önüne alındığında daha kabul edilebilir bulgular üretebilmiştir.


5.3.4. W-ELM Yönteminden Elde Edilen Bulgular

Deneyisel sonuçlara ait bu alt başlıkta, Bölüm 4.2.3 ile teorik altyapısı detaylandırılan W-ELM sınıflandırıcı kullanarak elde edilen bulgulara yer verilmiştir. Temel ELM yönteminde farklı olarak, sınıfların yoğunluğuna göre ek bir ağırlık matrisi ile çözüme ulaşan bu yöntem için belirlenen parametreler, Tablo 5.17 ile listelenmiştir.

Tablo 5.17: W-ELM sınıflandırıcı parametreleri

Yöntem	W-ELM
Gizli Katman Nöron Sayısı	2500 nöron
Düzenleme Parametresi (C)	100
Etkinleştirme Fonksiyonu	Tek kutuplu (unipolar) basamak (step) (<i>hardlim</i>)

Tablo 5.17 ile verilen W-ELM parametreleri, tekrar eden bir dizi deneyin uygulanması neticesinde ampirik olarak elde edilmiştir. Ampirik olarak belirlenen, düzenleme (C) parametresi için [55] çalışmasındaki değerler de aralık olarak referans alınmıştır. Farklı etkinleştirme fonksiyonları arasında, ELM yapısında olduğu gibi tek kutuplu basamak fonksiyonu en iyi doğruluk değerini üretmiştir. Gizli katman nöron sayısına karşılık gelen başarımların analizinde, en yüksek doğruluk değerine 2500 nöronda ulaşıldığı saptanmıştır. Bu durumu sunan grafiksel gösterim Şekil 5.28 ile verilmiştir.



Şekil 5.28: WELM Parametreleri: Gizli katman nöron sayısı değişimi

Tablo 5.18: W-ELM sınıflandırıcı yapısına ait genel başarımlar değerleri

Senaryo	Sayı	Doğruluk (Acc)				Süre (s)		Duy.	Özg.
		Test	Eğitim	$\pm$	Var	Eğitim	Test		
TS	51	0,984	0,976	0,01	0,0002	1,5719	0,5156	0,9867	0,9850
1	8	0,786	0,782	0,04	0,0015	1,5375	0,5156	0,9800	0,8200
2	8	0,726	0,727	0,05	0,0030	1,4328	0,2500	0,9300	0,8100
3	16	0,736	0,739	0,04	0,0015	1,5281	0,2500	0,9233	0,7600
4	18	0,812	0,836	0,03	0,0007	1,1688	0,0156	0,9733	0,9100
5	9	0,978	0,964	0,02	0,0003	1,4500	0,2500	0,9767	0,9950
6	13	0,902	0,920	0,03	0,0007	1,3625	0,2500	0,9633	0,9350
7	31	0,964	0,961	0,02	0,0004	1,3688	0,2500	0,9867	0,9650
8	40	0,972	0,963	0,01	0,0002	1,5109	0,2656	0,9967	0,9700
9	1	0,628	0,592	0,04	0,0014	1,4438	0,2031	0,9900	0,7300
10	7	0,652	0,681	0,03	0,0011	1,2969	0,2500	0,9567	0,7050
11	1	0,618	0,652	0,04	0,0016	1,5156	0,2500	0,9933	0,8250
12	8	0,784	0,765	0,03	0,0008	1,5641	0,2500	0,9800	0,8750
13	21	0,926	0,919	0,04	0,0014	1,5891	0,0156	0,9733	0,9450
14	26	0,890	0,893	0,03	0,0008	1,2125	0,2500	0,9833	0,9150
15	39	0,948	0,951	0,02	0,0005	1,6266	0,2500	0,9867	0,9350
16	3	0,554	0,319	0,12	0,0144	1,3828	0,2500	1,0000	0,4000
17	16	0,970	0,967	0,01	0,0001	1,1563	0,5625	0,9733	0,9750
18	21	0,894	0,936	0,02	0,0003	1,5156	0,2500	0,9700	0,8750
19	34	0,976	0,971	0,02	0,0003	1,4203	0,2500	0,9833	0,9800
20	12	0,410	0,348	0,06	0,0036	1,1438	0,2500	1,0000	0,5050
FV1 (TS)	102	0,994	0,987	0,01	0,0001	1,5531	0,2656	1,0000	0,9950
FV2	6	0,984	0,980	0,02	0,0002	1,5734	0,2500	0,9867	0,9850
FV3	36	0,956	0,975	0,02	0,0003	1,5031	0,2656	0,9900	0,9800
FV4	26	0,900	0,933	0,02	0,0006	1,5922	0,5000	0,9500	0,9500
FV5	18	0,968	0,965	0,02	0,0003	1,4828	0,0156	0,9833	0,9750
FV6	2	0,580	0,647	0,03	0,0010	1,3375	0,2500	0,9333	0,8350
FV7	14	0,736	0,777	0,04	0,0019	1,4328	0,5000	0,9633	0,8500

Tablo 5.18 detaylı olarak incelendiğinde, test doğruluğu bakımından en yüksek başarımlar değerini FV kodlama uygulanmış Tam Set (TS) yani **FV1-TS** öznelik setinin verdiği

görülmektedir. Tez çalışmasında teorik alt yapıları verilen tüm öznitelik çıkarım yöntemlerinden elde edilmiş bu öznitelik seti, duyarlılık ve özgüllük ölçütleri noktasında da yüksek başarımlar ortaya koymuştur. Bu senaryonun ürettiği duyarlılık değerinin 1 olduğu görülmektedir ki bu da modelin sınıflar arası tüm örneklerin neredeyse tamamının birbiri ile karıştırılmadan doğru olarak tahmin edildiğinin göstergesidir. W-ELM yöntemine ait bulgulara, tüm senaryolar için eğitim süreleri incelendiğinde, temel ELM yöntemine kıyasla az da olsa bir artış olduğu görülmektedir. Bu durumun nedeni, genelleme yeteneğinin artırılması adına kullanılan ek ağırlıklandırma süreci ve bu yöntemin sonuca ulaşmada daha fazla ara katman nöron sayısına ihtiyaç duyuyor olmasıdır. Bu yöntemde de, eğitim sonuçlarına ilişkin standart sapma ve varyans değerleri, 10–kat doğrulama sonucu elde edilen doğruluk dizisine ait dağılımın düzgün olduğunu ve başarımlarının ortalamaya yakın bir dağılım sergilediğini göstermektedir.

W-ELM yöntemine ait genel sonuçlar incelendiğinde, test doğruluğuna göre yapılan sıralamada ikinci olarak TS öznitelikleri yer almaktadır. Bu öznitelik seti de FV kodlama yapılmaksızın elde edilen tam öznitelik setini ifade etmektedir. TS senaryosu, en yüksek başarımlar üreten FV kodlamalı halinden sadece 0,01 geride olmakla birlikte FV1-TS setinin yarısı kadar bir eleman sayısına sahiptir. TS öznitelikleri, özgüllük ve duyarlılık ölçütleri açısından incelendiğinde, en yüksek başarıma sahip setten, doğruluk değerindeki farka göre biraz daha fazla geride kaldığı görülmektedir. Tablo 5.18 ile verilen sonuç listesindeki bir ayrıntı da ikinciliği, FV2 setinin yani FV kodlama uygulanmış HB öznitelik setinin paylaştığının görülmesidir. Bu öznitelik seti, TS öznitelik vektöründen yaklaşık 8 kat daha az sayıda eleman içermesine rağmen başarımlar olarak TS ile neredeyse aynı sonuçları üretebilmiştir. Bu da bize, FV kodlama ile haritalanmış anlık zaman bölgesi özniteliklerinin çok az bir sayıda (6 öznitelik) eleman sayısı içermesine rağmen kabul edilebilir bir başarımları yakaladığını göstermektedir.

Tablo 5.18 bulgularında dikkat çeken bir başka nokta ise başarımlar olarak en düşük değerleri üreten setlerin senaryo–16 ve senaryo–20 ile verilen anlık zaman bölgesi öznitelik seti ve bu setle 1st özniteliklerinin birleştirildiği set olduğudur. Bu iki öznitelik seti, FV2–LP senaryosunun da gerisinde kalmıştır.

Tablo 5.19: W-ELM yönteminde sınıflara göre ortaya çıkan test başarımları

Senaryo	Sayı	SINIF TEST BAŞARIMLARI (%)				
		SAF	ÇUKUR	TEPE	KESİNTİ	HARM.
TS	51	99	100	96	100	97
1	8	96	50	94	67	86
2	8	87	53	79	55	89
3	16	90	70	76	42	90
4	18	97	56	90	76	87
5	9	97	100	93	100	99
6	13	97	88	86	95	85
7	31	98	97	94	100	93
8	40	98	99	96	99	94
9	1	100	42	56	48	68
10	7	99	46	64	56	61
11	1	100	2	96	54	57
12	8	100	62	87	73	70
13	21	98	92	90	93	90
14	26	95	82	89	88	91
15	39	97	97	93	99	88
16	3	100	0	97	80	0
17	16	98	99	93	100	95
18	21	92	100	90	83	82
19	34	99	99	95	99	96
20	12	100	5	0	100	0
FV1 (TS)	102	98	100	100	100	99
FV2	6	99	100	96	99	98
FV3	36	85	100	97	98	98
FV4	26	97	82	90	89	92
FV5	18	94	99	96	97	98
FV6	2	100	0	78	66	46
FV7	14	66	82	76	61	83

Tablo 5.19 ile verilen bulgular, W-ELM yönteminin sınıflar bazında ortaya koyduğu test doğruluklarını göstermektedir. Bu tablodan görülebileceği üzere, en yüksek test doğruluğu değerini üretmiş olan FV1-TS senaryosunun, sınıflar arası doğru tahmin kapasitesinin de yüksek olduğu ve test veri setindeki çukur, tepe ve kesinti olaylarının tamamını doğru tahmin ettiği görülmektedir. FV6-LP senaryosunda, çukur olaylarının hiç birinin doğru tahmin edilmediği görülmektedir. Senaryo-16 deneyinde kullanılan ve 39 elemandan oluşan öznitelik setinin de çukur ve harmonik olaylarını tamamıyla yanlış tahmin ettiği görülebilmektedir.

Tahmin Sınıf Etiketleri	OS ₁	98	2	0	0	0	%98 %2
	OS ₂	0	100	0	0	0	%100 %0
	OS ₃	0	0	100	0	0	%100 %0
	OS ₄	0	0	0	100	0	%100 %0
	OS ₅	0	0	1	0	99	%99 %1
		%100 %0	%98 %2	%99 %1	%100 %0	%100 %0	%99,4 %0,6
		OS ₁	OS ₂	OS ₃	OS ₄	OS ₅	
		Gerçek Sınıf Etiketleri					

Şekil 5.29: W-ELM hata matrisi: FV1-TS senaryosu

Şekil 5.29 ile verilen hata matrisi, W-ELM yöntemi genel sonuç listesinde en yüksek başarımlı değerini ortaya koyan FV1-TS senaryosu ile elde edilmiştir. Bu hata matrisi incelendiğinde çukur, tepe ve kesinti olaylarına ait örneklerin tamamının doğru olarak tahmin edilip sınıflandırıldığı görülmektedir. Saf sinüs olayına ait 2 adet örnek çukur olayı olarak yanlış sınıflanmıştır, benzer olarak harmonik sınıfına ait tek örnek ise tepe olayı ile karıştırılarak hatalı sınıflandırma gerçekleştirilmiştir. Sonuç olarak toplamda, sadece 3 adet hatalı sınıflandırma gerçekleştirilmiştir. Genel doğruluk değerinden de anlaşıldığı üzere, neredeyse tüm test seti doğru olarak sınıflandırılmıştır.

Buraya kadar olan kısımda, önerilen her üç sınıflandırıcı yönteminden elde edilen deneysel sonuçlar verilmiştir. Devam eden alt başlıkta, her üç yöntemin kendi arasındaki ve literatürde kabul görmüş temel yöntemlerle karşılaştırmalı başarımlı testlerine yer verilmiştir.

5.3.5. Model Başarım Karşılaştırmaları

Çalışma boyunca gerçekleştirilen analizlerin tümünden elde edilen en yüksek başarımların değerleri bir araya getirilerek Tablo 5.20 ile özetlenmiştir. En iyi başarımları veren model ve senaryoya ait tablo satırı vurgulanmıştır.

Tablo 5.20: Deneysel sonuçlara ait genel başarımlar tablosu

Yöntem (Senaryo)	Sayı	Doğruluk (%)			Süre (s)		Duy.	Özg.
		Test	Eğt.	Var	Eğt.	Test		
W-ELM (FV1-TS)	102	99,4	98,7±0,01	0,0001	1,553	0,265	1,00	0,99
SB-ELM (18)	21	99,4	99,2±0,01	0,0000	146,078	0,023	0,99	0,99
ELM (20)	12	98,6	95,8±0,03	0,0007	0,829	0,000	0,99	0,98

Tablo 5.20 incelendiğinde, test veri setleri içinde FV1-TS senaryosunda, güç kalitesi olayları sınıflandırması işleminde en iyi başarımları veren algoritma W-ELM algoritmasıdır. Burada önerilen her üç modelin de başarımları birbirine çok yakın olsa da, ilk sırada bulunan W-ELM algoritmasının duyarlılık değerinin daha fazla olması bu yönetime ait bir avantajdır. W-ELM algoritması ile aynı test doğruluğunu üretmiş olan SB-ELM algoritması duyarlılık ölçütü açısından geride kalmıştır. Bununla beraber, temel ELM yapısı da en düşük eğitim ve test sürelerine sahiptir.


Tablo 5.21 ile verilen sınıf test başarımlarında görüldüğü üzere, W-ELM algoritması çukur, tepe ve kesinti olaylarındaki tüm test örneklerini doğru sınıflandırmıştır. Yukarıdaki sınıf test başarımlarının özeti düşünüldüğünde, yani 3 yöntem ve 84 deney toplamında, 29 farklı öz nitelik setinin tam doğrulukla sınıfladığı olay türü çukur olaylarıdır. Bunu 16 ile kesinti, 10 ile saf sinüs ve 2'şer tam doğruluk değerleri ile de tepe ve harmonik olayları izlemektedir. Bu sonuçlar da sınıf içi dağılım durumları hakkında bilgi vermektedir.

Tablo 5.21: Genel sonuçlarda sınıflara göre ortaya çıkan test başarımları

Yöntem	Senaryo	Sayı	SINIF TEST BAŞARIMLARI (%)				
			SAF	ÇUKUR	TEPE	KESİNTİ	HARM.
W-ELM	FV1-TS	102	98	100	100	100	99
SB-ELM	18	21	99	100	99	99	100
ELM	20	12	99	100	98	99	97


Tüm sonuçlar göz önüne alındığında, FV kodlu Tam Set (TS) özniteliklerini kullanarak en iyi başarımlar değerlerini üreten W-ELM yöntemi tez sonucunda önerilen model olarak öne çıkmaktadır. Güç kalitesi olay sınıflandırması gerçekleştiren bu akıllı örüntü tanıma yönteminin, bütüncül bir model olarak düşünülmesi gerekmektedir. Bu nedenle bu modele ait bazı ayrıntılı incelemeler de gerçekleştirilerek, tez çalışması sonucunda elde edilen güç kalitesi olay sınıflandırıcı ürün modeli, paket olarak son kullanıcıların uygulayabileceği hale büründürülmüştür.

Önerilen modele ait tüm özelliklerin net bir şekilde ortaya koyulması amacıyla gerçekleştirilen sıradaki analizde, eğitim setindeki örnek sayısının test doğruluğuna olan etkisi incelenmiştir. Eğitim seti örnek sayısı, 1000 örnekten 100 örneğe kadar 100 örnek adımları ile azaltılarak 10 farklı eğitim seti oluşturulmuştur. Gittikçe azalan örnek sayısına sahip bu eğitim setlerine, yine 10–kat çapraz geçişleme uygulanarak en iyi model tespiti yapılmış ve bu modeller, 500 örnek içeren test verisi ile sınanmıştır. Şekil 5.30, azalan örnek sayısına sahip eğitim setlerinin ürettiği test doğruluklarını göstermektedir. ELM modelinden elde edilen en yüksek doğruluk değeri olan yaklaşık 0,985 eşik değeri olarak düşünülürse, önerilen W-ELM modeli, en az 300 örnekli veri seti kullanılarak eğitilmelidir. Bu değerin altında örnek içeren eğitim seti kullanılırsa kabul edilebilir bir sınıflandırmanın elde edilemeyeceği sonucuna ulaşılabilir.



Şekil 5.30: W-ELM eğitim verisi örnek sayısının başarıma etkisi

Önerilen model, literatürde uzunca bir süredir var olan ve sıkça kullanılan temel iki yöntem ile yapay sinir ağları (Artificial Neural Networks–ANN) ve en küçük kareler destek vektör makinesi (Least Squares Support Vector Machine–LSSVM) yöntemleri ile de kıyaslanmıştır. ELM yöntemi, tek katmanlı ileri beslemeli bir ağ mimarisi için kullanılan öğrenme algoritması olduğundan, ANN yapısı tek gizli katman içerecek şekilde tasarlanmıştır. Gizli katman nöron sayısı 20 ve etkinleştirme fonksiyonu *tanjant sigmoid* olarak belirlenmiştir. Çıkış katmanında ise doğrusal etkinleştirme fonksiyonu kullanılmıştır. Bu değerler, gerçekleştirilen bir dizi parametre belirleme deneyi sonucunda ampirik olarak belirlenmiştir. LSSVM yöntemi için kullanılan kod dizininde parametreler, öz uyarlama ile deney içerisinde belirlenmektedir. Bu yöneme ait sınıflandırma teorik alt yapısı ve daha ayrıntılı bilgi için [116] çalışmasına başvurulabilir. Burada kullanılan kod dizini de aynı çalışmanın yazarları tarafından yayınlanan MATLAB araç kutusu ile gerçekleştirilmiştir.



Şekil 5.31: W–ELM, LSSVM ve ANN kutu grafiği

Şekil 5.31, önerilen W–ELM modelinin LSSVM ve ANN başarımlarını karşılaştırmasını kutu grafiği görseli ile sunmaktadır. Burada kıyaslanan ölçüt, ortalama doğruluktur çünkü yöntemlere ait doğruluk dağılımları elde edilmesi adına her sınıflandırıcı 1000 örnekle eğitim verisi ile 10 – kat çapraz geçerleme kullanılarak değerlendirilmiştir. Grafikten görülebileceği üzere W–ELM ve LSSVM yöntemlerinin ortalama doğrulukları birbirine çok yakın değerdedir. Üretilen sonuç dağılımı ise W-ELM yönteminde daha düzgün özelliktedir.

Yöntemler arası daha detaylı bir değerlendirme için Tablo 5.22 incelenebilir. Burada, kutu grafiğinde görselleştirilen başarımların dağılımlarına ait ortalama değerler, yöntem bazında tek tek verilmiştir. Gerçekleştirilen tüm deneylerde öznitelik seti olarak FV1–TS senaryosu kullanılmıştır. Tabloda yöntem bazında, ortalama doğrulukların yüzde değerleri yanı sıra, 10–kat çapraz geçişleme sonuçlarına ait standart sapma ($\pm$) ve dağılımların varyans (Var) değerleri de gösterilmiştir.

W–ELM ve LSSVM yöntemlerine ait ortalama doğruluklar her ne kadar birbirine çok yakın değerlerde elde edilmiş olsa da eğitim sürelerini baz alan kıyas yapıldığında, LSSVM yönteminin önerilen modelin çok gerisinde kaldığı görülmektedir. Bu veri için elde edilen sonuçlarda ortaya çıkan yaklaşık 120 katlık yavaşlık, büyük veri kapsamına giren setlerde kullanıcının karşısına önemli bir dezavantaj olarak çıkacaktır. Genel bir kıyaslama ile ELM yönteminin hesapsal hız bakımından diğer yöntemlere olan üstünlüğü ortaya çıkmaktadır.

Tablo 5.22: Karşılaştırmalı başarımlar tablosu

Yöntem	Ortalama			Ortalama
	Doğruluk (%)	$\pm$	Var	Eğt. Süresi (s)
W–ELM	98,7	0,01	0,0001	1,553
LS–SVM	99,0	0,09	0,0001	186,953
ANN	92,0	0,0346	0,001	11,7337

ANN yöntemi, çalışma mantığı gereği hataların geriye yayılımı yöntemine dayanan öğrenme sistemi kullandığından döngüsel olarak çalışmaktadır. Oluşturduğu doğruluk ve genelleme değerleri de makine öğrenme yöntemlerinin gerisinde kalmaktadır. Bu sonuçlarda, ANN yöntemi başarımlarının her iki sınıflandırıcı yapısının gerisinde kaldığı görülmektedir. Eğitim süresi açısından bakıldığında, W–ELM modelinin yaklaşık 8 kat daha hızlı olduğu görülmektedir. Ayrıca, tez çalışmasında ortaya koyulan modelin çevrimiçi çalışmaya uygun olarak tasarlanması da diğer yöntemlerden farklı olarak önemli bir avantajdır.

6. TARTIŞMA VE SONUÇ

Günümüz dünyasında, bir ülkenin teknoloji alanında ve endüstriyel ortamlarda varlığını devam ettirebilmesi, enerji sahnesinde yer edinip yerini koruyabilmesi ve sahip olduğu kaynakları verimli, sürdürülebilir ve güvenilir olarak kullanıp bu kaynakları sektördeki her paydaşa kesintisiz olarak aktarabilmesi için her alanda “akıllı” teknolojileri hayata geçirmesi ve bu teknolojileri de geliştirme yolunda oluşturacağı planların baş sırasına koyması gerekmektedir. Elektrik enerjisinin hayatımızın her alanına vazgeçilemeyecek ölçüde girmesi ve tüketim miktarlarının artmasıyla birlikte, şebekedeki sürekliliğin sağlanabilmesi adına *akıllı şebeke* kavramını sistemsel olarak tesis edebilecek adımların atılması ülkemiz için de büyük önem arz etmektedir. Dağıtılmış elektrik üretimi ve enerji kaynakları, yenilenebilir enerji entegrasyonu, akıllı şehirler gibi kavramların yoğun şekilde tartışıldığı günümüzde, elektrik şebekesinin de kendisiyle çok yakından ilgili bu başlıkları destekleyecek nitelikte hizmet sunabilmesi adına üretim, iletim ve dağıtım sisteminin her adımında, güç kalitesinin üst düzeyde izlenmesi, sistemin korunması ve tüm bunları gerçekleştiren bileşenlerin sürekli olarak yenilenmesi gerekmektedir.

Elektrik enerjisinin sürekliliğinin sağlanması yönünde olumsuz etkiler ortaya koyan küresel veriler incelendiğinde, ülkeler için ciddi maddi kayıplar oluşturan sorunlar listesinde, düşük güç kalitesi kaynaklı elektriksel problemler ilk sıralarda yer almaktadır. Öngörülemeyen geniş çaplı kesintiler ve gerilim düşmeleri gibi ciddi problemler, endüstriyel ortamlarda önemli parasal kayıplar ve üretim kayıplarına yol açabilmektedir. Küresel düzeyde yapılan bu incelemelerde bahsedilen kayıpların etkisinin ülkeler arası fark gözetmediği görülmektedir. Düşük güç kalitesinin ortaya koyduğu, yıl içine yayılan kayıpların yanı sıra daha uç durumlar neticesinde ortaya çıkabilen geniş ölçekli kesintiler, ülke ekonomilerini olumsuz olarak etkilemektedir. Bu duruma ülkemiz bazında örnek teşkil eden ciddi ölçekli bir kesinti, geniş çaplı bir sistem çökmesi ile 31 Mart 2015 tarihinde yaşanmıştır.

Bu tez çalışmasında, güç kalitesi izleme sisteminden elde edilen üç faz gerilim işaretlerindeki olay içeriklerini tespit ederek, düzenli bir eğitim seti oluşturan ve bu verilerin yardımıyla makine öğrenmesi tabanlı güç kalitesi olay sınıflandırma işlemi gerçekleştiren bir akıllı örüntü tanıma modeli belirlenmeye çalışılmıştır. Güç kalitesi bozulma olay sınıflarını çukur, tepe, kesinti ve harmonik olarak etiketlenen işaretler oluşturmaktadır. Şebekeden

ölçülmüş olan saf sinüs gerilim işaretleri de referans sınıf olarak belirlenmiştir. Veri seti, Türkiye geneline coğrafi olarak yayılmış ve endüstriyel ortam ağırlıklı olmak üzere yaşam alanlarına da yoğun olarak enerji aktarımı gerçekleştiren bir çok trafo merkezinden temin edilmiştir. Oluşturulan gerçek veri seti, 2015 yılının tamamında gerçekleştirilen ölçümlerin işlenmesiyle elde edilmiştir. Çalışma boyunca gerçekleştirilen ana işlemler maddeler halinde şu şekilde özetlenebilir:

- Çalışmada kullanılan veri seti, ciddi bir analiz sürecinden geçirilmiştir. Hazır elde edilen ve herhangi bir işleme tabi tutulmamış bir veri seti kullanılmayarak, çözüm odaklı hareket edilmiştir. Geçmişe dönük, bir yıllık verilerden elde edilen ve milli güç kalitesi izleme merkezi ile gerçekleştirilen ikili görüşmeler neticesinde tanımlanan problemlerin çözümüne ışık da tutabilecek yönde tasarlanan geçerli bir veri indirme, biriktirme ve veri seti hazırlama otomasyonu geliştirilmiştir. Bu otomasyon sayesinde, izleme merkezi işleyişinde kullanılan yıllık analizlerin daha detaylı olarak yapılabilceği, olay türlerinin farklı özelliklerine göre ayrı ayrı incelenebileceği bir bütüncül sistem de oluşturulmuştur. Çalışmanın akademik sürecinin hazırlık aşamalarında üretilen bu yapı, çalışma sırasında çıkan dolaylı ve faydalı bir ürün olarak çıktılarda yerini almıştır (Bölüm 3.2.2).
- Çalışmada, Türkiye’de kullanılan standartlar ve dünya çapında kabul görmüş standartların belirlediği parametreler ışığında üretilen çözümler kullanılarak, profesyonel bir veri seti oluşturmak da amaçlanmıştır. Bu süreçte ilk hedefimiz, geniş kapsamlı bir tarama gerçekleştirip sonuç üreten otomatik bir segmentasyon süreci geliştirmek olmuştur. Böylece denetimden uzak ve kayıp ya da uç değerler içeren bir veri setinin ortaya çıkması önlenmiştir. Böylece, oluşturulan modelin öğrenme sürecinin en iyi ve denetimli şartlarda gerçekleştirilmesi sağlanmıştır. Sahada çevrimiçi de kullanılabilecek olan modelin, yüzleşebileceği olası tüm durumlara karşı cevap üretebilecek şekilde tasarlanması hedeflenmiştir (Bölüm 3).
- Çalışma sonucunda önerilen model, tüm özellikleri ile haritalanarak ve sınırları çizilerek kullanıcıya bütüncül bir *paket ürün* konsepti ile sunulmuştur. En zorlayıcı şartlarda başarımlar değerlendirilmeleri gerçekleştirilen modeller, problemin tanımlanmasından modelin önerilme sürecine kadar CRISP planlama adımları uygulanarak son haline getirilmiştir (Bölüm 4.2).

- Bir örüntü tanıma sisteminin önemli yapı taşlarından olan öznitelik çıkarım sürecinde Histogram, Permütasyon Entropi, Yerel Tepe noktaları ve belirlenen anlık zaman yöntemleri gibi güç kalitesi olay işaretleri analizinde daha önce kullanılmayan yöntemlerle oluşturulan, ayırt edicilik yeteneği yüksek fakat düşük boyutlu bir öznitelik seti elde edilmiştir. Öznitelik setini sınıflandırıcının yüksek başarılı sonuç üretmesi için güçlendirmek adına, özellikle olay tespit işleminde literatürde kanıtlanmış geleneksel yöntemler arasındaki ayrık dalgacık dönüşümünden de faydalanmıştır. Oluşturulan öznitelik seti, Fisher Vektör kodlama uygulanarak da geliştirilmiştir.
- Olay işaretlerinin sınıflandırma işleminde, karar aşamasını gerçekleştiren sınıflandırıcı yapıları makine öğrenme tabanlı yöntemlerden belirlenmiştir. Ortaya koyduğu hesapsal hız ve genelleme başarımı ile bir çok alanda kullanılan ELM yöntemine ait kapsamlı analizler gerçekleştirilmiş ve ek olarak W-ELM ve SB-ELM geliştirmeleri ile oluşturulan modellerin de üst düzeyde analizi gerçekleştirilmiştir. Güç kalitesi işaretleri sınıflandırma alanına makine öğrenme perspektifinin ELM yöntemleri ile katkısı sağlanmıştır.
- Model başarımlarını değerlendirme aşamasında, sadece 10–kat çapraz geçiş yöntemi kullanmak yerine, bu çalışmaya özgü olarak geliştirilmiş kapsamlı bir değerlendirme yapısı oluşturulmuştur. Çapraz geçiş yöntemi, öğrenme aşamasında eğitim verileri ile gerçekleştirilmiş ve test edilecek model bu aşamada en iyi doğruluk değerini üreten modeller arasından belirlenmiştir. Belirlenen modele, öğrenme aşamasında kesinlikle kullanılmayan ayrı bir test veri seti uygulanarak hem tek bir model ortaya koyulması sağlanmış hem de modelin daha güvenilir olarak elde edilmesine çalışılmıştır (Bölüm 5.2). Bu yöntem sayesinde, her model kayıt altına alınarak, ürün çıktıları oluşturulmuştur.
- Model başarımlarını değerlendirme ölçütleri olarak sadece doğruluk değerleri değil, ilgili literatürde çokça tercih edilen ve veri seti kaynaklı oluşabilecek bir takım hatalı yorumları da ortadan kaldırabilecek özellikteki duyarlılık ve özgüllük ölçütleri ile birlikte hata matrisi gösterimi de kullanılmıştır. Hata matrisleri, her algoritmaya ait tüm deneylerde oluşturulmuş ancak değerlendirme aşamasında sadece en iyi sonucu üreten durum için gösterilmiştir.

Deneysel Sonuçların Değerlendirilmesi

Bu tez çalışmasında önerilen akıllı örüntü tanıma sisteminin en önemli bileşeni, karar aşamasını oluşturan sınıflandırıcı yapısıdır. Çalışma kapsamında, güç kalitesi olay verilerini türlerine göre sınıflandırabilmek için uç öğrenme makinesi (ELM) ve bu temel algoritmanın geliştirilmiş versiyonları olan ağırlıklandırılmış uç öğrenme makinesi (W-ELM) ve Seyrek Bayes uç öğrenme makinesi (SB-ELM) algoritmaları kullanılmıştır. Veri setinin etkin olarak değerlendirilmesi adına ve modelin sınıflandırma başarımını yükseltebilmek adına, tercih edilen öznitelik setleri bir takım birleştirmelerle farklı senaryolar ile kullanılmıştır. Tüm deneylerden elde edilen bulgular incelendiğinde en iyi başarımların, hata matrisinden elde edilen yorumlar ve işlem süresi de dikkate alındığında, Fisher Vektör ile kodlanmış (102 öznitelik sayısına sahip) Tam Set (TS) özniteliklerini giriş olarak kullanan W-ELM yönteminden elde edildiği sonucuna ulaşılmıştır (Tablo 5.20).

Temel ELM yönteminin döngüsel olmayan (iterasyonsuz) hızlı bir öğrenme süreci ile çalışması, geleneksel geriye yayılım algoritması ile öğrenen ileri beslemeli ağlara göre daha iyi genelleme başarımına sahip olması ve analitik bir yöntemle çıkış ağırlıklarına ulaşması gibi olumlu özelliklerinin yanında bazı dezavantaj olarak sayılabilecek yönleri de mevcuttur. Özellikle büyük veri kapsamındaki veri setlerinde işlem yapması için gerekli olan nöron sayılarının çok fazla olabilmesi ve bunun sonucunda başarımının gizli katmandaki nöron sayısına bağlı olması durumu, pratik uygulamalar için hafıza sıkıntısı doğurabilmektedir. Ayrıca, sahip olduğu doğrusal diskriminant yaklaşıma dayanan öğrenme algoritması (en küçük kareler azalımı öğrenmesi), sınıflayıcının *ezberleme* denilen olgu ile yüzleşmesine neden olabilmektedir. Bu problem, işlenecek verilerin eğitim verilerinin karakteristiklerine uzak olduğu durumlarda daha da artan bir yapıya kavuşabilmektedir. Bu tez çalışmasında bulguları incelenen SB-ELM yöntemi sayılan bu dezavantajlardan ilkinde yani gizli katman nöron sayısı optimizasyonuna doğrudan bir çözüm bakış açısı getirmektedir. Ayrıca kullandığı kararlı öğrenme yapısı ile ezberleme problemine karşı da güçlü yanları bulunmaktadır. Çalışma kapsamında, SB-ELM yönteminin güç kalitesi literatüründe daha önce kullanılmadığı haliyle, çeşitli senaryolar için değerlendirilmesi yapılmıştır.

Farklı öznitelik veri seti senaryolarını kullanan ELM, W-ELM ve SB-ELM yöntemleri

ile elde edilen başarımların değerleri yorumlandığında, başarımların ölçütlerinin özellikle test doğruluğu anlamında birbirinden çok da uzaklaşmadığı görülmektedir. Başarımlar olarak geride kalan ELM yönteminin, en yüksek doğruluk ile arasındaki fark 0,8 olarak ölçülmüştür (Tablo 5.20). Bu analiz yüzeysel olarak böyle görünürken, hata matrislerindeki doğru sınıflandırılan olay sayılarına göre yorumlar yapıldığında, bu küçük farkların da ciddi anlamlar ifade edebileceği yorumuna ulaşılabilecektir (Tablo 5.21). Örneğin, 500 test verisi içerisinde yanlış olarak sınıflandırılan örnek sayısının 3 olması, %99,4 doğruluk değeri üretirken 7 örneğin yanlış sınıflandırılmış olması %98,6 doğruluk değeri üretmektedir ki bu değerler Tablo 5.20 ile verilen W-ELM ve ELM başarımlarıdır. Doğruluklar arasındaki fark %0,8 olsa da yanlış sınıflandırma oranı 2 kattan fazladır. İncelenen 500 veri için ortaya çıkan bu değer, 1000 veri sayısında 4 katı aşacaktır ki bu kadar olayın yanlış tahmin edilmesi neticesinde doğabilecek olumsuzluklar sistem açmaları, uyarılar, röle denetimleri ya da operatör ikazlarına olumsuz anlamda etki ederek, istenmeyen sonuçlar üretebilecektir.

Dikkate alınması gereken bir nokta da, tez çalışmasında önerilen ve güç kalitesi işaretlelerinin işlenmesinde daha öncesinde kullanılmamış olan anlık zaman bölgesi öznitelik seti sadece 3 eleman içerdiği haliyle, SB-ELM modeli (senaryo-16) ile sınıflandırıldıklarında doğruluk değerinin %98,6 olarak elde edilmesidir (Tablo 5.14). Elde edilen bu değer senaryo-20 yani bu üç özelliğe ek olarak 9 elemanlı istatistik setini birlikte kullanan ELM yöntemi doğruluğu ile aynıdır (Tablo 5.11). Ayrıca, TS özniteliklerini (51 eleman) kullanan W-ELM yöntemi doğruluk değeri de %98,4 ile bu SB-ELM senaryosunun gerisinde kalmıştır (Tablo 5.18). Büyük veri kapsamına girmeyen veri setlerinin eğitilmesi için SB-ELM yöntemi de eğitim süresinden ödün verilerek tercih edilebilir. Histogram, Permütasyon Entropi ve Yerel Tepe Nokta sayısı özniteliklerinin ana öznitelik setine katkılarının olduğu net bir biçimde görülmektedir. Bunun nedeni en iyi sonuçların büyük bir kısmı tam setin kullanılmasıyla elde edilmiş olmasına karşın, tek başına kullanıldıklarında aynı etki kendi başarımların değerlerine yansımamıştır.

Tez çalışmasında gerçekleştirilen veri seti hazırlama ve ön işleme otomasyonu, metodolojik altyapı ve bulguların elde edildiği deneysel çalışmaların tümünde MATLAB yazılım paketinde düzenlenen özgün kod dizinleri kullanılmıştır.

Gelecek Çalışmalar ve Öneriler

İleride gerçekleştirilmesi düşünülen çalışmalara ait özet bilgiler şu şekilde listelenebilir:

- Bazı süreçlerin gerçekleşmesi neticesinde, elde edilen bu kapsamlı veri setinin kamuya açık olarak internet ortamında depolanması ve ilgili alanda çalışan araştırmacılarla isim ya da bölge verilmeksizin salt güç kalitesi olay veri seti olarak paylaşılması hedeflenmektedir. Uluslararası ortamlarda son derece yaygın olan bu uygulamanın ülkemize de yaygınlaşması adına veri paylaşımı önem arz etmektedir.
- Literatürde bulunan makine öğrenme tabanlı sınıflandırıcıların ve özellikle önerilen ELM yöntemlerine ait geliştirilmiş diğer versiyonların kullanımı ile elde edilecek bir yığın (bundle) sınıflandırıcı yapısı içeren grafiksel işlemci arayüzü oluşturulması ve bu açık kaynak kodlu arayüze öznitelik çıkarım yöntemlerinin de eklenmesi ile bütüncül olarak, güç kalitesi olay verisi sınıflandırma işlemi gerçekleştiren bir yazılım aracı üretilmesi hedeflenmektedir. Detaylı grafiksel gösterimler, hata matrislerine hızlı erişim, öznitelik analizlerinin görsel olarak gerçekleştirilebilmesi gibi üstün özelliklere sahip olacak bu arayüzle, güç kalitesi işaret işleme alanında çalışan araştırmacılar için önemli bir ürün ortaya çıkarılmış olacaktır.
- Makine öğrenme algoritmalarının yanı sıra, büyük veri işlemede ve özellikle görüntü işleme uygulamalarında kullanılan *derin öğrenme* yapılarının da zaman serisi işaretlerine uyarlanarak güç kalitesi olay verilerinde kullanımının analiz edilmesi de hedeflenmektedir.
- Olay işaretlerine ait daha ayırt edici bilgileri az sayıda özellikle sunacak, dönüşüm tabanlı olmayan öznitelik çıkarım yöntemlerinin araştırılmasına devam edilecektir.
- Elde edilen 3 elemanlı HB öznitelik setini kullanan eğitilmiş bir SB-ELM modelinin öncelikle geliştirme amaçlı kullanılan bir mikro denetleyici üzerinde uygulamasının gerçekleştirilmesi hedeflenmektedir. Devamında, son kullanıcıya hitap eden daha kolay uygulanabilir bir gömülü sisteme entegrasyonu da planlarımız arasındadır.

Sonuç olarak, makine öğrenme bilim dalının, elektrik güç kalitesi işaret işleme alanına uygulaması olarak düşünülen özgün tez çalışmamızda, gerçek ölçümlerden elde edilmiş güç

kalitesi olay veri seti kullanarak, makine öğrenme yöntemlerine dayalı modeller ile sınıflandırma işlemi gerçekleştiren bir karar (*akıllı örüntü tanıma*) mekanizması oluşturulmuştur. Kullanılan modellerin, güç kalitesi izleme sistemlerine entegre edilerek, şebeke operatörlerine fayda sağlayacak analizlerde, ön teşhis ve önlem adına atacakları adımlarda ve üretilcek çözümler noktasında ortaya koyacağı bilimsel katkılar amaçlanmıştır. Çalışmamızın yukarıda bahsedilen gelecek hedefleri ile daha da zenginleştirilmesi, literatürde yapılacak başkaca çalışmalara basamak teşkil etmesi ve ülkemiz elektrik enerji kalitesi sektörüne küçük bir damla da olsa katkı sağlaması en içten dileğimizdir.

Tez Çalışmasından Üretilen Bazı Yayınlar

- Ucar, Ferhat; Alcin, Omer F.; Dandil, Besir; Ata, Fikret, 2018. ***Power Quality Event Detection Using a Fast Extreme Learning Machine***, *Energies*, **11**, no. 1: 145.
- Ucar, F., Alcin, O. F., Dandil, B., Ata, F., Cordova, J., & Arghandeh, R., 2018. ***On-line power quality events detection using weighted Extreme Learning Machine***, *6th International Istanbul Smart Grids and Cities Congress and Fair (ICSG)*, IEEE.
- Ucar, Ferhat; Alcin, Omer F.; Dandil, Besir; Ata, Fikret, 2016. ***Machine learning based power quality event classification using wavelet—Entropy and basic statistical features***, *21st International Conference on Methods and Models in Automation and Robotics (MMAR'2016)*, IEEE.
- Uçar, Ferhat; Dandıl, Beşir and Ata, Fikret, 2015. ***Classification of power quality events using extreme learning machine***, *23th Signal Processing and Communications Applications Conference (SIU'2015)*, IEEE.

KAYNAKLAR

- [1] **Colak, I., Bayindir, R., Fulli, G., Tekin, I., Demirtas, K. and Covrig, C.F.**, 2014. Smart grid opportunities and applications in Turkey, *Renew. Sustain. Energy Rev.*, **33**, 344–352.
- [2] **Ribeiro, P.F., Duque, C.A., Ribeiro, P.M. and Cerqueira, A.S.**, 2013. Power Systems Signal Processing for Smart Grids, Wiley.
- [3] **Carol L.Stimmel**, 2015. Big Data Analytics Strategies for the Smart Grid, Band 53, CRC Press.
- [4] **Bollen, M. and Gu, I.**, 2006. Signal processing of power quality disturbances, Wiley.
- [5] TC Enerji ve Tabii Kaynaklar Bakanlığı Stratejik Planı 2015-2019, URL , <http://sp.enerji.gov.tr/ETKB{~2015{~2019{~Stratejik{~Plani.pdf>.
- [6] **El-hawary, M.E.**, 2014. The Smart Grid—State-of-the-art and Future Trends, *Electr. Power Components Syst.*, **42(3-4)**, 239–250.
- [7] **Ribeiro, E., Dias, G., Barbosa, B. and Ferreira, D.**, 2016. Real-time system for automatic classification of power quality disturbances, *IEEE, Proceedings of International Conference on Harmonics and Quality of Power, ICHQP*, 908–913.
- [8] **Kartal, E.**, 2015. Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri ve Kardiyo-lojik Risk Değerlendirmesine İlişkin bir Uygulama, *Doktora tezi*, İstanbul Üniversitesi.
- [9] **TÜBA** beklenti-enbüyütme algoritması, TUBA, Türkçe Bilim Terimleri Sözlüğü, URL , <http://www.tubaterim.gov.tr/>.
- [10] **Alpaydm, E.**, 2011. Yapay öğrenme, Boğaziçi Üniversitesi Yayınevi.
- [11] **Erişti, H. and Demir, Y.**, 2010. A new algorithm for automatic classification of power quality events based on wavelet transform and SVM, *Expert Systems with Applications*, **37(6)**, 4094–4102.
- [12] **Uyar, M.**, 2008. Güç kalitesindeki bozulma türlerinin akıllı örüntü tanıma yaklaşımları ile belirlenmesi, *Doktora Tezi*, Fırat Üniversitesi, Elazığ.
- [13] **Erişti, H.**, 2010. Güç kalitesi için dalgacık dönüşümü ve destek vektör makine tabanlı bir olay tanıma tekniğinin geliştirilmesi. *Doktora Tezi*, Fırat Üniversitesi, Elazığ.
- [14] **IEEE**, 2009. IEEE Std 1159-2009 - IEEE Recommended Practice for Monitoring Electric Power Quality, IEEE.
- [15] **Barros, J. and Perez, E.**, 2006. Limitations in the Use of R.M.S. Value in Power Quality Analysis, *Instrumentation and Measurement Technology Conference Proceedings IEEE*, 2261–2264.

- [16] **Styvaktakis, E., Bollen, M. and Gu, I.**, 2000. Classification of power system events: voltage dips, in *Ninth International Conference on Harmonics and Quality of Power*, Proceedings, IEEE 745–750.
- [17] **Mahela, O.P., Shaik, A.G. and Gupta, N.**, 2015. A critical review of detection and classification of power quality events, *Renewable and Sustainable Energy Reviews*, **41**, 495–505.
- [18] **Chen, S. and Zhu, H.**, 2007. Wavelet Transform for Processing Power Quality Disturbances, *EURASIP Journal on Advances in Signal Processing*, **2007(1)**, 047695.
- [19] **Barros, J., Diego, R.I. and De Apraiz, M.**, 2012. Applications of wavelets in electric power quality: Voltage events, *Electric Power Systems Research*, **88**, 130–136.
- [20] **Erişti, H., Yıldırım, Ö., Erişti, B. and Demir, Y.**, 2014. Automatic recognition system of underlying causes of power quality disturbances based on S-Transform and Extreme Learning Machine, *International Journal of Electrical Power & Energy Systems*, **61**, 553–562.
- [21] **Erişti, H., Yıldırım, Ö., Erişti, B. and Demir, Y.**, 2013. Optimal feature selection for classification of the power quality events using wavelet transform and least squares support vector machines, *International Journal of Electrical Power & Energy Systems*, **49**, 95–103.
- [22] **Barrera Nunez, V., Gu, I.Y.H., Bollen, M.H. and Melendez, J.**, 2010. Feature characterization of power quality events according to their underlying causes, in *Proceedings of 14th International Conference on Harmonics and Quality of Power - ICHQP 2010*, IEEE, 1–8.
- [23] **Styvaktakis, E., Bollen, M. and Gu, I.**, 2002. Expert system for classification and analysis of power system events, *IEEE Transactions on Power Delivery*, **17(2)**, 423–428.
- [24] **Styvaktakis, E., Bollen, M. and GU, I.**, 2002. Automatic Classification of Power System Events Using RMS Voltage Measurements, *IEEE, Power Eng. Soc. Summer Meet.*, **2**, 824–829.
- [25] **Bollen, M.H.J., Gu, I.Y.H., Axelberg, P.G.V. and Styvaktakis, E.**, 2007. Classification of underlying causes of power quality disturbances: Deterministic versus statistical methods, *Eurasip Journal on Advances in Signal Processing*.
- [26] **Styvaktakis, E., Bollen, M. and Gu, I.**, 2001. Expert system for voltage dip classification and analysis, in *2001 Power Engineering Society Summer Meeting. Conference Proceedings*, IEEE, 671–676, vol.1.
- [27] **Gunal, S., Gerek, O.N., Ece, D.G. and Edizkan, R.**, 2009. The search for optimal feature set in power quality event classification, *Expert Systems with Applications*, **36(7)**, 10266–10273.
- [28] **Ozgonenel, O., Yalcin, T., Guney, I. and Kurt, U.**, 2013. A new classification for power quality events in distribution systems, *Electric Power Systems Research*, **95**, 192–199.

- [29] **Manjula, M. and Sarma, A.**, 2012. Comparison of Empirical Mode Decomposition and Wavelet Based Classification of Power Quality Events, *Energy Procedia*, **14**, 1156–1162.
- [30] **Shareef, H., Mohamed, A. and Ibrahim, A.A.**, 2013. An image processing based method for power quality event identification, *International Journal of Electrical Power & Energy Systems*, **46**, 184–197.
- [31] **Morales, J., Orduña, E. and Rehtanz, C.**, 2014. Classification of lightning stroke on transmission line using multi-resolution analysis and machine learning, *International Journal of Electrical Power & Energy Systems*, **58**, 19–31.
- [32] **Ribeiro, M.V., Marques, C.A.G., Duque, C.A., Cerqueira, A.S. and Pereira, J.L.R.**, 2007. Detection of Disturbances in Voltage Signals for Power Quality Analysis Using HOS, *EURASIP Journal on Advances in Signal Processing*, **2007(1)**, 059786.
- [33] **Meher, S.K. and Pradhan, A.K.**, 2010. Fuzzy classifiers for power quality events analysis, *Electric Power Systems Research*, **80(1)**, 71–76.
- [34] **Kapoor, R. and Saini, M.K.**, 2011. Hybrid demodulation concept and harmonic analysis for single/multiple power quality events detection and classification, *International Journal of Electrical Power & Energy Systems*, **33(10)**, 1608–1622.
- [35] **Saini, M.K. and Kapoor, R.**, 2012. Classification of power quality events – A review, *International Journal of Electrical Power & Energy Systems*, **43(1)**, 11–19.
- [36] **Azam, M., Tu, F., Pattipati, K. and Karanam, R.**, 2004. A Dependency Model-Based Approach for Identifying and Evaluating Power Quality Problems, *IEEE Transactions on Power Delivery*, **19(3)**, 1154–1166.
- [37] **Li, J.q., Wang, S.l., Niu, C.l. and Liu, J.z.**, 2008. Research and Application of Data Mining Technique in Power Plant, in *2008 International Symposium on Computational Intelligence and Design*, IEEE, 250–253.
- [38] **Livani, H., Evrenosoglu, C.Y. and Centeno, V.A.**, 2013. A machine learning-based faulty line identification for smart distribution network, in *2013 North American Power Symposium (NAPS)*, IEEE, 1–5.
- [39] **Moravej, Z., Banihashemi, S. and Velayati, M.**, 2009. Power quality events classification and recognition using a novel support vector algorithm, *Energy Conversion and Management*, **50**, 3071–3077.
- [40] **Santiago Cerqueira, A., Ferreira, D., Ribeiro, M.V. and Duque, C.A.**, 2008. Power quality events recognition using a SVM-based method, *Electric Power Systems Research*, **78**, 1546–1552.
- [41] **Subasi, A., Yilmaz, A.S. and Tufan, K.**, 2011. Detection of generated and measured transient power quality events using Teager Energy Operator, *Energy Conversion and Management*, **52(4)**, 1959–1967.

- [42] **Morais, J., Pires, Y., Cardoso Jr., C. and Klautau, A.**, 2010. A Framework for Evaluating Automatic Classification of Underlying Causes of Disturbances and Its Application to Short-Circuit Faults, *IEEE Transactions on Power Delivery*, **25(4)**, 2083–2094.
- [43] **Martinez-figueroa, G.D.E.J., Morinigo-sotelo, D., Zorita-lamadrid, A.L., Morales-velazquez, L., Romero-troncoso, R.D.E.J. and Member, S.**, 2017. FPGA-Based Smart Sensor for Detection and Classification of Power Quality Disturbances Using Higher Order Statistics, *IEEE Access*, 14259–14274.
- [44] **Kim, D.I., Chun, T.Y., Yoon, S.H., Lee, G. and Shin, Y.J.**, 2017. Wavelet-based event detection method using PMU data, *IEEE Transactions on Smart Grid*, **8(3)**, 1154–1162.
- [45] **Wu, M., Member, S., Xie, L. and Member, S.**, 2017. Online Detection of Low-Quality Synchrophasor Measurements : A Data Driven Approach, *IEEE Transactions on Power Systems*, **32(4)**, 2817–2827.
- [46] **Biscaro, A.A.P., Pereira, R.A.F., Kezunovic, M. and Mantovani, J.R.S.**, 2016. Integrated Fault Location and Power-Quality Analysis in Electric Power Distribution Systems, *IEEE Transactions on Power Delivery*, **31(2)**, 428–436.
- [47] **Li, J., Teng, Z., Tang, Q. and Song, J.**, 2016. Detection and Classification of Power Quality Disturbances Using Double Resolution S-Transform and DAG-SVMs, in *IEEE Transactions on Instrumentation and Measurement IEEE*, 1–11.
- [48] **Borras, M.D., Bravo, J.C. and Montano, J.C.**, 2016. Disturbance Ratio for Optimal Multi-Event Classification in Power Distribution Networks, *IEEE Transactions on Industrial Electronics*, **0046(c)**, 1–1.
- [49] **Albu, M.M., Sănduleac, M. and Stănescu, C.**, 2017. Syncretic Use of Smart Meters for Power Quality Monitoring in Emerging Networks, *IEEE Transactions on Smart Grid*, **8(1)**, 485–492.
- [50] **Liu, Y., Geng, G., Gao, S. and Xu, W.**, 2016. Non-Intrusive Energy Use Monitoring for A Group of Electrical Appliances, *IEEE Transactions on Smart Grid*, **3053(c)**, 1–1.
- [51] **Samantaray, S., ACHLERKAR, P. and Manikandan, M.S.**, 2016. Variational Mode Decomposition and Decision Tree Based Detection and Classification of Power Quality Disturbances in Grid-Connected Distributed Generation System, *IEEE Transactions on Smart Grid*, **3053(c)**, 1–1.
- [52] **Borges, F.A.S., Fernandes, R.A.S., Silva, I.N. and Silva, C.B.S.**, 2016. Feature Extraction and Power Quality Disturbances Classification Using Smart Meters Signals, *IEEE Transactions on Industrial Informatics*, **12(2)**, 824–833.
- [53] **Huang, G., Huang, G.B., Song, S. and You, K.**, 2015. Trends in extreme learning machines: A review, *Neural Networks*, **61**, 32–48.
- [54] **Duda, R.O., Hart, P.E. and Stork, D.G.**, 2001. Pattern Classification, John Wiley, New York.

- [55] **Zong, W., Huang, G.B. and Chen, Y.**, 2013. Weighted extreme learning machine for imbalance learning, *Neurocomputing*, **101**, 229–242.
- [56] **Luo, J., Vong, C.M. and Wong, P.K.**, 2014. Sparse Bayesian extreme learning machine for multi-classification, *IEEE Trans. Neural Networks Learn. Syst.*, **25(4)**, 836–43.
- [57] **IEC**, 2003. Electromagnetic Compatibility (EMC), Bolum 4-30, Power Quality Measurement, IEC 61000-4-30, Switzerland.
- [58] **Unlusoy, B.**, 2013. Enerji kalitesi, TS EN 50160 standardı ve ülkemizdeki uygulamaları, *III. Elektrik Tesisat Ulusal Kongre ve Sergisi*, 21-24 Kasım, İzmir.
- [59] **IEEE**, 1996. The IEEE standard dictionary of electrical and electronics terms, 6th edition.
- [60] **Tan, R.H. and Ramachandaramurthy, V.K.**, 2015. A comprehensive modeling and simulation of power quality disturbances using MATLAB/SIMULINK, InTech Publishing.
- [61] **Dugan, R.C., McGranaghan, M.F., Santoso, S. and Beaty, H.W.**, 2012. Electrical power systems quality, 3rd edition, McGraw Hill, USA.
- [62] **Math H. Bollen**, 1999. Understanding Power Quality Problems: Voltage Sags and Interruptions, Wiley-IEEE Press.
- [63] **Arrillaga, J. and Watson, N.R.**, 2003. Power System Harmonics, John Wiley & Sons, Ltd, Chichester, UK.
- [64] **Efe, S.B.**, 2006. Güç sistemlerinde harmonikler ve harmoniklerin analizi, *Yüksek lisans Tezi*, İnönü Üniversitesi, Malatya.
- [65] **Owen, E.**, 1998. A history of harmonics in power systems, *IEEE Industry Applications Magazine*, **4(1)**, 6–12.
- [66] **Kocatepe Celal**, 2003. Elektrik tesislerinde harmonikler, Birsen Yayınevi, İstanbul.
- [67] **H. K. Anwar**, 2009. Gerilim beslemeli ve akım beslemeli üç fazlı şönt aktif güç filtresinin karşılaştırması ve simülasyonu, *Yüksek lisans Tezi*, Gazi Üniversitesi, Ankara.
- [68] **BALCI, M.E.**, 2009. Harmonik üreten yüklerin belirlenmesi ve optimum kompanzasyon için yeni bir güç ifadesi, *Doktora Tezi*, Gebze İleri teknoloji Enstitüsü, Kocaeli.
- [69] **Caner, F.**, 2006. Güç sistemlerinde harmonikler ve filtrelemelerin incelenmesi, *Yüksek lisans Tezi*, Kırıkkale Üniversitesi.
- [70] <http://www.eigm.gov.tr/tr-TR/Enerji-Dagitim-Sirketleri-Haritasi>, Enerji Dagitim Sirketleri Haritasi, 27.03.2018.

- [71] **CEER**, 2016. 6th CEER benchmarking report on the quality of electricity and gas supply 2016, in 6th CEER benchmarking report on the quality of electricity and gas supply, CEER.
- [72] **Targosz, R. and Chapman, D.**, 2015. Application Note The Cost Of Poor Power Quality, *ECI Publication*, (September), 41.
- [73] **CEER**, 2012. Guidelines of Good Practice on the Implementation and Use of Voltage Quality Monitoring Systems for Regulatory Purposes.
- [74] **Chapman, D.**, 2001. The Cost of Poor Power Quality, *European Copper Institute (ECI)*, (0b), 8.
- [75] **Hofmann, M., Slejeseth, H., Volden, G.H. and Kjølle, G.**, 2010. Study on Estimation of Costs due to Electricity Interruptions and Voltage Disturbances, *SINTEF Energy Research*, (December), 1–72.
- [76] **Hans De Keulenaer**, 2004. The hidden cost of poor power quality, *Power Quality Application Guide*, (0b), 8.
- [77] **Teke, A., Emin Meral, M., Tumay, M. and Cagatay Bayindir, K.**, 2009. Türkiye'nin Güney Sanayi Bölgelerindeki Güç Kalitesi Üzerine Bir Araştırma, *Uludağ U Muh.-Mim. F. Dergisi*, **14(2)**, 23–31.
- [78] **Darrow, Ken ve Bourgeois, T.**, 2005. The Role of Distributed Generation in Power Quality and Reliability, *Energy Environ. Anal.*, (December), 118.
- [79] **Atalık, T.**, 2007. İnternet Üzerinden Haberleşen Güç Kalitesi Monitör Cihazı Donanım Tasarımı, *Yüksek lisans Tezi*, Hacettepe Üniversitesi, Ankara.
- [80] **Naderian, S. and Salemnia, A.**, 2017. Method for classification of PQ events based on discrete Gabor transform with FIR window and T2FK-based SVM and its experimental verification, *IET Generation, Transmission & Distribution*, **11(1)**, 133–141.
- [81] **Uyar, M., Yildirim, S. and Gencoglu, M.T.**, 2008. An effective wavelet-based feature extraction method for classification of power quality disturbance signals, *Electr. Power Syst. Res.*, **78(10)**, 1747–1755.
- [82] **TEİAŞ**, 2018. Türkiye Elektrik Üretim-İletim İstatistikleri, URL <https://www.teias.gov.tr/tr/turkiye-elektrik-uretim-iletim-istatistikleri>.
- [83] **Yıldırım, Ö.**, 2015. İnternet Tabanlı Güç Kalitesi İzleme Sisteminin Donanımsal Ve Yazılımsal Olarak Gerçekleştirilmesi, *Doktora Tezi*, Fırat Üniversitesi, Elazığ.
- [84] **Güder, M.**, 2009. Data Mining Methods For Clustering Power Quality Data Collected Via Monitoring Systems Installed On The Electricity Network, *Yüksek lisans Tezi*, Orta Doğu Teknik Üniversitesi, Ankara.
- [85] **Daubechies, I.**, 1992. Ten lectures on wavelets, 1st edition, CBMS-NSF Regional Conference Series in Applied Mathematics.

- [86] **Strang, G. and Nguyen, T.**, 1997. Wavelets and filter banks, 2nd edition, Wellesley-Cambridge Press.
- [87] **Buhan, S.**, 2009. Güç Kalitesi Parametrelerinin Dalgacık Çözümleme Yöntemleri Kullanılarak Belirlenmesi, *Yüksek Lisans Tezi*, Hacettepe Üniversitesi, Ankara.
- [88] **Türkoğlu, İ.**, 2003. Durağan Olmayan İşaretler İçin Zaman-Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma, *Doktora Tezi*, Fırat Üniversitesi, Elazığ.
- [89] **Mikhail V. Volkenstein**, 2009. Entropy and Information, Springer.
- [90] **Ucar, F., Alcin, O., Dandil, B. and Ata, F.**, 2018. Power quality event detection using a fast extreme learning machine, *Energies*, **11(1)**.
- [91] **Kanitpanyacharoen, W. and Premrudeepreechacharn, S.**, 2004. Power quality problem classification using wavelet transformation and artificial neural networks, in *IEEE Region 10 Conference TENCN 2004*, IEEE 252–255.
- [92] **Tuljapurkar, M. and Dharme, A.**, 2014. Wavelet Based Signal Processing Technique for Classification of Power Quality Disturbances, in *2014 Fifth International Conference on Signal and Image Processing IEEE*, 337–342.
- [93] **Mallat, S.G. and Peyre, G.**, 2009. A wavelet tour of signal processing : the sparse way, Elsevier/Academic Press.
- [94] **William H. Press, Teukolsky, S.A., Vetterling, W.T. and Flannery, B.P.**, 2007. Numerical Recipes: The Art of Scientific Computing, third edition, Cambridge University Press.
- [95] **Pearson, K.**, 1895. Contributions to the Mathematical Theory of Evolution. II. Skew Variation in Homogeneous Material, *Philos. Trans. R. Soc. A*.
- [96] **Sturges, H.A.**, 1926. The Choice of a Class Interval, *J. Am. Stat. Assoc.*, **21(153)**, 65–66.
- [97] **Scott, D.W.**, 2009. Sturges' rule, *Wiley Interdiscip. Rev. Comput. Stat.*, **1(3)**, 303–306.
- [98] **Nicolaou, N. and Georgiou, J.**, 2012. Detection of epileptic electroencephalogram based on Permutation Entropy and Support Vector Machines, *Expert Syst. Appl.*, **39(1)**, 202–209.
- [99] **Li, X., Ouyang, G. and Richards, D.A.**, 2007. Predictability analysis of absence seizures with permutation entropy, *Epilepsy Res.*, **77(1)**, 70–74.
- [100] **Scholkmann, F., Boss, J. and Wolf, M.**, 2012. An efficient algorithm for automatic peak detection in noisy periodic and quasi-periodic signals, *Algorithms*, **5(4)**, 588–603.
- [101] **Hazza, A. and Shoaib, M.**, 2013. An Overview of Feature-Based Methods for Digital Modulation Classification, *Conf. Commun. Signal Process. their Appl.*

- [102] **Jayasree, T., Devaraj, D. and Sukanesh, R.**, 2010. Power quality disturbance classification using Hilbert transform and RBF networks, *Neurocomputing*, **73(7-9)**, 1451–1456.
- [103] **Aslan, M., Sengur, A., Xiao, Y., Wang, H., Ince, M.C. and Ma, X.**, 2015. Shape feature encoding via Fisher Vector for efficient fall detection in depth-videos, *Appl. Soft Comput. J.*, **37**, 1023–1028.
- [104] **Döngel, T.**, 2016. Büyük İmge Veri Tabanlarında Erişim İçin Yarı Eğitimli Görsel Temsiller, *Yüksek Lisans Tezi*, Osmangazi Üniversitesi, Eskişehir.
- [105] **Budak, Ü.**, 2017. Uydu Görüntülerinde Havaalanı Tespit Edilmesi, *Doktora Tezi*, Fırat Üniversitesi, Elazığ.
- [106] **Alcin, O.F., Siuly, S., Bajaj, V., Guo, Y., Sengur, A. and Zhang, Y.**, 2016. Multi-category EEG signal classification developing time-frequency texture features based Fisher Vector encoding method, *Neurocomputing*.
- [107] **Gopinath, R., Kumar, C.S. and Ramachandran, K.I.**, 2017. Fisher vector encoding for improving the performance of fault diagnosis in a synchronous generator, *Measurement*, **111(July)** 264–270.
- [108] **Bishop, C.M.**, 2006. Pattern Recognition and Machine Learning, Springer.
- [109] **Shearer, C.**, 2000. The CRISP-DM model: The New Blueprint for Data Mining, *J. Data Warehous.*, **5(4)**, 13–22.
- [110] **Huang, G.B., Zhu, Q.Y. and Siew, C.K.**, 2006. Extreme learning machine: Theory and applications, *Neurocomputing*, **70(1-3)**, 489–501.
- [111] **Liu, X., Lin, S., Fang, J. and Xu, Z.**, 2015. Is extreme learning machine feasible? A theoretical assessment (part I)., *Neural Networks Learn. Syst. IEEE Trans.*, **26(1)**, 21–34.
- [112] **Penrose, R.**, 1955. A generalized inverse for matrices, *Math. Proc. Cambridge Philos. Soc.*, **51(03)**, 406 – 413.
- [113] **Li, K., Kong, X., Lu, Z., Wenyin, L. and Yin, J.**, 2014. Boosting weighted ELM for imbalanced learning, *Neurocomputing*, **128**, 15–21.
- [114] **Sokolova, M. and Lapalme, G.**, 2009. A systematic analysis of performance measures for classification tasks, *Information Processing and Management*, **45(4)**, 427–437.
- [115] **Ferri, C., Hernández-Orallo, J. and Modroiu, R.**, 2009. An experimental comparison of performance measures for classification, *Pattern Recognition Letters*, **30(1)**, 27–38.
- [116] **Suykens, J.A.K., Van Gestel, T., De Brabanter, J., De Moor, B. and Vandewalle, J.**, 2002. Least Squares Support Vector Machines, World Scientific Publishing.

ÖZGEÇMİŞ

Adı Soyadı : Ferhat Uçar
Doğum Yeri : Adana/Seyhan
Doğum Tarihi : 22.09.1983
Medeni Hali : Evli, Bir çocuk babası
Yabancı Dili : İngilizce

Lise : Çukurova Elektrik Anadolu Teknik Lisesi, 1997 - 2001, Adana.

Lisans : Fırat Üniversitesi Teknik Eğitim Fakültesi
Elektrik Öğretmenliği Bölümü 2002 - 2006

Yüksek Lisans : Fırat Üniversitesi Fen Bilimleri Enstitüsü
Elektrik Eğitimi Ana Bilim Dalı 2010 - 2012

Doktora : Fırat Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Ana Bilim Dalı 2013-

Deneyimler : 2006 - 2007, Mühendis, Mis Holding-Misland Eğlence Merkezi
Elazığ
: 2007, Satış Mühendisi, HP Kurumsal
Bölge Onarım Merkezi, Adana
: 2007 - 2009 Proje Mühendisi, Schneider Electric Adana Bölge
Emsan Elektrik
: 2009 - Halen, Araştırma Görevlisi, Fırat Üniv. Teknik Eğt. Fakültesi
Elektrik Eğitimi Bölümü

İletişim : Fırat Üniversitesi Teknoloji Fakültesi
Enerji Sistemleri Mühendisliği Bölümü, 23119 - Elazığ
Tel : +90 424 237 00 00 - 7660
eposta: fucar@firat.edu.tr,
ferhatucar01@gmail.com