



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



YAPAY ZEKA YÖNTEMLERİ
KULLANILARAK ELEKTRİK
TESİSLERİNDE GÜÇ KALİTESİ
PROBLEMLERİNİN SINIFLANDIRILMASI

Tuğçe YEŞİLYURT

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Aralık-2021
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Tuğçe YEŞİLYURT tarafından hazırlanan “YAPAY ZEKA YÖNTEMLERİ KULLANILARAK ELEKTRİK TESİSLERİNDE GÜÇ KALİTESİ PROBLEMLERİNİN SINIFLANDIRILMASI” adlı tez çalışması 30/12/2021 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Unvanı Adı SOYADI

Danışman

Unvanı Adı SOYADI

Üye

Unvanı Adı SOYADI

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Tuğçe YEŞİLYURT

Tarih: 30.12.2021

ÖZET

YÜKSEK LİSANS

YAPAY ZEKA YÖNTEMLERİ KULLANILARAK ELEKTRİK TESİSLERİNDE GÜÇ KALİTESİ PROBLEMLERİNİN SINIFLANDIRILMASI

Tuğçe YEŞİLYURT

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman: Doç. Dr. Bahadır AKBAL

2021, 89 Sayfa

Jüri

**Doç. Dr. Bahadır AKBAL
Doç. Dr. Nurettin ÇETİNKAYA
Dr. Öğr. Üyesi M. Üsâme ÖZİÇ**

Güç sistemlerinin işletilmesinde tüketiciye ulaşan enerjinin kaliteli, güvenli ve kesintisiz olması hedeflenmektedir. Enerji ihtiyacının her geçen gün artması ve bununla birlikte ortaya çıkan sorunların en önemli nedenlerden biri de sistemin kararlılık problemi. Özellikle nüfus ve sanayileşmenin artmasıyla giderek artan enerji talebi güç sistemlerinin daha ağır şartlarda çalıştırılmasını beraberinde getirmektedir. Bu da hatların fazla yüklenmesine ve iletim hatlarında sıkışıklığa neden olmaktadır. Yeni iletim hatlarının kurulum maliyetlerinin yüksek olması nedeniyle sistemler maksimum kapasitelerinde ve kararlılık sınırlarında çalıştırılmaktadır.

Tez çalışmasında gerilim kararlılığını etkileyen faktörler ve bu faktörlerden biri olan güç kalitesi problemleri üzerinde durulmuştur. Problemin tanımlanması, çözümlenebilmesi için kritik önem taşımaktadır. Bu nedenle MATLAB ortamında matematiksel eşitlikler kullanılarak şebekede gerilim kararlılığını bozucu sinyaller modellenmiştir. Üretilen sinyallerin sınıflandırılması ile şebekede meydana gelen bozukluk tespit edilebildiğinden sistemin kararlılığını sağlayacak adımların atılması da kolaylaşacaktır. Sınıflandırma işleminde K-En Yakın Komşuluk Algoritması (KNN), Destek Vektör Makineleri (DVM), karar ağaçları ve Yapay Sinir Ağları (YSA) gibi makine öğrenmesi yöntemleri kullanılmıştır. Özellik çıkarma işlemi için Fourier Dönüşümü (FD), S-Dönüşümü (SD), Hilbert Huang Dönüşümü (HHD), Dalgacık Dönüşümü (DD, Wavelet Transform) ve Ayrık Dalgacık Dönüşümü (ADD, Discrete Wavelet Transform) yaygın olarak kullanılmaktadır. Bu çalışmada üretilen sinyallerden öncelikle enerji, standart sapma, mutlak değerin ortalaması, eğrilik, basıklık, ortalama (medyan) mutlak sapma, ortalama frekans, medyan frekans, toplam harmonik bozulma, rms, rms oranının tepe büyüklüğü ve entropi olmak üzere 13 adet özellik çıkarılıp sınıflandırma algoritmalarına verilmiştir. Ayrıca ADD yöntemi ile de özellik çıkarımı yapılmış ve sonuçlar karşılaştırmalı olarak verilmiştir. Yapılan çalışma sonucunda dalgacık dönüşümü yapılmadan, 13 adet özellik çıkarılarak yapılan sınıflandırmada Kübik DVM ile %94.4 ile en yüksek doğruluk bulunmuştur.

Anahtar Kelimeler: Dalgacık Dönüşümü, Destek Vektör Makinaları, Gerilim Kararlılığı, Güç Kalitesi Problemleri, Güç Sistemlerinde Kararlılık, Makine Öğrenmesi, Sınıflandırma, Yapay Sinir Ağları

ABSTRACT

MS THESIS

CLASSIFICATION OF POWER QUALITY PROBLEMS IN POWER SYSTEMS USING AI METHODS

Tuğçe YEŞİLYURT

**Konya Technical University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering**

Advisor: Assoc.Prof.Dr. Bahadır AKBAL

2021, 89 Pages

**Jury
Assoc.Prof.Dr. Bahadır AKBAL
Assoc.Prof.Dr. Nurettin ÇETİNKAYA
Asst.Prof.Dr. M. Üsâme ÖZİÇ**

In the operation of power systems, it is aimed that the energy reaching the consumer is of high quality, safe and uninterrupted. One of the most important reasons for the increase in energy demand and the problems that arise with it is the stability problem of the system. Increasing energy demand, especially with the increase in population and industrialization, brings power systems to be operated under more severe conditions. This causes the lines to be overloaded and congestion in the transmission lines. Due to the high installation costs of new transmission lines, the systems are operated at their maximum capacity and stability limits.

In the thesis, the factors affecting voltage stability and power quality problems, which is one of these factors, are emphasized. Defining the problem is critical for its resolution. For this reason, signals that disturb the voltage stability in the network are modeled by using mathematical equations in MATLAB environment. By classifying the generated signals, it is aimed to detect the decay signals occurring in the network. Since the malfunction in the system can be detected with the created model, it will be easier to take steps to ensure the stability of the system. In the classification process, both machine learning methods such as K-Nearest Neighborhood Algorithm (KNN), Support Vector Machines (SVM), decision trees and Artificial Neural Networks (ANNs) were used. Fourier Transform (FT), S-Transform (ST), Hilbert Huang Transform (HHD), Wavelet Transform (WT) and Discrete Wavelet Transform (DWT, Discrete Wavelet Transform) are widely used for feature extraction. In this study, 13 features such as energy, standard deviation, average of absolute value, curvature, kurtosis, average (median) absolute deviation, average frequency, median frequency, total harmonic distortion, rms, peak size of rms ratio and entropy were extracted from the signals produced in this study and given to machine learning classifiers and ANNs. In addition, feature extraction was performed with the DWT method and the results were given comparatively. As a result of the study, the highest accuracy of 94.4% was found with Cubic SVM in the classification made by removing 13 features without wavelet transform.

Keywords: Artificial Neural Networks, Classification, Machine Learning, Power Quality Problems, Stability in Power Systems, Support Vector Machines, Voltage Stability, Wavelet Transform

ÖNSÖZ

Yüksek lisans tez çalışmalarım süresince değerli bilgileri ve kıymetli katkılarıyla beni yönlendiren danışmanım Doç. Dr. Bahadır AKBAL'a, eğitim hayatımın her aşamasında bana emek vermiş değerli hocalarıma, bu süreçte destekleriyle beni hiçbir zaman yalnız bırakmayan değerli arkadaşlarıma ve her türlü maddi ve manevi desteğini esirgemeyen aileme teşekkür ederim.

Tuğçe YEŞİLYURT
KONYA-2021



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
2.1. Güç Sistemlerinde Kararlılık ile İlgili Çalışmalar	3
2.2. Güç Kalitesi Bozunumlarının Sınıflandırılması ile İlgili Çalışmalar	6
3. MATERYAL VE YÖNTEM.....	10
3.1. Güç Sistemlerinde Kararlılık	10
3.1.1. Rotor açısı kararlılığı	11
3.1.2. Frekans kararlılığı	14
3.1.3. Gerilim kararlılığı	15
3.2. Elektrik Şebekelerinde Gerilim Kararlılığı.....	16
3.2.1. Gerilim kararlılığını etkileyen faktörler ve gerilim kararsızlığına karşı alınabilecek önlemler	19
3.3. Güç Kalitesi Problemleri	25
3.3.1. Güç kalitesi olaylarının sınıflandırılması.....	29
3.4. Makine Öğrenmesi Yöntemleri	38
3.4.1. Denetimli öğrenme	40
3.4.2. Denetimsiz öğrenme	42
3.4.3. Yarı denetimli öğrenme	43
3.4.4. Pekiştirmeli öğrenme (Reinforcement learning).....	43
3.5. Sınıflandırma Algoritmaları.....	44
3.5.1. Destek vektör makineleri (DVM)	44
3.5.2. K en yakın komşu algoritması (KNN)	44
3.5.3. Karar ağaçları.....	45
3.5.4. Rastgele orman algoritması	45
3.5.5. Topluluk öğrenme modelleri (Ensemble models)	45
3.6. Yapay Sinir Ağları (YSA)	46
3.6.1. Yapay sinir ağlarında öğrenme	50
3.6.2. Yapay sinir ağlarının aktivasyon fonksiyonları	51
3.7. Performans Metrikleri.....	55
3.7.1. Doğruluk	56
3.7.2. Hata.....	57
3.7.3. Duyarlılık	57
3.7.4. Özgünlük.....	57
3.7.5. Kesinlik.....	57

3.7.6. F1 skoru	58
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	59
4.1. Kararlılığı Bozucu Sinyallerin Elde Edilmesi	59
4.2. Özellik Çıkarımı	60
4.3. Çalışmanın Uygulanması ve Sınıflandırma Yöntemlerinin Karşılaştırılması	62
4.3.1. Daubechies dalgacık modellerinin karşılaştırılması	68
5. SONUÇLAR VE ÖNERİLER	82
5.1 Sonuçlar	82
5.2 Öneriler	84
KAYNAKLAR	85



SİMGELER VE KISALTMALAR

Simgeler

AC	: Alternatif akım
b	: Bias
cA	: Yaklaşım katsayıları
cD	: Detay katsayıları
DC	: Doğru akım
e	: Hata
H	: Atalet
Hz	: Hertz
HiD	: Dalgacık filtresi
LoD	: Ölçeklendirme filtresi
p1, p2, p3	: Aktif güce ait yük bileşenlerinin oranı
P	: Aktif güç
P _M	: Üretilen gücü
P _L	: Yükün gücü
pu	: Per-unit
S	: Görünür güç
V ₁	: Hat başı gerilimi,
V ₂	: Hat sonu gerilimini
δ	: Senkron makinanın rotorları arasındaki açı
δ_m	: Motorun iç açısı
δ_g	: Generatörün iç açısı
δ_h	: Generatör ile motorun uç gerilimleri arasındaki fark
y	: Bağımlı değişken
w	: YSA için ağırlık parametresi
ω_s	: Senkron hız
Q	: Reaktif güç

Kısaltmalar

ADD	: Ayrık Dalgacık Dönüşümü
BEDS	: Batarya Enerji Depolama Sistemleri
ÇKA	: Çok Katmanlı Algılayıcı
db1, db2, db3,	
db4, db8	: Daubechies Dalgacık Tipleri
DD	: Dalgacık Dönüşümü
DN	: Doğru Negatif
DÜ	: Dağıtılmış Üretim
DÜK	: Dağıtık Üretim Kaynağı
DP	: Doğru Pozitif
DVM	: Destek Vektör Makinaları
EPRI	: Electric Power Research Institute
FACTS	: Esnek iletim cihazları
FD	: Fourier Dönüşümü
FPGA	: Alanda programlanabilir kapı dizisi
GA	: Genetik Algoritma
HHD	: Hilbert- Huang Dönüşümü

KNN	: K-En Yakın Komşu Algoritması
KSFD	: Kısa Süreli Fourier Dönüşümü
MLS	: En Küçük Kareler Yöntemi
PSO	: Parçacık Sürü Optimizasyonu
PSO-DVM	: Dalgacık dönüşümü tabanlı bir PSO
PSS	: Güç Sistemi Dengeleyici
RBF	: Radial Basis Function (Radyal tabanlı bir ağ)
SD	: S Dönüşümü
SİS	: Sıralı İleri Seçim
SNR	: Sinyal-Gürültü Oranı
SSSC	: Statik Senkron Seri Kompanzatör
STATCOM	: Statik Senkron Kompanzatör
SVC	: Statik Var Kompanzatör
TCPAR	: Tristör Kontrollü Faz Açısı Düzenleyicisi
TCSC	: Tristör Kontrollü Seri Kapasitör
TCVSC	: Tristör Kontrollü Statik Var Kompanzatör
TEİAŞ	: Türkiye Elektrik İletim A.Ş.
UPFC	: Birleşik Güç Akış Denetleyicisi
YAKD	: Yük Altında Kademe Değiştiriciler
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları
ZAKA	: Zaman Alanı Karakteristik Analizi

1. GİRİŞ

Sanayileşmenin, teknoloji kullanımının ve nüfusun artmasıyla elektrik enerjisine olan talep günden güne artmaktadır. Artan bu talep doğrultusunda güç sistemleri de genişlemektedir. Artan talep ve şebekelerdeki büyüme neticesinde güç dengesinin korunması, sistemin kabul edilebilir sınırlarda çalıştırılabilir olması gerekmektedir.

Tüketiciye sağlanan enerjinin kaliteli, güvenilir ve kesintisiz olması kritik önem arz etmektedir. Günümüzde iletim ve dağıtım sistemlerinde güvenilirlik çok yüksek seviyelere erişmesine karşın sistemde meydana gelen arızalar hem tüketici tarafında hem de şebeke tarafında sorunlara sebep olmaktadır. Güç sistemi kararlılığının bozulması, sistemin güvenli çalışması bakımından önemli bir sorundur. Güç sisteminin kararsızlığı nedeniyle oluşan birçok sistem arızası, sistemin kararlı olmasının önemini ortaya koymaktadır. Bu sorunlara çözüm bulunabilmesi için meydana gelen şebeke bozukluklarının çok iyi incelenmesi gerekmektedir. Güç sistemlerinde kararlılık gerilim kararlılığı, rotor açısı kararlılığı ve frekans kararlılığı olmak üzere 3 alt başlık altında incelenmektedir.

Hem çevresel etmenler hem de insan sağlığı açısından fosil yakıt kullanımının azaltılması gerektiğinden özellikle son yıllarda yenilenebilir enerji kaynaklarına yönelim artmıştır. Dağıtık üretim olarak adlandırılan, enerjinin tüketileceği yerde üretilmesiyle daha temiz enerji elde etmeye yönelik çalışmalar hız kazanmıştır. Böylece enerji, üretildiği santralden kilometrelerce uzaklıktaki tüketim merkezlerine uzun iletim hatlarıyla götürülmek yerine, tüketicinin yoğun olduğu yerde üretilmeye başlanmıştır. Hat uzunluğu azaldığı için iletim ve dağıtım hatlarında oluşan kayıplar ve şebeke karmaşası da azalmıştır. Literatürdeki çalışmalar incelendiğinde dağıtık üretim kaynaklarının şebekelere uygun yerde ve büyüklükteki entegrasyonu, güç sistemlerinde özellikle gerilim kararsızlığının önüne geçebilmek adına atılabilecek bir adım olarak karşımıza çıkmaktadır. Ancak dağıtık üretim kaynaklarının şebekeye uygunsuz entegrasyonu, hatlardaki düzensizlikler ve güç sistemlerinde meydana gelen diğer güç kalitesi bozuklukları gibi sistemi kararsızlığa götüren olaylara en kısa sürede müdahale edilememesi durumunda sistemi çökmeye götürebilmektedir.

Bu tez çalışmasında sistemin kararlılığına etkiyen olayların sınıflandırılması amaçlanmaktadır. Çalışma Matlab ortamında gerçekleştirilmiş olup sınıflandırılan arıza sinyalleri matematiksel formüller üzerinden elde edilerek çoğaltılmıştır. Çalışmada Yapay Sinir Ağları (YSA), Destek Vektör Makinaları (DVM, Support Vector Machine),

K- En Yakın Komşu Algoritması (KNN, K-Nearest Neighbors Algorithm), karar ağaçları, rastgele orman algoritması gibi makine öğrenmesine dayalı çeşitli sınıflandırma algoritmaları kullanılmıştır. Elde edilen doğruluk oranları karşılaştırmalı olarak sunulmuştur.



2. KAYNAK ARAŞTIRMASI

Bu çalışmada oluşturulan arıza sinyallerinin çeşitliliği ve sınıflandırma yapılırken kullanılan algoritmalar literatürde taranmıştır. Literatürdeki çalışmalar incelendiğinde çıkarılan özellik sayısı ve sınıflandırılması yapılan bozunumların çeşitliliği bakımından çalışmaların sınırlı olduğu gözlemlenmiştir. Kaynak araştırması bölümü güç sistemlerinde kararlılık ile ilgili çalışmalar ve güç kalitesi bozunumlarının sınıflandırılması ile ilgili çalışmalar olmak üzere iki alt başlıkta incelenmiştir.

2.1. Güç Sistemlerinde Kararlılık ile İlgili Çalışmalar

Moulin ve ark. (2004) yaptıkları çalışmada örüntü tanıma yaklaşımı ile geçici kararlılık analizi yapmışlardır. Çalışmada doğrusal olmayan DVM ve Çok Katmanlı Algılayıcı (ÇKA, Multi Layer Perceptron) modellerinden alınan verilerin karşılaştırılması yapılmıştır. Analitik çalışmaların tek başlarına karşılayamadıkları işlevlerin (mevcut çalışma noktası niteliksel değerlendirmesi, istikrar marjları, güvenlik bölgelerinin görselleştirilmesi, mevcut transfer kapasitesi, önleyici ve düzeltici kontroller, optimum yük atma) bu yaklaşımla sağlanabileceği, önemli katkılarda bulunabileceği belirtilmiştir. DVM sınıflandırıcıda hata oranlarının daha az olduğu görülmüştür.

Yalçınöz ve ark. (2004), güç sistemlerinde gerilim kararlılığı ve gerilim çökmelerinin ÇKA tipi YSA kullanılarak incelenmesi üzerinde durmuşlardır. Sistemde generatörlerin ürettiği aktif ve reaktif güç değerleri ile generatörün çıkış gerilimleri YSA'ya giriş verileri olarak verilmiştir. Tek gizli katmanlı ve iki gizli katmanlı YSA ile yapılan kararlılık analizi sonuçları ve MATLAB yük akışı simülasyonundan elde edilen veriler karşılaştırılmıştır. YSA ile yapılan kararlılık analizinin gerçeğe yakın sonuçlar verdiği ve iki gizli katman topolojisindeki hata oranının daha az olduğu görülmüştür.

Aydın ve ark. (2006), yaptıkları çalışmada seri kapasitör kullanımının enerji iletim sistemlerindeki etkilerini incelemişler. Çalışmada Powerworld programı kullanılarak, 7 baralı bir sistemde örnek uygulamalar gerçekleştirilmiştir. Çalışma sonucunda değişik oranlarda seri kompanzasyon yapılmış bir sistemde, sürekli halde iletim hatlarının yük taşıma kapasitesinin arttığı, bara gerilimlerindeki salınımların istenen değerler arasında olduğu, generatörlerin rotor açılarındaki salınımların ise azaldığı, sistemin hem açısıl hem de gerilim kararlılığının arttığı görülmüştür.

Erişti ve ark. (2007), yaptıkları çalışmada geçici rejim bozulmalarının sınıflandırılması için dalgacık dönüşümleri, DVM, ileri beslemeli yapay sinir ağları ve olasılıksal sinir ağları kullanarak bir yaklaşım sunmuşlardır. Geçici rejim bozulmalarını gösteren 4 farklı bozunum türü (çökme, sıçrama, kesinti, salınımlı geçici rejim) ve normal sinüs dalgası için sınıflama problemi oluşturulmuştur. Her sınıf için 1000 veri üretilmiştir. Her bir periyotun 256 örnekten oluştuğu 16 periyot bulunmaktadır. Bu verilerin dalgacık dönüşümleri ve enerji yöntemi kullanılarak özellikleri çıkarılmıştır. Bu özellikler eğitim ve test aşamalarında girdi verisi olarak kullanılmıştır. Benzetim sonuçlarından DVM ile en yüksek başarı sağlandığı görülmektedir.

Erişti ve Demir (2011), yaptıkları çalışmada bir transformatör binasında güç kalitesi izleme sistemi kurarak dağıtım sisteminin güç kalitesi parametrelerinin belirlenmesini amaçlamışlardır. Güç kalitesi analizörü ile güç sistemi olayları izlenmiştir. Elde edilen sonuçlar, harmonik içeriklerinin yönetmeliklerle belirlenen sınırları aştığını göstermiştir. Sisteme bağlı floresan lambaların ve bilgisayarların bu durumu tetiklediği belirlenmiştir. Elde edilen ölçümler sonucu, aylık olarak ortalama 35 güç sistemi olayı meydana geldiği ve bu durumlarda özellikle arızalı fazlarda gerilim seviyesinin oldukça azaldığı gözlemlenmiştir. Ayrıca, kompanzasyon kapasitörlerinin sürekli devreye girip çıkması ile çok sayıda geçici durum olayı meydana geldiği görülmüştür. Çalışma sonucunda güç kalitesinin ve güç kalitesini sağlamak için atılacak adımların önemi vurgulanmıştır.

Kawabe ve Yokoyama (2013), yaptıkları araştırmada çok makineli bir güç sisteminin kısa vadeli gerilim kararlılığını geliştirmek için yüksek gerilim şebekesinde batarya enerji depolama sistemlerinin (BEDS, Battery Energy Storage System) kullanımını incelemişlerdir. Sistemde öngörülemeyen şekilde meydana gelen kararsızlık durumunda için potansiyel bir önlem olarak, kararlılığının iyileştirilmesi için geniş alan ölçüm sistemi kullanan yeni bir BEDS acil durum kontrol şeması geliştirilmiştir. Geniş alan bilgisini kullanarak, BEDS'ler hem geçici kararlılığı hem de kısa vadeli gerilim kararlılığını yüksek sağlamlıkla iyileştirebildiği ortaya konmuştur. Sonuçlar, önerilen yöntemle kontrol edilen BEDS'lerin, üç fazlı bir topraklama arızası altında hem geçici durum kararlılığını hem de kısa vadeli gerilim kararlılığını iyileştirebileceğini göstermektedir. Önerilen yöntemin sağlamlığı, diğer arıza yerleri de dikkate alınarak doğrulanmıştır.

Goh ve ark. (2015), yaptıkları çalışmada gerilim çökmesi meydana gelmeden önce bir uyarı sağlayabilecek gerçek zamanlı bir izlemeden alınan veriler ile yapay sinir ağları

kullanılarak yapılan tahminler karşılaştırmışlardır. Bunun için sistem parametrelerinin değişiminin gözlenebileceği çok sayıda indeksler değerlendirilmiştir. Temel olarak en zayıf hattın (kritik hattın) bulunması amaçlanmıştır. Hat gerilim kararlılık endekslerini tahmin etmek için ileri beslemeli geri yayımlı yapay sinir ağı (Feed forward back propagation artificial neural network) kullanılmıştır. Sonuçlar göstermektedir ki kullanılan yapay sinir ağı yapısının tahminleri ile gerçek veriler arasında çok küçük, kabul edilebilir hatalar oluşmuştur. Dolayısıyla elde edilen tahminler sayesinde gerilim çökmesini önlemek için önceden uygun önlemlerin alınabileceği vurgulanmıştır.

Shukla ve ark. (2016), yaptıkları çalışmada dağıtılmış üretimin (DÜ) sayısını, konumlarını ve mevcut sistemlere entegrasyon için optimal kapasitelerini belirlemek için bir yöntem önermişlerdir. IEEE-33 ve IEEE-69 baralı test sistemlerinde değişen çalışma koşulları için güç akışı analizi ve dinamik simülasyonlar yapmışlardır. Farklı penetrasyon seviyelerine sahip iki tip DÜ (Tip I, sadece aktif güç enjekte eden ve Tip II hem aktif hem de reaktif güç enjekte eden DÜ) için çalışmalar yapılmıştır. Önerilen DÜ'lerin yerleştirilmesinin ve boyutlandırılmasının, her iki DG tipine sahip her iki test sisteminde de tüm penetrasyon seviyeleri için dikkate alınan tüm performans endekslerini iyileştirdiği gösterilmiştir.

Albatsh ve ark. (2017), Güç sistemindeki en savunmasız veya en zayıf bölgeleri belirlemek için 4 adet gerilim kararlılık indeksi kullanmışlardır. Bu indekslerin gerilim çökme noktasına duyarlılığına dayalı olarak indeksler arasında karşılaştırmalı bir çalışma yapmışlardır. PSCAD ortamında tasarladıkları IEEE-14 baralı test sistemi üzerinde çalışmışlardır. İndekslerin yük artışına maruz kaldıklarında göreceli olarak hassasiyetlerinin gözlemlenmesi de sağlanmıştır. Yapılan çeşitli simülasyonlar ile en zayıf bölgeler tespit edilmiştir. Gerilim kararlılığını sağlamak adına FACTS veya reaktif güç kompanzasyon cihazlarının yerleşiminde de en zayıf bölgeler kritik olduğundan çalışmada bu cihazların nereye yerleştirileceği konusunda da önerilerde bulunulmuştur.

Shekhawat ve ark. (2018), yaptıkları çalışmada gerilim kararlılık indeksleri ile ilgili önemli hususlar üzerinde durmuşlardır. Bir sistemdeki zayıf baraları tanımak için bir yazılım programı tasarlamışlardır. Programın verimliliği IEEE 14 baralı ve IEEE 30 baralı test sistemlerinde, farklı yükleme koşullarında hat kararlılık indeksi ve hızlı gerilim kararlılık indeksi kullanılarak değerlendirilmiştir. Önerilen yaklaşım, gerilim kararlılık değerlendirmesinin hızlı bir şekilde hesaplanmasını sağlamaktadır.

Kyomugisha ve ark. (2021), yaptıkları çalışmada Uganda Güç Sistemini MATLAB-PSAT'ta modelleyerek gerilim kararlılığının ve ilgili geliştirme önlemlerinin

bir deęerlendirmesini yapmıřlardır. Srekli g akıřı analizi ile zayıf baralar tespit edilmiř ve bu baralar Statik Senkron Kompanzatrlerin (STATCOM) kurulumu iin aday bara olarak tanımlamıřlardır. STATCOM'un beklenmedik durum ve arıza kořulları altında řebekedeki gerilim kararlılıęı zerindeki etkisi de gzlemlenmiřtir. Sonular, STATCOM'un dahil edilmesinden sonra bara gerilimlerinin tm normale dndrlerek hem arıza sırasında hem de sonrasında olası bir gerilim kmesinin nlendięini gstermektedir.

Lokesh ve ark. (2021), oklu sinyal analiz ara kutusunu kullanarak yenilenebilir DG'lere dayalı mikro řebekenin geici kararlılıęını ve gerilim kalitesini deęerlendirmiřlerdir. Sistemde 3 faz-toprak arızası oluřtuęunda sistemin gerilim, bara frekansı ve rotor hızının analizi eřitli durumlar iin analiz edilmiřtir. eřitli simlasyonlar sonucu, yenilenebilir D'lerin řebekeye girmesinin sistemin geici kararlılıęını tehlikeye atacaęı sonucuna varılmıřtır. Dalga formlarından ve istatistiksel verilerden, řebeke baęlantılı modda mikro řebekenin geici kararlılıęının yksek olduęu grlmřtir.

Choudhury ve ark. (2021), 3 faz-toprak arızasına maruz kalan bir elektrik řebekesi iin G Sistemi Dengeleyicisinin (PSS, Power System Stability) ve Statik Var Kompansatrn (SVC) koordineli alıřmasının yalnızca PSS olan bir sisteme gre farkını ortaya koymayı amalamaktadır. SVC, PSS ile birleřtirildięinde yalnızca g sistemi geici durum stabilitesini arttırmakla kalmayıp, aynı zamanda gerilim reglasyonunu da iyileřtirdięi gzlemlenmiřtir. PSS ve SVC'nin birleřik kullanımı durumunda, sistemin yalnızca PSS kullanımına gre daha hızlı tepki verdięi ve geliřmiř verimlilik ve gvenilirlięe sahip olduęu sonucuna varılmıřtır.

2.2. G Kalitesi Bozunumlarının Sınıflandırılması ile İlgili alıřmalar

Janik ve Lobos (2006), yapmıř oldukları alıřmada 5 ana g kalitesi problemine saf sinzoid sinyalleri simle etmiřlerdir. Altı sınıfın her biri iin 50 adet olmak zere toplam 300 adet farklı sinyal retildi. Bunlardan on tanesi eęitimde kullanılmıř, dięerleri test ařamasında uygulanmıřtır. Grltsz sinyallerle beslenen Radyal Tabanlı bir aę (RBF, Radial Basis Function) ve DVM sınıflandırıcıları kullanılarak elde edilen sınıflandırma sonuları tablolarla verilmiřtir. DVM sınıflandırıcı, grlt eklendięinde ve eklenmedięinde aynı performans gsterdięi grlmřtir. DVM sınıflandırıcı, zellikle salınımlı geiřler iin RBF sınıflandırıcısından daha iyi sınıflandırma oranları

göstermiştir. Eğitim vektörlerinin sayısı önceki deneylere kıyasla yarı yarıya azaldığı görülmüştür. Yalnızca beş eğitim vektörü kullanarak, RBF ağı özellikle yükselmeler, düşmeler ve salınımlı geçişler durumunda önemli ölçüde daha kötü performans göstermiştir.

Kalyani ve Shanti Swarup (2009), DVM tabanlı örüntü tanıma yaklaşımını hem statik hem de geçici güvenlik değerlendirmesi için IEEE 57 baralı ve 118 baralı standart test sistemlerine uygulamışlardır. DVM sınıflandırıcısının simülasyon sonuçları, geleneksel En Küçük Kareler Yöntemi (MLS, Method of Least Squares) sınıflandırıcıları ile karşılaştırılmıştır. Özellik seçimi süreci Sıralı İleri Seçim (SİS, Sequential Forward Selection) yöntemi adı verilen basit bir yaklaşımla gerçekleştirilmiştir. Simülasyon sonuçları, DVM sınıflandırıcısının çevrimiçi güvenlik değerlendirmesi için uygunluğunu artırarak daha iyi bir sınıflandırma sağladığını kanıtlamaktadır.

Erişti ve ark. (2010), yaptıkları çalışmada hem gürültülü hem de gürültüsüz sinyaller üzerinde çalışmışlardır. Güç sistemi bozukluklarının belirlenmesi için dalgacık dönüşümü ve DVM tabanlı bir sınıflandırma algoritması önerilmiştir. Özellikle, özellik çıkarma ve özellik seçimi üzerinde durulmuştur. Öncelikle, özellikler, bozulma sinyalinin tüm ayrışma seviyelerinin dalgacık katsayıları için farklı teknikler ile elde edilmiştir. Daha sonra, SİS tekniği kullanılarak, ilk aşamadan elde edilen özellik setinde sağlam ve yeterli özellikler seçilmiştir. Deneysel sonuçlar, önerilen algoritmanın hem gürültüsüz hem de gürültü uygulanmış bozuklukları yüksek doğrulukla sınıflandırabileceğini göstermiştir.

Erişti ve ark. (2014), yaptıkları çalışmada yeni bir ST – ELM Extreme learning machine tabanlı yaklaşım önermişlerdir. Çalışmada MATLAB / Simulink ortamında oluşturulan 538 gerçek PQ olay verisi ve 4920 sentetik PQ olay verisi kullanılmıştır. Önerilen yöntemin farklı gürültü koşulları altında performansını test etmek için 20, 30 ve 50 dB sinyal-gürültü oranlarına (SNR) sahip farklı seviyelerdeki gürültüler kullanılmıştır. ELM sınıflandırıcısının performansını değerlendirmek için 10 farklı sınıflandırma prosedürü belirlenmiştir.

Yuanhang ve ark. (2015), yaptıkları çalışmada Relief algoritmasına dayalı çoklu DVM ile güç sistemlerinde geçici kararlılık değerlendirilmesi yapmışlardır. Yanlış ve eksik sınıflandırmaların önüne geçebilecek bir yöntem önermişlerdir. Yanlış sınıflandırmalar operatörlerin kararlarını ciddi şekilde etkilediğinden güç sistemlerinde güvenlik ve kararlılık açısından birçok olumsuzluklara sebep olmaktadır. Çalışmada öncelikli olarak güç sisteminin güvenlik sınırı belirlenmeye çalışılmıştır. Arıza

senaryoları meydana getirildiğinde yanlış sınıflandırılan örneklerin sayısının önemli ölçüde azaltıldığı görülmüştür. Bu durumun da operatörlerin zamanında ve etkili kontrol önlemleri almalarında etkili olacağı düşünülmüştür.

Hao ve ark. (2016), yaptıkları çalışmada Matlab/Simulink'te IEEE 9 test modelinin analizine dayanan çoklu güç kalitesi bozulmalarının sınıflandırılması ve değerlendirilmesi için zaman alanı karakteristik analizi (ZAKA, time domain characteristic analysis) yöntemini ele almışlardır. Tüm olağan karmaşık güç kesintileri modelde simüle edilmiştir. Bu bozuklukların tümü, doğru bir şekilde ZAKA yöntemiyle sınıflandırılmış ve değerlendirilmiştir. Matlab'tan alınan verilerle karşılaştırılarak ZAKA yönteminin değerlerinin doğruluğu gösterilmiştir. Simülasyon sonuçları, bu yöntemin güç sistemine dayalı güç kesintisi sınıflandırmasında da kullanılabileceğini göstermektedir.

Erişti ve ark. (2016), yaptıkları çalışmada güç kalitesi bozukluklarının tanımlanması amacıyla gerçek zamanlı gömülü bir algılama sistemi önermektedir. Geliştirilen algılama sistemi, alanda programlanabilir kapı dizisi (FPGA, Field Programmable Gate Array) ortamında dalgacık dönüşümü kullanılarak oluşturulmuştur. Bu algılama sisteminde FPGA ortamında anlık olarak tespit edilen güç kalitesi bozulma verileri bilgisayar ortamına aktarılmakta, görüntülenmekte ve kayıt altına alınmaktadır. FPGA tabanlı algılama sistemini test etmek, doğruluk oranlarını belirlemek ve başarısını değerlendirmek için laboratuvar ortamında güç sisteminin deneysel bir düzeneği kurulmuştur. Bu model üzerinde çeşitli güç kalitesi bozulmaları oluşturulmuştur. Bu çalışma kapsamında önerilen gerçek zamanlı güç kalitesi bozulma tespit sistemi için elde edilen sonuçlar incelendiğinde, donanım ve yazılım tasarımlarının oldukça etkili, hızlı ve yüksek başarımlı performansına sahip olduğu görülmüştür.

Borrás ve ark. (2016), tarafından yapılan çalışmada önerilen yöntem dalgacık çoklu çözünürlük analizi ve DVM'ye dayanmaktadır. 10 adet güç kalitesi bozukluğu (Harmonikler, sarkmalar, gerilim sıçramaları, salınımlı geçişler, gerilim dalgalanmaları, harmonikler ve gerilim çökmesi, harmonikler ve gerilim sıçraması, salınımlı geçici durum ve gerilim çökmesi, salınımlı geçici durum ve gerilim sıçraması, salınımlı geçici durum ve harmonikler) üzerinde gerçek zamanlı laboratuvar ortamında deneysel çalışmalar gerçekleştirilmiştir. Sistemin farklı gürültülü durumlarda nasıl çalıştığını test etmek için, 30 ila 50 dB SNR değerlerine sahip farklı Gauss beyaz gürültü seviyeleri dikkate alınmıştır. Bu gürültülü koşullarda, yöntemin SNR için minimum 34 dB olana kadar düzgün çalıştığı görülmüştür. SNR'si 34 dB veya daha yüksek olan her sınıf başına 100

adet olmak üzere toplamda 1000 adet test verisi ile test edildiğinde %94.2 doğruluk oranı elde edilmiştir.

Liquan ve ark. (2017), yaptıkları çalışmada içerisinde çoklu güç kalitesi bozunumlarının da bulunduğu 11 adet güç kalitesi bozunumunun analizini yapmışlardır. Özellikle çoklu güç kalitesi bozunumlarının sınıflandırılmasındaki doğruluğu artırabilmek için parçacık sürü optimizasyonu (PSO) ve dalgacık dönüşümü tabanlı yeni bir yaklaşım (PSO-DVM) önerilmiştir. Sadece DVM ile yapılan sınıflandırmalar ile PSO-DVM yapısıyla yapılan sınıflandırmaların doğruluk oranlarını karşılaştırılmıştır. PSO yaklaşımının DVM ile yapılan sınıflandırmanın doğruluk oranlarında ciddi iyileştirmeler sağladığı ve gürültüye direncinin daha fazla olduğu görülmüştür.

Patil ve ark. (2019), yaptıkları çalışmada bir örüntü tanıma sinir ağının Maharashtra State Electricity Transmission Company Limited'den elde edilen 132 kV veriyolundaki gerilim verilerinde güç kalitesi olaylarını nasıl sınıflandırabildiğini göstermektedir. Gerilim çökmesi, gerilim sıçraması, kesinti ve normal sinüzoidal olmak üzere 4 adet güç kalitesi olayları incelenmiştir. %95.2381 sınıflandırma doğruluğu elde edilmiştir.

Zhang ve ark. (2020), yaptıkları çalışmada S dönüşümü ve DVM sınıflandırıcı kullanılarak özel yük tipi güç kalitesi bozulmalarını tanımlamak için bir yöntem önermektedirler. Çalışmada 7 adet güç kalitesi bozukluğu (gerilim çökmesi, gerilim sıçraması, gerilim kesintisi, harmonikler, salınımlı geçişler, gerilim sıçraması ve harmonikli durum, gerilim çökmesi ve harmonikli durum) incelenmiştir. Yöntemin doğruluğunu değerlendirmek için 80 adet eğitim sinyali (gürültüsüz), 1100 adet test sinyali (gürültüsüz) oluşturulmuştur. 40dB, 30dB, 20dB gürültü eklenerek test sonuçları karşılaştırılmıştır. En yüksek doğruluk oranı %99.71 ile 40dB eklenen sinyaller ile elde edilmiştir.

Abdullah ve ark. (2020), yaptıkları çalışmada saf sinüzoidal, gerilim çökmesi, gerilim sıçraması, kesinti, ani yükselmeler, salınımlı geçici durum, harmonik, gerilim çökmesi ile harmonikler, gerilim sıçraması ile harmonikler, fliker, gerilim çökmesi ile fliker, gerilim sıçraması ile fliker, salınımlı geçici ile gerilim çökmesi, salınımlı geçici durum ile gerilim sıçraması, harmonikli gerilim çökmesi, harmoniklerle gerilim sıçraması ve çentik olmak üzere 17 farklı güç kalitesi üzerinde çalışmışlardır. Her sınıf için 1000 adet veri oluşturulmuştur. DVM ve karar ağaçları algoritmalarının doğruluk oranları karşılaştırılmıştır. Çalışma sonucunda saf sinüs, fliker, harmonikler, harmonikli gerilim çökmesi ve geçici durumun hatasız olarak sınıflandırıldığı görülmüştür.

3. MATERYAL VE YÖNTEM

Güç kalitesi sorunları güç sistemlerinin kararlılığını doğrudan etkilemektedir. Bu bölümde güç sistemlerinin kararlılığını ve kararlılığı doğrudan etkilediği için güç kalitesini etkileyen faktörlere yer verilmiştir. Çalışmada matematiksel yöntemlerle güç kalitesini bozan etkenlerin sinyallerinin üretimi yapılarak güç kalitesini bozan etkenlerin sınıflandırılması yapılmıştır. Matematiksel denklemlerden oluşturulan sinyallerin sınıflandırılması için KNN, DVM, YSA gibi çeşitli yöntemler kullanılmıştır. YSA ve çeşitli sınıflandırma algoritmaları bu bölümde ayrıntılı olarak incelenmiştir. Sinyal işleme yöntemleri ile arıza sinyallerinden özellik çıkarma işlemleri yapılmıştır. Tezin sonraki bölümlerinde şu ana kadar özetlenen kavramların ayrıntılı açıklamaları yapılacaktır.

3.1. Güç Sistemlerinde Kararlılık

Güç sistemlerinde kararlılık, bir güç sisteminin bozucu bir etkiye maruz kaldıktan sonra tanımlanan sınırlarda çalışmasını devam ettirebilme yeteneği olarak tanımlanmaktadır (Kundur, 1994). Güç sistemlerinin enterkonnekte yapısının sürekli olarak büyümeye devam etmesi sistemin çalışma koşullarının zorlanmasına sebep olmaktadır. Bu durum sistemin kararsızlık sınırlarında çalışmasına yol açmaktadır. Güç sistemlerinde kararlılık kavramı hem güç sistemi işletmeciliği açısından hem de tüketiciler için oldukça önemlidir. Dolayısıyla sistem gerektiğinde anlık olarak talep edilen güce cevap verebilmeli, bozucu etkilerle karşılaştığında da çalışma sınırlarını koruyabilmelidir. Özellikle son yıllarda ülkemizde ve diğer ülkelerde yaşanan büyük çaplı elektrik kesintileri ve şebeke çökmeleri güç sistemlerinin kararlı çalışmasının ne derece önemli olduğunu ortaya koymuştur. Büyük ve karmaşık yapıda olan güç sistemlerinin analizi de oldukça zordur. Bu nedenle bilgisayar destekli analiz yöntemleri büyük kolaylık sağlamaktadır.

Güç sistemlerinde kararlılık rotor açısı kararlılığı, frekans kararlılığı ve gerilim kararlılığı olmak üzere 3 ana başlıkta incelenmektedir. Şekil 3.1’de gösterildiği gibi her başlık kendi içerisinde alt dallara ayrılmaktadır.




Şekil 3.1. Güç sistemlerinde kararlılık

3.1.1. Rotor açısı kararlılığı

Rotor açısı kararlılığı, bir güç sisteminde çalışan tüm senkron makinaların senkronizmada kalma yeteneğidir. İki ya da daha fazla senkron makina birlikte çalışırken, tüm makinaların stator gerilimleri ve akımları aynı frekansa sahip ve her rotorun mekanik hızı frekansa uyumlu olmalıdır. Böylece birlikte çalışan tüm senkron makinalar senkronizmada kalmalıdır (Arifoğlu, 2020).

Rotor açısı kararlılığının temelini anlayabilmek için bir generatör ve motordan oluşan örnek bir sistem modeli Şekil 3.2’de verilmiştir.



Şekil 3.2. Bir generatör ve motordan oluşan sistem modeli


Aktif ve reaktif güçlere ilişkin denklemler Eşitlik 3.1, 3.2 ve 3.3’te verilmiştir.

$$P = \frac{V_1 V_2}{X} \sin \delta \quad (3.1)$$

$$Q = \frac{V_1(V_1 - V_2)}{X} \cos \delta \quad (3.2)$$

$$X = X_g + X_h + X_m \quad (3.3)$$

Verilen eşitliklerde P aktarılan aktif güç miktarını, Q reaktif güç miktarını, V_1 hat başı gerilimi, V_2 hat sonu gerilimini, δ senkron makinanın rotorları arasındaki açısal farkı ve X toplam reaktansı göstermektedir. Şekil 3.3'te generatör ve motor gerilimleri arasındaki bağıntıyı açıklayan fazör diyagramı gösterilmiştir.




Şekil 3.3. Fazör diyagramı

Generatörden motora aktarılan güç iki makinenin rotorları arasındaki açısal farkın (δ) bir fonksiyonudur. Eşitlik 3.4'te gösterildiği gibi motorun iç açısı (δ_m), generatörün iç açısı (δ_g) ve generatör ile motorun uç gerilimleri arasındaki farkın (δ_h) toplamından oluşmaktadır. Rotorlar arasındaki açısal farkın denklemi Eşitlik 3.4'te verilmiştir.

$$\delta = \delta_m + \delta_g + \delta_h \quad (3.4)$$

Şekil 3.4'te güç-açı karakteristiği verilmiştir.



Şekil 3.4. Güç- açı karakteristiği (Ova, 2017)

Şekil 3.4 incelendiğinde açı 0 iken güç iletiminin olmadığı, $\frac{\pi}{2}$ 'de iken aktarılan gücün maksimum olduğu, $\frac{\pi}{2}$ 'ye kadar arttığı $\frac{\pi}{2}$ 'den sonra ise azaldığı görülmektedir.

Bir güç sisteminde her bir makinanın mekanik giriş momenti ile elektriksel çıkış momenti arasında bir denge olmalıdır. Sistem bir bozulmaya maruz kaldığında denge bozulur makinaların rotorları hızlanmaya ya da yavaşlamaya başlar. Generatör geçici olarak diğerlerinden daha hızlı hareket etmeye başlarsa generatörün rotorunun açısal durumu, daha yavaş olan makinanın açısal durumuna göre ileride olur (Arifoğlu, 2020). Açıda meydana gelen bu sapma kararsızlığa neden olur.

Rotor açılı kararlılığı küçük işaret kararlılığı ve geçici hal kararlılığı olmak üzere ikiye ayrılır.

3.1.1.1. Küçük işaret kararlılığı (Sürekli hal kararlılığı)

Küçük bozucu etkiler karşısında güç sisteminin senkronizmayı koruma yeteneğidir. Sistemdeki yükler ve üretimdeki değişimlerden dolayı sistem üzerinde sürekli olarak meydana gelmektedir. Küçük bozucular iki türlü sürekli hal kararsızlığına neden olabilirler. Senkronizasyon momentinin yetersiz olması nedeniyle rotor açısındaki artış veya yeterli sönümleme momentinin olmaması nedeniyle rotor salınımlarının artması şeklinde meydana gelebilir (Kundur, 1994).

3.1.1.2. Geçici hal kararlılığı

Şiddetli geçici bozukluklar karşısında güç sisteminin senkronizmayı sürdürebilmesidir. Üretim birimlerinin kaybı, iletim hatlarının devre dışı kalması ve anahtarlama olayları bu geçici kararlılığı bozan arıza örneklerindendir. Bu tür arızalarda sistem cevabı, generatör rotor açıları, yük akışları, bara gerilimleri ve diğer sistem değişkenlerinin büyük sapmalarına yol açar (Ekinci, 2015).

Generatör ataleti, generatör yüklenmesi, arıza süresince generatör çıkışı (güç transferi), arıza temizleme zamanı, arıza sonrası iletim sistemi reaktansı, generatör reaktansı, generatör iç gerilim genliği ve sonsuz bara gerilimi genliği gibi faktörler de geçici hal kararlılığını etkilemektedir (El-Sherbiny ve Mehta, 1973).

3.1.2. Frekans kararlılığı

Frekans kararlılığı, sistemde meydana gelen bir bozulma nedeniyle üretim ve yük arasında önemli bir dengesizlik oluştuğunda, güç sisteminin sabit bir frekansta kalabilme yeteneği olarak ifade edilmektedir. Toplam üretim kapasitesinin toplam yükü dengelemeye çalışması gibi sorunlar önlenmelidir. Bununla birlikte hem üretim hem de talep dinamik olarak değişmektedir. Bu durum sistem içindeki toplam üretim ve toplam talep arasında bir dengesizliğe yol açabilir. Bu dengesizlik bir frekans sapması yaratır. Sapma kabul edilebilir bir aralıktaysa, önemli bir etki olmaz. Ancak belirli bir eşiği geçerse, güç sisteminin çalışmasını, verimliliğini ve güvenliğini etkiler duruma gelir. Ayrıca yüklenme miktarının düşmesine, iletim hatlarına aşırı yük binmesine ve koruma arızalarına neden olmaktadır (Bevrani, 2009).

Temel olarak sistem frekansı, generatörün hızı ile doğru orantılıdır; rotor hızının artmasıyla sistemin frekansı artar ve azalmasıyla azalır. Sistem talep arttığında ise rotorun hızı ve frekans yavaş yavaş azalır. Benzer şekilde sistemdeki yükün azalmasıyla rotorun hızı ve frekans artar. Dolayısıyla üretilen güç, talep edilen güç ve güç kayıplarının toplamına eşit olmalıdır; aksi takdirde frekans sapması meydana gelir. Sistemdeki frekans ve güç sapması arasındaki ilişki Eşitlik 3.5'te verildiği gibi salınım denklemi ile ifade edilebilir.


$$P_M - P_L = \frac{2Hd^2\delta}{\omega_s dt^2} \quad (3.5)$$

Burada P_M üretilen gücü, P_L yükün gücünü. H ataleti, ω_s ise senkron hızı temsil etmektedir.

Üretim ve yük dengesizliğinin ortaya çıkmasından sonra, primer frekans kontrolü, frekansı gerekli aralıkta tutmak için frekans sapmasına tepki verir. Frekans sapması hala sistem gereksinimini karşılayamıyorsa, döner rezervler ve hızlı başlatma generatörleri, frekansı nominal değere geri yüklemek için üretimi artırarak veya azaltarak sonradan tepki verecektir (Kundur, 1994). Primer frekans kontrolü frekans sapması durumunda milisaniyeler içinde etkin olur, 30 saniye içinde en yüksek değerine ulaşır ve 0-15 dakika arasında bir sürede etkinliği devam eder. Primer frekans kontrolü sistem frekansını geri yükleyemeyebilir; bu nedenle, sistem geri yüklemesi için sekonder frekans kontrolü gereklidir. Temel olarak, primer frekans kontrolü, kısa vadede frekansı kontrol etmek için

kullanılırken, sekonder frekans kontrolü sistem frekansının uzun bir süre boyunca istenen sınırları aşmasını önlemek için primer olanı yönlendirmek için kullanılır (Undrill, 2019).

Primer ve sekonder frekans kontrol rezervlerinin sistem dengesini sağlamaya yeterli olmadığı durumlarda Elektrik Piyasası Dengeleme ve Uzlaştırma Yönetmeliği uyarınca dengeleme güç piyasası kapsamında verilen yük alma ve yük atma talimatları ile tersiyer frekans kontrolü gerçekleştirilir. Sistem dengesinin primer ve sekonder frekans kontrolü süreleri ile sağlanabildiği durumlarda ise sekonder frekans rezervlerinin boşaltılması için uygulanır. Şebeke frekansının bozulmasını takiben dakikalar ile başlayıp saatlerce sürebilir. Şekil 3.5'te Elektrik Şebeke Yönetmeliği'nden alınan normal işletme koşullarında rezervlerin devreye girme sıralamasına ait grafik verilmiştir.



Şekil 3.5. Rezervlerin devreye girme sıralaması (Elektrik şebeke yönetmeliği, 2014).

Türkiye Elektrik Şebeke Yönetmeliğine göre sistemin 50 Hz olan nominal frekansının kabul edilebilir sınırları TEİAŞ tarafından 49,5-50,5 Hz aralığı olarak belirlenmiştir. Frekans kontrolü için gerekli olan yeterli miktarda güç rezervleri ilgili yönetmelik gereğince yine TEİAŞ tarafından sağlanmaktadır (Elektrik şebeke yönetmeliği). Bu rezerv genellikle en büyük kurulu güce sahip ünitenin devre dışı kalması göz önünde bulundurularak belirlenir ve kesintisiz olarak sağlanması kritiktir (Tür ve ark., 2018).

Frekans kararlılığında meydana gelen problemler üretim üniteleri ve yüklerdeki değişimlerden kaynaklanabileceği gibi yenilenebilir enerji kaynaklarının entegrasyonundan da kaynaklanabilmektedir.

3.1.3. Gerilim kararlılığı

Gerilim kararlılığı, sistemin bir bozunuma uğradıktan sonra sistemdeki tüm baraların tekrar başlangıçtaki gerilim koşullarında ya da kabul edilebilir sınırlarda

çalışmaya devam etmesidir (Kundur, 1994). Sistemin gerilim kararlılığı sınırları 0.9-1.1 pu aralığıdır. Bir güç sistemi, yük ve üretim arasında büyük bir dengesizlik meydana geldikten sonra yeni bir denge noktasına ulaşamazsa, frekansı azalmaya devam eder ve sistem frekansı kararsız hale gelir (Amjady ve Fallahi, 2010). Yük akışı (güç akışı olarak da bilinmektedir) analizi, kararlılık analizi yaparken sıkça karşımıza gelmektedir.

Literatür incelendiğinde gerilim kararlılığına en büyük etkisi olan faktörlerden bazılarının;

- Güç sisteminin reaktif güç talebinin karşılanamaması
- Yükün cinsi
- Hattın güç transfer kapasitesi
- Güç sisteminin üretim kapasitesi olduğu görülmüştür.

Gerilim kararsızlığını engellemek için ise;

- Kompanzasyon sistemleri
- Trafo kademe değiştiricileri
- Otomatik gerilim regülatörleri
- Koruma ve kontrol sistemlerinin koordinasyonu
- FACTS cihazları
- Düşük gerilim yük atma gibi yöntemlerin kullanıldığı gözlemlenmiştir.

3.2. Elektrik Şebekelerinde Gerilim Kararlılığı

Bu tez çalışmasının konusu elektrik şebekelerinde gerilim kararlılığı üzerinedir. Frekans ve rotor açısı kararlılığı daha çok döner makinalarla ilgili olduğundan genellikle üretim santrallerini ilgilendirmektedir. Bir güç sisteminin çoğunu elektrik şebekeleri oluşturmaktadır. Elektrik şebekelerinde de gerilim kararlılığı önemli bir konudur. Bu nedenle bu tez çalışmasında gerilim kararlılığına yönelinmiştir.

Enerji üretim santralleri ile tüketim merkezlerinin arasındaki uzaklıklar, sistemin aşırı yüklü olması, yük karakteristikleri, trafo kademe ayarları, kompanzasyon cihazlarının özellikleri ve yetersizliği, talep edilen reaktif gücün karşılanamaması gibi durumlar gerilim kararsızlığına neden olmaktadır. Gerilim kararsızlığı çözümlenemediği takdirde sistemi çökmeye götürebilmektedir. Gerilim çökmesi olayı başlangıçta bölgesel olarak görünse de sonrasında tüm sistemi etkileyebilmektedir.

Güç sistemlerinde gerilim kararlılığı analizi yapılırken sistemin kararsızlık noktasının ne kadar yakınında olduğu, sistemde oluşan kararsızlığın nedeni ve nasıl

oluştugu sorularına cevap aranmaktadır. En çok kullanılan yaklaşımlar dinamik gerilim kararlılığı analizi ile statik gerilim kararlılığı analizleridir. Dinamik gerilim kararlılığı analizi, zaman eksenli simülasyonlar temeline dayanır ve sistemde oluşacak bozunumlar sonrasında sistemin uygun bir şekilde işletilmesi yönünden sistemin yeteneğini analiz etmek için kullanılır. Statik gerilim kararlılığı analizinde ise güç sisteminde aktif ve reaktif güç bakımından zayıf bölgelerin, sistemdeki baraların yüklenebilirlik limitlerinin ve sistem için gerekli olan kompanzasyon cihazlarının boyutunun belirlenmesi amaçlanmaktadır.

Gerilim kararlılığı büyük rahatsızlık gerilim kararlılığı ve küçük rahatsızlık gerilim kararlılığı olmak üzere iki alt başlık altında incelenebilir.

Büyük rahatsızlık gerilim kararlılığı yük kaybı, üretim kaybı, sistem arızası gibi büyük bozulmalardan sonra sistemin gerilimini kabul edilebilir sınırlarda tutabilmesidir. Tüm bu bozucu etkilerden sonra sistem sınır değerlerin dışına çıkmaksızın çalışmasını devam ettirebilmelidir.

Küçük rahatsızlık gerilim kararlılığı, yük değişimi gibi küçük bozucu etkilerin ardından sistemin gerilimini kabul edilebilir sınırlarda tutabilmesidir. Büyük rahatsızlıklara göre daha sık karşılaşılan bu durum karşısında sistem sorunsuz çalışmasını ve maksimum güç aktarımını sürdürebilmelidir.


Gerilim kararlılık problemlerinin analizi için literatürde farklı yöntemler önerilmiştir. Statik gerilim kararlılığı yöntemleri gerçek zamanlı durumlarda kullanılır, hesaplama süresi kısadır. Ancak dinamik kararlılık statik kararlılığa göre daha doğru olmasına rağmen sistem ile ilgili daha fazla verinin bilinmesini gerektirmektedir (Kamaruzzaman ve ark. , 2015). Gerilim kararlılığı dinamik bir olay olmasına karşın genellikle analiz edilirken statik yaklaşımlar kullanılmaktadır. Statik gerilim kararlılığı analizi için yaygın olarak kullanılan yöntemler;

- P–V ve Q–V eğrileri,
- Sürekli güç akışı yöntemi
- Gerilim çökme noktasındaki güç akışının Jacobian matrisinin tekilliğine dayanan yöntemlerdir.

P–V eğrisi yöntemi, gerilim çökme noktasından önce mevcut aktif güç marjı miktarını belirleyerek gerilim kararlılığını analiz etmek için yaygın olarak kullanılır. Q–V eğrisi yöntemi, istenen gerilimi elde etmek için yük ucundaki reaktif güç miktarını araştırmak için kullanılır. Jacobian matrisinin modal analizi, güç sistemi kararlılık analizinde de yaygın olarak kullanılmaktadır. Gerilim kararlılığı ile ilgili yapılan

çalışmaların büyük bir kısmı güç akışı algoritmasına dayalı olarak gerçekleştirilmektedir. Yukarıda belirtilen tüm analiz teknikleri, bir sistemin tolere edebileceği maksimum yüklemde gerilim çökme noktasını belirlemek için kullanılır. Gerilim çökme noktası, arızalı bir güç sisteminde, reaktif gücü olmayan bir güç sisteminde ve ağır yüklü güç sistemlerinde meydana gelebilir (Gurusinghe ve Ongsakul, 2012).


Şekil 3.6'da örnek bir güç sistemine ait P-V ve Q-V eğrileri verilmiştir.



Şekil 3.6. Güç sisteminde herhangi bir bara için P-V ve Q-V eğrileri (Eminoğlu ve Hocaoglu, 2005)

Buradaki P_{max} ve Q_{max} bara yükünün maksimum değerini göstermektedir. Bu değerlerden daha büyük yük değerlerinde sistemde gerilim kararsızlığı oluşacak ve yükte olabilecek herhangi bir değişim sistemi çökmeye götürecektir. P-V eğrisindeki kritik noktaya karşılık gelen güç, baradan çekilecek maksimum aktif yük miktarını belirtmektedir. Eğrinin kritik noktasının üstünde kalan kısım, sistemin kararlı çalışma aralığını göstermektedir (Baysal ve ark., 2007).

Gerilim kararlılığının reaktif güçle yakından ilişkili olduğu bilinmektedir ve gerilim kararlılık sınırı Q-V eğrilerinden direkt olarak elde edilebilmektedir. Q-V eğrileri test barası veya kritik baradaki reaktif güce karşı gelen gerilimi gösterir. Gerilim çökmesini ve sistem kararsızlığını engellemek için yapılan analizlerde Q-V eğrileri önemli bir yer tutmaktadır. Gerilim çökme riski, sistem gerilimi, Q_{max} 'a karşılık gelen V_{kritik} noktasından ne kadar uzaksa o kadar azdır (Ova, 2017). Şekil 3.7'de işletme noktası, kritik nokta ve gerilim açısından kararlı-kararsız olan bölgeler gösterilmiştir



Şekil 3.7. Q-V eğrisi (Ova, 2017)

3.2.1. Gerilim kararlılığını etkileyen faktörler ve gerilim kararsızlığına karşı alınabilecek önlemler

Güç sistemlerinde gerilim kararlılığını bozan birçok durum vardır. Gerilim kararsızlığına neden olan başlıca etkenler, nedenleri ve alınabilecek önlemler bu bölümde ayrıntılı olarak açıklanmıştır.

3.2.1.1. Yük karakteristikleri

Güç sistemlerinde kullanılan yük modelleri güç sisteminin gerilim kararlılığını etkilemektedir. Özellikle asenkron motorlar, ark fırınları gibi doğrusal olmayan yükler gerilim kararlılığını bozmaktadır. Kullanılan yüklerin büyük bir çoğunluğu eksponansiyel (üstel) karakteristiğe sahip olup aktif ve reaktif güç gerilimin üstel bir fonksiyonu olarak modellenmektedir (Haque, 1996). Bu yük modelleri için gücün aktif ve reaktif bileşenlerinin genel ifadesi Eşitlik 3.6 ve 3.7’de verilmiştir.

$$P = P_0 \left(\frac{V}{V_0} \right)^\alpha \quad (3.6)$$

$$Q = Q_0 \left(\frac{V}{V_0} \right)^\beta \quad (3.7)$$

Burada P_0 ve Q_0 yükte tüketilen referans aktif ve reaktif gücü, V_0 referans gerilimini, α ve β parametreleri ise yük karakteristiklerini temsil etmektedir. Bu parametreler, yükün tipine göre farklı değerler almaktadır.

Çizelge 3.1. Çeşitli yüklerin üstel değerleri (Van Cutsem ve Vournas, 1998.)

Yük Tipi	α	β
Elektrik Ampulü	1.54	----
Klimalar	0.5	2.5
Fırın Fanları	0.08	1.6
Şarj Cihazları	2.59	4.06
Elektronik Kompak Floresanlar	0.95-1.03	0.31-0.46
Geleneksel Floresanlar	2.07	3.21

Diğer bir yük modeli ise sabit akım, sabit empedans ve sabit gücü temsil eden ZIP yük modelidir (Genet, 2009). ZIP modeli literatürde yaygın olarak kullanılan ve lineer olmayan yük modellerindendir. ZIP modeli için aktif güç ifadesi Eşitlik 3.8’de verilmiştir. p_1 , p_2 ve p_3 katsayıları aktif güce ait yük bileşenlerinin oranını göstermektedir.

$$P = p_0 \left[p_1 \left(\frac{V}{V_0} \right)^2 + p_2 \left(\frac{V}{V_0} \right) + p_3 \right] \quad (3.8)$$

3.2.1.2. Sistemde üretim kaybı veya ani yüklenmeler

Sistemde çalışır durumdaki generatör, transformatör, hat gibi bir sistem elemanının herhangi bir nedenle devre dışı kalmasıyla, yükteki artış sistemi kararsızlığa götürür. Örneğin iletim hatları, ekonomik çalışma için kararlılık sınırlarında çalıştığından, bir arıza sonucunda devre dışı kalabilmektedir. Böyle bir durumda, hatların geri kalanı daha fazla yüklenecektir. Böylece hat empedans değerleri yükselir ve yükler için reaktif güç talebinin hızla artmasıyla hatlardaki reaktif güç ihtiyacı da artar. Sistemdeki aşırı reaktif güç talebi kararsızlık durumunu meydana getirebilir.


3.2.1.3. Şebekenin reaktif güç talebini karşılayamaması

Yukardaki örnek aynı zamanda reaktif güç talebinin karşılanamaması durumu için de örnek teşkil etmektedir. Reaktif güç elektrik motorları, transformatörler gibi bobinli

yapıların mıknatıslanmasında kullanılan güçtür. Aktif iş yapmayan ve sadece bu cihazlarda manyetik alan oluşturmaya yarayan reaktif güç, hatların ve transformatörlerin gereksiz yüklenmesine sebep olur. Bu da taşınabilecek elektriksel güç miktarını (hattın güç transfer kapasitesini) azalmasına neden olmaktadır. Aynı zamanda şebekede dolaşan reaktif gücün çok fazla olması aşırı ısınmaya neden olması nedeniyle güç kayıplarını artırır ve hattan geçen akımın artması nedeniyle istenmeyen gerilim düşüşlerine dolayısıyla hat sonu geriliminin azalmasına neden olmaktadır.

Bu nedenle aşırı yüklenmeler, gerilim düşmelerinin önlenmesi ve şebekeden en verimli şekilde faydalanılabilmesi için elektrik motorları, floresan lambalar, bobinler, kaynak makinaları gibi yüklerin çekmiş olduğu reaktif gücün bu yüklerin bulundukları noktadan veya bunlara en yakın yerden beslenmesi gerekmektedir.

Reaktif güç kompanzasyonu bu durum için kullanılabilir en etkili yoldur. Kompanzasyon yöntemleriyle akım ve gerilim arasındaki faz farkı en ideal olabilecek açığa getirilir ve sistemi olumsuz etkileyen reaktif güçler sıfıra yaklaştırılır. Böylece güç aktarım kapasitesi artırılmış, güç faktörü ($\cos \phi$) ve gerilim kararlılığı iyileştirilmiş olur. Güç faktörünün iyileştirilmesine örnek bir güç üçgeni Şekil 3.8’de ve ilgili formüller Eşitlik 3.9, Eşitlik 3.10 ve Eşitlik 3.11’de verilmiştir.



Şekil 3.8. Güç faktörü düzeltilmesi

$$Q_2 = Q_1 - Q_c \quad (3.9)$$

$$S_2 = \sqrt{P_1^2 + Q_2^2} \quad (3.10)$$

$$\cos \phi_2 = \frac{P_1}{S_2} \quad (3.11)$$

Tesis ve işletmelerde reaktif güç harcaması fazlaysa güç faktörü düşer ve tesis nominal kapasitesinin altında çalışmaya başlar. Bu durum gerilim düşümü ve kayıpların artmasıyla sonuçlanır. Kompanzasyon yapılması sonucu gereğinden fazla reaktif güç sistemde taşınmayacaktır. Buna bağlı olarak;

- Şebekedeki güç kayıpları azalır,
- Hattan daha fazla aktif enerji iletileceğinden üretim, iletim ve dağıtım sistemlerinin kapasitesi artar ve buna bağlı olarak verim yükselir,
- Şebekenin enerji (güç) taşıma kapasitesi artar,
- Şebeke iletkenlerinin kesitleri azalır,
- Isı kayıpları azalır.

Sistemdeki gerilimi kontrol etmek için reaktif gücü telafi edecek ek cihazlar kullanılmalıdır. Bu amaçlar için kullanılan cihazlar aşağıdaki gibi sıralanabilir:

Şönt kapasitörler: Güç faktörünün düzeltilmesinde sıklıkla tercih edilmektedirler. Sistemde farklı noktalara bağlanarak iletim ve dağıtım hatlarında sistemin verimliliğine katkı sağlarlar. Dağıtım hatlarında genellikle reaktif güç üretimi için kullanılırken, iletim hatlarında ağır yük koşullarında yeterli gerilim seviyelerini elde etmek için kullanılır (Demirören ve Zeynelgil, 2004). Maliyetlerinin düşük olması, kolay tesis edilmeleri ve esnek çalışmaları en önemli avantajlarıdır.

Seri kapasitörler: Seri kapasitörlerin kompanzasyon için kullanılması pratik ve ekonomik bir çözümdür. İletim hatlarında endüktif reaktansı kompanze etmek için hatta seri bağlanırlar. Böylece toplam reaktans azaltılarak iletilen maksimum gücün artması ve reaktif güç kaybının azalması sağlanır (Demirören ve Zeynelgil, 2004). Seri kapasitörlerin güç dağıtım sistemlerinde kullanımının yanı sıra, yükün doğal olarak dalgalandığı birçok uygulamada da kullanılabilirler.

Şönt reaktörler: İletim hatlarındaki kapasitif gücü kompanze ederek enerji sistem verimliliğini artırmak için kullanılan endüktif yüklerdir. Şebekeye paralel bağlanırlar. Şönt reaktörler hattan endüktif güç çekerek, hat kapasitesinin çektiği kapasitif gücü baskılar.

Senkron kondansatörler: Gerilim ve reaktif güç kontrolü sağlamak için kullanılan senkron motorlardır. Senkron makineler uyarma akımını kontrol ederek hem endüktif hemde kapasitif çalışabilen AC makinelerdir. Aşırı uyartılmış senkron motor şebekeye reaktif güç aktarırken düşük uyartımla senkron motor şebekeden reaktif güç çekmektedir (Al Hamrani, 2002).

Şebekeye bağlanan senkron motor şebekeden boşa çalışma kayıplarını karşılayacak kadar az bir aktif güç çeker ve şebekeye istenen reaktif gücü vererek, bir reaktif güç üreticisi şeklinde çalışır. Senkron motor, eğer kompanzasyon yapılan sistemde başka bir amaçla kullanılmıyorsa ekonomik değildir (Bayındır ve ark., 2008). Statik faz kaydırıcı olan kondansatörler daha ucuz ve bakımları daha kolay olduğundan dinamik faz kaydırıcı olan senkron motorlar genellikle tercih edilmemektedir.

Kondansatörler, statik faz kaydırıcılardır. Kondansatörlerin bakım masrafının olmaması ve ekonomik olmaları nedeni ile günümüzde reaktif güç kompanzasyonunda kullanılmaktadırlar. Reaktif güç sağlamak amacıyla kullanılan tüm cihazların yeri, koordinasyonu ve kapasitesi oldukça önem arz etmektedir.

FACTS Cihazları: Son yıllarda güç elektroniği teknolojisindeki gelişmelere bağlı olarak FACTS cihazlarına olan ilgi artmıştır. FACTS cihazları güç akışını kontrol etme kolaylığı sağladığından gerilim kararsızlığının çözümüne katkı sağlamaktadır. FACTS cihazları güç elektroniği tabanlı bir uygulama olduğu için diğer yöntemlere (şönt kapasitör, seri kapasitör, faz kaydırıcı vb.) göre daha hızlıdır (Ertay ve Aydoğmuş, 2012). FACTS cihazları tristör tabanlı ve konverter tabanlı olmak üzere ikiye ayrılmaktadır. Konverter tabanlı cihazlara SVC, STATCOM, Statik Senkron Seri Kompanzatör (SSSC) ve Birleşik Güç Akış Denetleyicisi (UPFC) örnek verilebilirken Tristör Kontrollü Statik Var Kompanzatör (TCVSC), Tristör Kontrollü Seri Kapasitör (TCSC) ve Tristör Kontrollü Faz Açısı Düzenleyicisi (TCPAR) tristör kontrollü cihazlardır.

3.2.1.4. Trafolarda kademe değişiklikleri

Düşük gerilim durumunda transformatörlerde kademe değiştirme yapılması gerilim kararsızlığına neden olan etmenlerdendir. Dağıtım sistemlerinde gerilim düzenlemesi genellikle yük altında kademe değiştiriciler (YAKD, On Load Tap Changer) ile yapılır. Günümüzde hemen hemen tüm büyük güç trafolarında YAKD bulunmaktadır. YAKD'ler gerilim kararlılığını bozmadan, kesintisiz ve güvenli bir şekilde gerilim düzenlemesi yapmakta ve sistemin verimliliğini önemli derecede artırmaktadır. YAKD'lerin tasarımının ve uygulanmasının kolay olması tercih edilme sebeplerindendir.

3.2.1.5. Generatör reaktif güç sınırları

İstenen sistem gerilimin elde etmek için gerilim regülatörleriyle generatörün alan akımı ayarlanarak generatör çıkış gerilimi kontrol edilebilir. Böylece güç sistemine verilen reaktif güç değeri de kontrol edilmiş olur. Sistem gerilimi düşerse, generatör, sistem gerilimini yükseltme eğiliminde olan güç sistemine reaktif güç enjekte edecektir. Sistem gerilimi yükselirse, generatörün reaktif çıkışı düşecek ve nihayetinde reaktif güç, sistem gerilimini düşürme eğiliminde olacaktır.

3.2.1.6. Enerjinin üretildiği yer ile tüketici arasındaki uzaklık

Elektrik enerjisinin üretildiği yer ile tüketildiği yer arasında çok uzun mesafeler olması iletim hatlarında reaktif gücün taşınmasına dolayısıyla da hatların, transformatörlerin gereksiz yüklenmesine neden olmaktadır. Ancak sistemde reaktif güç ihtiyacı olan yerin yakınında reaktif gücün üretilmesi sağlandığı takdirde bu sorun ortadan kalkacaktır.

3.2.1.7. İletim hatları ve trafoların karakteristikleri

İletim hatlarının uzunluğu ve kullanılan iletkenlerin özellikleri de güç sisteminin gerilimini etkileyen önemli parametrelerdir. Havai iletim hatları kapasitif ve endüktif karakteristiklerine göre reaktif enerjiyi azaltabilir ya da artırabilir. Yer altı kablolu hatlar ise genellikle normal yüklerinin altında yüklenirler (Yeşilbudak ve ark.,2015). Sahip oldukları yüksek kapasitif karakteristik nedeniyle genellikle kapasitif reaktif güç çekerler, böylece bağlı oldukları baralarda ihtiyaç duyulan reaktif gücü karşılayarak gerilim kararsızlığı olasılığını azaltabilirler (Akwukwaegbu ve Ibe, 2013).

3.2.1.8. Koruma ve kontrol cihazlarının koordinasyon eksikliği

Koruma ve anahtarlama cihazları arasında kurulacak doğru koordinasyon, elektriksel donanımın güvenliği ve de güvenilirliği için temel gereksinimlerden biridir. Cihazların uygun olmayan yerlere yerleştirilmesiyle cihazlar arasında dengesiz bir koordinasyon meydana gelebilir ve devre dışı kalabilir.

Ayrıca sistemde meydana gelebilecek aşırı yüklenmeler sonucunda koruma sistemlerinin devreye girerek hatların devreden çıkması istenmeyen bir durumdur. Koruma cihazlarındaki hatalı ve istenmeyen açmalar, istenmeyen elektrik kesintilerine neden olabilmektedir. Dolayısıyla bu durum da hem ekonomik kayıplara yol açarken hem de can ve mal güvenliğini olumsuz etkileyebilmektedir.

3.2.1.9. Güç kalitesi problemleri


Güç elektroniği tabanlı elemanların kullanımının artması elektrik yüklerinin doğasının tamamen değişmesine yol açmıştır. Bu yükler güç kalitesi sorunlarının ana nedenlerinden biridir. Doğrusal olmamaları nedeniyle gerilim dalga biçiminde bozulmalara neden olmaktadır. Güç kalitesi problemleri de doğrudan şebeke kararlılığını etkilemektedir. Güç kalitesi problemlerinin tespiti ve analizi iyi yapıldığı takdirde şebeke kararlılığına da katkısı büyük olacaktır.

Elektrik enerjisine olan talepteki hızlı artışa rağmen elektrik üretim, iletim ve dağıtım altyapısının paralel hızla gelişmemesi elektrik şebekelerinde güç kalitesi problemlerinin görülme sıklığının artmasına neden olmuştur. Güç kalitesi sorunlarının düzeltilmemesi durumu ise sistemi kararsızlığa sürükleyen bir etmen olarak karşımıza çıkmaktadır.

3.3. Güç Kalitesi Problemleri

Güç kalitesi değişkenlerinin durumunun, mevcut standartlarca sürekli olarak izlenmesi için TEDAŞ Genel Müdürlüğü'nde Milli Güç Kalitesi İzleme Merkezi kurulmuştur. Böylece güç ve güç kalitesi verilerinin sürekli olarak ölçümleri yapıp kayıt altına alınmakta ve değerlendirilmesi sağlanmaktadır. Elde edilen verilerden yola çıkılarak problemleri noktalar tespit edilebilmektedir.


Güç kalitesinde mevcut standartlar Şekil 3.9'da özetlenmiştir.



Şekil 3.9. Güç kalitesinde mevcut standartlar

Güç sistemlerinin güç kalitesi açısından izlenmesi ve sistemdeki hataların tespiti, dağıtım ve iletim sistemi operatörleri için büyük öneme sahip bir konudur.

Güç kalitesi olaylarının sınıflandırılmasını IEEE 1159-2019 standardınca 7 ana kategori altında inceleyebiliriz. Bu kategoriler Şekil 3.10’da gösterilmiştir.



Şekil 3.10. Güç kalitesi olaylarının sınıflandırılması

Geçici Rejim Olayları: Güç sistemlerinde anahtarlama olayları ve yıldırımdan kaynaklı durumlarda meydana gelebilen ani değişikliklerdir. ns, µs mertebelerinde oluşabilirler. Salınımlı ya da darbe şeklinde karşımıza çıkabilir.

Geçici rejim olaylarına sebep olan durumlar;

- 3-faz, fazlar arası, faz-toprak arızaları,
- Seri ve şönt kondansatör bankları ve şönt reaktörlerin anahtarlanması,
- Transformatörlerin devreye alınıp çıkartılması,
- Kesicilerin açılıp kapanması,
- Yüklerin devreye girip çıkması,
- Yıldırım düşmesi olarak sıralanabilir.

Kısa Süreli Değişimler: Şebekedeki arızalardan kaynaklı kesinti, gerilim çökmesi ve gerilim yükselmesi olarak karşımıza çıkabilen olaylardır.


Kısa süreli gerilim değişimleri;

- Bakım proseslerinin düzgün uygulanmaması,
- Güç sistemlerindeki hatalar,
- Ekipman yaşlanması,
- Yol verme akımları yüksek olan yüklerin devreye alınması,
- Dağıtım sistemindeki bağlantı kopuklukları,
- Yanlış manevralar gibi nedenlerden kaynaklanabilmektedir.

Uzun Süreli Değişimler: 1 dakikadan uzun süren güç frekansındaki efektif değer değişimlerini ifade eder. Sistemdeki yük değişiklikleri ile anahtarlamalardan kaynaklanmaktadır. Kesintiler, düşük gerilimler, aşırı gerilimler ve aşırı akımlar olarak karşımıza çıkmaktadır.

Gerilim Dengesizliği: 3 fazlı güç sistemlerinde her faza ait gerilim genlik değerleri birbirine eşit ya da çok yakın olmalıdır. Fazlar arasındaki gerilimlerin genlikleri arasında fark olması durumu gerilim dengesizliği olarak tanımlanmaktadır. Bir faz diğer fazlara göre daha fazla yüklendiğinde, bu fazdaki gerilim daha düşük olur. Gerilimi düşük olan fazdan beslenen transformatörlerin ve üç fazlı motorların çalışırken daha fazla ısınmasına, normalden fazla gürültü çıkarmasına, aşırı derecede titreşmesine ve arızalanmasına neden olabilir. Gerilim dengesizliğini değerlendirebilmek için simetrik bileşenler yöntemini bilmekte fayda vardır.

Dalga Formu Bozuklukları: Sağlıklı bir güç sisteminde gerilim ve akım dalga formları periyodik sinüzoidal formda olmalıdır. Şebeke frekansında, olması gereken dalga formundan uzaklaşmasıyla ortaya çıkan bozulmalardır. Şekil 3.11’de gösterildiği gibi 5 başlık altında incelenebilmektedir.



Şekil 3.11. Dalga formu bozuklukları

DC Bileşen: AC güç sisteminde DC gerilim veya DC akım bileşenin yer alması durumudur. Dengesiz çalışan güç konvertörleri veya yarım dalga doğrultucular nedeniyle oluşur ve güç transformatörlerini doymaya götürebilir.

Harmonik: Gerilim veya akım dalga şeklinin saf sinüzoidal halden sapmasıdır. Güç sisteminde artan güç kayıplarına, gerilim düşümlerine ve elektrik sisteminin verimli kullanılamamasına sebep olur.

Ara harmonik: Temel frekansın tam sayı katı olmayan bir frekans bileşenidir. Ara harmoniklerin etkilerinin çoğu harmoniklerin etkilerine benzer, ancak bazıları periyodik olmayan doğaları nedeniyle ara harmoniklere özgüdür. En temel iki etkisi ışıpta titreme (light flicker) ve iletişim hatlarında oluşturduğu parazitlerdir.

Çentik: 3 fazlı kontrollü veya kontrolsüz doğrultucuların sebep olduğu gerilimdeki bir bozulma olayı olarak tanımlanmaktadır.

Gürültü: Güç sistemlerinde istenmeyen, yüksek frekanslı bozulmalardır. Harmonik veya geçici olay olarak tanımlanamayan bozunumları içermektedir. Mikroişlemciler veya programlanabilir kontrolörlerin çalışmasını bozabilir.

Gerilim Değişimleri: Uzun süreli ve kısa süreli gerilim değişimleri olarak ikiye ayrılmaktadır. Uzun süreli gerilim değişimleri gerilimin efektif değerinde 1 dakikadan uzun süren değişimlerdir. Kısa süreli gerilim değişimleri, ani oluşan olaylar etkisi ile yarım periyotla 1 dakika arasında etki süresine sahip gerilimdeki değişimler olarak tanımlanabilir.

Uzun süreli gerilim değişimleri genellikle sistemdeki yük değişimlerinden ve sistem anahtarlama işlemlerinden kaynaklanır. Kısa süreli gerilim değişimlerine ise genellikle arıza koşulları neden olur. Büyük yüklerin enerjilendirilmesi veya güç

kablolarında gevşek bağlantılar nedeniyle oluşabilmektedir (IEEE Power and Energy Society, 2019).

Frekans Salınımları: Güç sisteminin çalışma frekansının, belirlenmiş nominal değerden sapması olarak tanımlanır. Güç sistemindeki talep edilen güç miktarı ile üretilen güç miktarının uyuşmamasından kaynaklanabilmektedir.

3.3.1. Güç kalitesi olaylarının sınıflandırılması

Güç kalitesi olaylarının meydana gelmesi elektriksel cihazların arızalanmasına, ömürlerinin kısılmasına veya tamamen zarar görmesine, sistemin verimliliğinin düşmesine ve sistemin kararlılığının bozulmasına neden olabilmektedir. Dolayısıyla güç kalitesi problemlerinin çözümlenebilmesi için öncelikle problemin çok iyi tanımlanması, sebeplerinin belirlenmesi ve sınıflandırılması gerekmektedir.

Çalışmada gerilim çökmesi, gerilim sıçraması, gerilim kesintisi, harmonik, fliker, salınımlı geçici durum, darbeli geçici durum, harmonikli gerilim çökmesi, flikerlı gerilim çökmesi, harmonikli gerilim sıçraması, flikerlı gerilim sıçraması kesinti ile harmoniğin aynı anda olduğu durum ve normal sinüs sinyali olmak üzere 13 güç kalitesi problemi üzerinde durulmuştur. Bu problemlerin oluşmasına neden olan durumlar incelenmiştir.

Gerilim Çökmesi

Gerilim çökmesi, şebeke frekansında çalışan bir güç sisteminde 10ms-60s zaman aralığında sınırlı olmak kaydıyla, gerilimdeki 0.1-0.9 pu arasında meydana gelen azalma olarak tanımlanır (IEEE Power and Energy Society 2019). Gerilim çökmeleri genellikle sistem arızalarıyla ilişkilidir. İletim ve dağıtım hatlarında oluşan kısa devreler, büyük güçlü yüklerin anahtarlanması, kapasitörlerin devreden çıkarılması, aşırı yüklenmiş devreler ve büyük güçlü motorların devreye girmesi gibi olaylar gerilimin çökmesine neden olurlar. Atmosferik koşullar (yıldırım düşmesi, şiddetli rüzgar, buz), hayvan teması, izolatörlerin kirlenmesi, inşaat kazaları, motorlu araç kazaları, düşme veya ağaç dallarına temas da gerilim düşmelerine neden olabilir. Bu tür arızalar 3 faz, faz-faz veya faz-toprak şeklinde olabilir. 3 fazlı arızalar en şiddetli olanlar olmasına karşın meydana gelme sıklığı bakımından daha az görülmektedir. Şebeke sistemindeki faz-toprak arızaları, bir endüstriyel tesisteki gerilim çökmelerinin en önemli nedenlerinden birisidir (Alonso Orcajo ve ark., 2005). EPRI (Electric Power Research Institute) çalışmasından


elde edilen ön sonuçlar, anlık gerilim çökmelerinin en önemli nedeninin yıldırım çarpmaları olduğunu göstermektedir. Gerilim çökmelerinin çoğunda, paralel fiderlerde gerilim nominal değerin yaklaşık %80'ine düşerken, arızalı fider daha az bir düşme değerine sahip olabilir veya arıza giderilemezse bir kesintiye neden olabilir.

1 dakikadan uzun süren gerilim çökmeleri, tipik olarak gerilim düzenleme ekipmanı tarafından kontrol edilebilir ve sistem arızaları dışında çok çeşitli nedenlerle ilişkilendirilebilir. Gerilimin çökmesiyle, bazı ekipmanlara ihtiyaç duydukları gerilim miktarı sağlanamayabilir ve performansları etkilenebilir (Krarti, 2018).

Gerilim çökmesinin büyüklüğü şebeke empedansı, arıza oluşum mesafesi, arıza yerindeki gerilim seviyesi, arıza anında bağlı yükler ve güç sistemindeki reaktif güç bileşenlerinden kaynaklanan gerilim iyileştirmesi gibi birçok faktöre bağlıdır. Gerilim çökmesinin süresi, dönen yüklerin dinamiği, sistem empedansı ve arıza giderme süresi tarafından belirlenir (Sivaraman and Sharmeela, 2021).

Gerilim çökmesi olayı kısa devre gücünün arttırılması, koruma cihazların selektivite ayarlarının değiştirilmesi kaynaktan geçici olarak bağlantıyı açma operasyonlarıyla çözümlenebilir. Ek olarak (Saidian ve ark., 2010)'da yapılan çalışmaya göre farklı boyutlardaki dağıtık üretim kaynaklarının (DÜK) şebekeye entegre edilmesiyle DÜK'nın boyutu büyüdükçe baralardaki gerilim çökmelerinin iyileştiği gözlemlenmiştir.


Şekil 3.12'de oluşturulan gerilim çökmesi için sinyal örneği verilmiştir. Oluşturulan sinyallerde x eksenini sinyalin uzunluğunu belirtmekte olup sinyal uzunluğu 1024 olarak belirlenmiştir. Y eksenini ise pu cinsinden ifade edilmiştir.



Şekil 3.12. Gerilim çökmesi

Gerilim Sıçraması

Gerilimin rms değerinde 1.1 ile 1.8 pu arasında artış olarak tanımlanır (IEEE Power and Energy Society, 2019). Gerilim sıçramaları, gerilim çökmeleri kadar sık görülmezler. Faz-toprak kısa devre arızası sırasında arızasız fazda geçici gerilim yükselmesi olabilir. Ayrıca büyük yüklerin anahtarlanması ve büyük kapasitör banklarının enerjilendirilmesinde de gerilim sıçramaları meydana gelebilmektedir. Şekil 3.13'te gerilim yükselmesi için sinyal örneği verilmiştir.




Şekil 3.13. Gerilim sıçraması

Gerilim Kesintisi

Bir veya daha fazla fazda besleme geriliminin kaybolması olarak tanımlanmaktadır. Kesintinin süresi bakımından incelendiğinde anlık gerilim kesintisi, geçici gerilim kesintisi, sürekli gerilim kesintisi olarak sınıflandırılmaktadır.

Şekil 3.14'te gerilim kesintisi sinyal örneği verilmiştir.



Şekil 3.14. Gerilim kesintisi

Harmonik


Güç sistemlerinin sağlıklı çalışabilmesi için üretilen gerilim ve akımın sinüzoidal formda olması gerekmektedir. Ancak günümüzde modern elektrikli ekipmanlar, yarı iletken teknolojilerinin kullanıldığı güç elektroniği cihazları ve doğrusal olmayan yükler sebebiyle sinüzoidal olmayan, yüksek frekanslı dalga formları görülebilmektedir. Bu bozulmalara harmonik adı verilir.

Harmonikler, güç sistemlerinde gerilim düşümlerine, kayıplara, kesicilerin hatalı çalışmasına, motorlarda sarsıntı ve verim düşümüne, hassas elektronik cihazların bozulmasına, kompanzasyon sistemlerinin aşırı yüklenerek arızalanmasına varıncaya kadar birçok ekonomik ve teknik probleme yol açarlar. Harmoniklerin elimine edilmediği sistemlerde oluşan gerilim düşümleri ve kayıplar, verimliliği düşürmekle birlikte sistem güvenliğini de riske atarlar. Eşitlik 3.12 ve Eşitlik 3.13'te harmonikli sistemler için güç formülleri ve Şekil 3.15'te harmonikli sinyal örneği verilmiştir.

$$S = \sqrt{P^2 + Q_T^2 + D^2} \quad (3.12)$$

$$Q_T = \sqrt{Q_1^2 + Q_h^2} \quad (3.13)$$

Verilen eşitliklerde Q_1 temel bileşen reaktif gücünü, Q_h harmonik reaktif gücü, Q_T toplam reaktif gücü, D ise distorsiyon (bozulma) gücünü temsil etmektedir.



Şekil 3.15. Harmonik

Harmoniklerin sisteme verdiği zararlar aşağıda sıralanmıştır.


- Kondansatörlerin, transformatörlerin, baraların ve kabloların aşırı ısınması
- Isınmalar sonucunda motor ve kondansatör ömrünün kısalması
- Merkezi ve uzaktan kumanda alıcılarının hatalı çalışması
- Gerilim düşmelerinin artması
- Şebekede beklenmeyen ve önceden kestirilemeyen rezonansların oluşması
- Trafolarda kayıpların artması ve izolasyonun zorlanması
- Generatör ve şebeke gerilimi dalga şeklinin bozulması
- Kesintisiz güç kaynaklarında yaşanan verim kayıpları
- Kompanzasyon tesislerinin aşırı reaktif yüklenmesi
- Kesici kesme kapasitesinin etkilenmesi
- Güç faktörü değişimi
- Şebekede rezonans olayları, rezonansın neden olduğu aşırı gerilim ve akımlar
- Akkor flamanlı lamba ömürlerinin kısalması
- Ölçü sistemlerinin ve sayaçların hatalı çalışması
- Güç kondansatörlerinde güç kayıpları, delinmeler ve patlamalar
- Sesli ve görüntülü iletişim araçlarında parazit

Harmonikleri elimine etmek için harmonik filtreleme yapılması gerekmektedir. Pasif ve aktif filtreler olmak üzere 2 çeşit harmonik filtre mevcuttur.

Fliker

Güç sistemi nominal frekans ve gerilimde çalışırken, gerilimin çeşitli nedenlerden dolayı daha düşük bir frekansta ve genlikte salınmasının sonucu olarak oluşmaktadır. Yani gerilimin tepe genliğinin salınması durumudur. Özellikle ark ocağı gibi ani değişen yükler söz konusu olduğunda baradaki gerilim belli sınırlar içerisinde salınmaktadır. EN 50160 standartlarına göre ölçüm süresinin %95'inde gerilim dengesizliği %2'yi geçmemelidir (Arıcı ve İskender, 2020). Baranın kısa devre gücünün değerlendirilmesi, bara için başka çözümler bulunması gerekmektedir. Flikerin büyüklüğü, gerilimin ne kadar değiştiğine ve bu değişimin frekansına bağlıdır.

Fliker, lambalarda parlaklığın dalgalanmasına, manyetik çekirdeğe sahip cihazlarda arızalara ve elektrik motorlarında hız değişimlerine neden olmaktadır. Şekil 3.16'da fliker için sinyal örneği verilmiştir.




Şekil 3.16. Fliker

Salınımlı Geçici Durum

Gerilim, akım veya her ikisinin kararlı durum koşullarında hem pozitif hem de negatif polarite değerlerini içeren çift yönlü ve ani bir frekans değişikliğidir. Bir salınımlı geçici olay, anlık değeri polariteyi birden çok kez hızla değiştiren ve normal olarak bir temel frekans döngüsü içinde azalan bir gerilim veya akımdan oluşur. Salınımlı geçici

olaylar büyüklüğü, süresi ve spektral içeriği ile tanımlanır. Geçici olaylar neredeyse her zaman bir tür anahtarlama olayından kaynaklanır. Yüksek frekanslı salınlımlı geçici olaylar, genellikle bir darbeli geçici olaya yerel bir sistem yanıtının sonucudur (IEEE Power and Energy Society, 2019).


Salınlımlı geçici olaylar kapasitör banklarının devreye alınması, büyük yüklerin devreden çıkarılması, hatların veya transformatörlerin enerjilendirilmesi sonucunda oluşmaktadır. Şekil 3.17’de salınlımlı geçici durum için sinyal örneği verilmiştir.



Şekil 3.17. Salınlımlı geçici durum

Darbeli Geçici Durum


Darbeli geçici olay, gerilim, akım veya her ikisinin nominal durumundan, tek yönlü, ani bir frekans değişikliğidir. Darbeli geçici durumlar tepe değerleri, yükselme ve azalma süreleri ile karakterize edilir. Darbeli geçici durumlara sebep olan en yaygın neden yıldırımdır. Şekil 3.18’de darbeli geçici durum için sinyal örneği verilmiştir.



Şekil 3.18. Darbeli geçici durum


Gerilim Çökmesi ve Flikerli Durum

Motorun çalıştırılması, aralıklı yükler, ark ocakları ve sistem arızası gibi durumların spesifik kombinasyonu ile meydana gelebilmektedir. Şekil 3.19’da gerilim çökmesi ve flikerli durum için sinyal örneği verilmiştir.




Şekil 3.19. Gerilim çökmesi ve flikerli durum


Gerilim çökmesi ve harmonikli durum için örnek sinyal Şekil 3.20’de, gerilim sıçraması ve harmonikli durum için Şekil 3.21’de, gerilim sıçraması ve flikerli durum için Şekil 3.22’de ve kesinti ve harmonikli durum için ise Şekil 3.23’te verilmiştir.




Şekil 3.20. Gerilim çökmesi ve harmonikli durum



Şekil 3.21. Gerilim sıçraması ve harmonikli durum




Şekil 3.22. Gerilim sıçraması ve flikerli durum



Şekil 3.23. Kesinti ve harmonikli durum


3.4. Makine Öğrenmesi Yöntemleri

Yapay zekanın alt dalı olarak nitelendirebileceğimiz makine öğrenmesinde makinelerin insan desteği olmaksızın öğrenmesi ve karar verebilmesi amaçlanmaktadır. Yapay zekâ ile makine öğrenmesi anlam açısından benzerlikler gösterse de farklı kavramlardır. Yapay zekâ, bilgisayarların insan zekâsını taklit etmesini sağlamayı hedeflemektedir. Şekil 3.24'te yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki gösterilmiştir.




Şekil 3.24. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki

Makine öğrenmesi ise kendisine sunulan veriler ve parametreler ile kendini eğitip insanların yapabileceğinden daha iyi çıkarımlar yapabilen sistemlerdir. Eğitim için kendisine sunulan verilerden öğrenir, tahmin modellerini oluşturur ve daha önce görmediği yeni verilerle karşılaştığında bunlar için bir sonuç üretir. Veri miktarı, sonucu daha doğru tahmin eden, daha iyi bir model oluşturmaya yardımcı olmaktadır. Şekil 3.25'te makine öğrenmesinin genel yapısı gösterilmiştir.



Şekil 3.25. Makine öğrenmesinin genel yapısı

Makine öğrenmesi, öğrenme algoritmalarına bağlı olarak Şekil 3.26'da gösterildiği gibi alt kategorilere ayrılmaktadır.




Şekil 3.26. Makine öğrenmesi algoritmaları

3.4.1. Denetimli öğrenme

Modele giriş verileriyle birlikte etiketlenmiş çıktı verilerinin de verildiği öğrenme çeşididir. Modele hem etiketlenmiş olan çıktı verileri hem de giriş verileri birlikte verilerek önce eğitilir sonrasında ise benzer giriş verileriyle test edilir. Etiketler aslında çıktı olarak almayı amaçladığımız sonuçlardır. Model kendi elde ettiği sonuçlar ile etiket değerlerini karşılaştırarak hataları bulur ve model üzerinde düzenlemeler yapabilir. Denetimli öğrenme algoritması genellikle tahmin ve sınıflandırma problemleri için kullanılmaktadır. Denetimsiz öğrenmeye göre daha basit ve güvenilir bir yapıya sahiptir. DVM, YSA, regresyon, rastgele orman algoritması gibi algoritmalar kullanılmaktadır.

Regresyon: Bir bağımlı değişken (y) ile diğer bağımsız değişkenler ($x_1, x_2, \dots$) arasındaki ilişkiyi açıklamaktadır. Bu yöntem genellikle değişkenler arasındaki neden-sonuç ilişkisini tahmin etmek amacıyla kullanılır. Regresyon analizi, bağımsız değişkenlerden bazıları değiştiğinde bağımlı değişkendeki değişimi anlamamıza yardımcı olmaktadır. Genel amaç ağırlık (w) parametrelerini hesaplayarak veri setine en uygun regresyon denklemini bulmaktır. Bu da gerçek gözlem değeri ile tahmin değerinin

arasındaki farkın minimum değerinde olması ile mümkündür. Regresyon teknikleri çoğunlukla bağımsız değişkenlerin sayısına ve bağımsız ve bağımlı değişkenler arasındaki ilişkinin türüne göre farklılık göstermektedir. Şekil 3.27’de regresyon çeşitleri verilmiştir.



Şekil 3.27. Regresyon çeşitleri

Doğrusal regresyon: İki değişken arasında doğrusal bir ilişki kurarak tahminde bulunur. Doğrusal regresyon denklemi aşağıda verilmiştir. Denklemlerde y bağımlı değişkeni, w ağırlığı, e ise hatayı temsil etmektedir. Eşitlik 3.14’te doğrusal regresyon denklemi verilmiştir.

$$y = w_0 + w_1x + e \quad (3.14)$$

Çoklu doğrusal regresyon: Basit bir doğrusal regresyonda bir adet bağımsız değişken (x) varken çoklu doğrusal regresyonda birden fazla bağımsız değişken bulunmaktadır. Çoklu doğrusal regresyon denklemi Eşitlik 3.15’te verilmiştir.

$$y = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n + e \quad (3.15)$$

Hem doğrusal regresyonun hem de çoklu doğrusal regresyonun temel çözümü en küçük kareler yöntemine dayanmaktadır.


Doğrusal olmayan regresyon: Değişkenler arasında doğrusal bir ilişki olabileceği gibi doğrusal olmayan bir ilişki de olabilmektedir. Doğrusal regresyonun aksine analitik çözümler bulmak zor olacağından iteratif yöntemler kullanılarak sonuca ulaşılmaktadır. Günlük hayattaki problemlerin çözümü genellikle doğrusal olmadığından doğrusal olmayan regresyon çözüm için daha uygun olabilmektedir. Denklemdaki

parametre sayısı verideki değişken sayısı ile doğrudan ilişkili olmayabilmektedir. Doğrusal olmayan regresyon denklemi Eşitlik 3.16'da verilmiştir.

$$y = w_0 + w_1x + w_2x^2 + \dots + w_nx^n \quad (3.16)$$

Doğrusal olmayan regresyon modellerinin parametre tahminleri için pek çok yöntem bulunmaktadır. En küçük kareler, en çok olabilirlik (Maksimum Likelihood) ve Gauss-Newton yöntemleri bunlardan en çok bilinenleridir.

Sınıflandırma: Makinenin verilen eğitim verileri ile öğrendiği daha sonra karşılaştığı yeni veriler için daha önce öğrendiklerinden yola çıkarak yeni genellemeler yapmasıdır. Şekil 3.28'de sınıflandırma ve regresyon için örnek dağılım grafikleri verilmiştir.




Şekil 3.28. Sınıflandırma ve regresyon örneği (Belkacem, 2021)

Naive Bayes Sınıflandırıcı, DVM, Karar Ağaçları, Rastgele Orman Algoritmaları, lojistik regresyon, YSA, KNN gibi makine öğrenmesi sınıflandırma algoritmalarından 3.6 bölümünde detaylı olarak bahsedilecektir.

3.4.2. Denetimsiz öğrenme

Modelin kendi kendine verilerden anlam çıkarıp sınıflandırma veya kümeleme yapabildiği öğrenme çeşididir. Modele çıktı verileri sunulmaz, etiketsiz verilerle eğitim gerçekleştirilir. Dolayısıyla model önceki tecrübelerinden yola çıkarak olaylar arasında kurduğu bağlantı ile sonuçlar üretmektedir. Sınıf sayısı belli değildir ve denetimli öğrenmeye göre daha karmaşık bir yapıya sahiptir. Denetimsiz öğrenme algoritması

kümeleme ve boyut azaltımında tercih edilmektedir. Kümeleme, K-Means Kümeleme, Hiyerarşik Kümeleme gibi algoritmalar kullanılmaktadır. Şekil 3.29’da kümeleme için örnek verilmiştir.



Şekil 3.29. .Kümeleme için örnek (Abualigah, Khader and Hanandeh, 2018)

3.4.3. Yarı denetimli öğrenme

Genellikle etiketlenmemiş veri sayısının etiketlenmiş veri sayısından fazla olduğu denetimsiz öğrenme ve denetimli öğrenme arasında bir öğrenme şeklidir. Model etiketli verilerden yaptığı çıkarımlarla etiketlenmemiş veriler için de tahmin üretip genelleyerek bir sonuç çıkarması amaçlanmaktadır. Genel anlamda model, verileri kendi kendine keşfetmekte ve veri kümesine ilişkin kendi anlayışını geliştirmektedir.

3.4.4. Pekiştirmeli öğrenme (Reinforcement learning)


Eğitim verisi olmadan, algoritmanın içinde bulunduğu duruma vereceği tepkiler sonucunda ödüllendirme sistemi ile eğitilen ve bunun neticesinde ne kadar doğru ya da yanlış tepkiler verdiğini tecrübe eden makine öğrenmesi çeşididir. Yani algoritma hedefe yönelik doğru bir tepkisinde pozitif ödül alacak şekilde, bu hedeften uzaklaştığında ceza alacak şekilde programlanır. Ödül ve cezalar bir defaya mahsus ayarlanır ve verdiği tepkiler neticesinde tecrübelerinden yola çıkarak yönelimini gerçekleştirir. Böylece deneme yanılma yoluyla çevreden aldığı tepkiler ile eğitilmesi amaçlanmaktadır.

3.5. Sınıflandırma Algoritmaları

3.5.1. Destek vektör makineleri (DVM)

DVM'nin daha az hesaplama gücü ile önemli doğruluk oranları verdiği için literatürde önemli bir yeri bulunmaktadır. Sınıflandırma ve regresyon problemlerinin ikisi için de kullanılabilir ancak sınıflandırma problemlerinde sıklıkla tercih edilmektedir.

DVM algoritmasının amacı, yeni veri noktasının kolayca doğru kategoride yer alabilmesi için n-boyutlu uzayı sınıflara ayırabilen en iyi karar sınırını oluşturmaktır. Bu en iyi karar sınırı hiperdüzlem olarak adlandırılmaktadır. DVM'nin diğer sınıflandırıcılara göre en büyük avantajı, küçük bir veri kümesi için bile doğru, etkili ve güçlü olmasıdır (Lv ve ark., 2005). Şekil 3.30 'da DVM sınıflandırıcıyı göstermektedir. Veri setlerinin doğrusal olup olmaması durumuna göre ikinci dereceden DVM, Polinomal DVM, kübik DVM kullanılabilmektedir.



Şekil 3.30. DVM sınıflandırıcı

3.5.2. K en yakın komşu algoritması (KNN)

KNN hem sınıflandırma hem de regresyon için kullanılan yöntemlerdendir. Kolay yorumlanması ve hesaplama süresinin düşük olması tercih edilme nedenlerindendir (Cai ve ark., 2017). KNN algoritması benzer verilerin birbirine yakın olacağı varsayımına dayanmaktadır. Sınıfı bilinmeyen bir verinin, eğitim setindeki diğer veriler ile karşılaştırılıp bir uzaklık ölçümü gerçekleştirilmesi sonucu hesaplanan uzaklığa göre henüz bir sınıfa atanmamış verinin, en ideal (optimal) sınıfa atanarak sınıflandırılması olarak ifade edilmektedir (Razmi ve ark., 2021).

3.5.3. Karar ağaçları

Ağaç formunda bir yapıya sahip bir akış şeması ile sunulduğu, tahmine dayalı bir modeldir. Hem sınıflandırma hem de regresyon için kullanılmaktadır. Bu yöntemde öznitelikler bir ağaç olarak kullanılarak verilerin daha küçük alt kümelerle parçalanması gerçekleştirilir ve daha iyi anlaşılması için if-then kuralları kullanılarak yazılır (Rokach ve Maimon, 2014). Eğitim verilerine bağlı olarak, bu yöntemin her aşamasında veriler için bir öznitelik seçilir ve veri seti, seçilen özniteliklere dayalı olarak başka bir sınıf gruplamasına ayrıştırılır. Bu işlem, bir kategorideki tüm veriler tek bir etikete sahip oluncaya kadar devam eder.

Karar ağaçları anlaşılmasının, yorumlanmasının kolay olması ve güvenilirliklerinin iyi olmasından ötürü en yaygın kullanılan yöntemlerden biridir.

3.5.4. Rastgele orman algoritması

Algoritma temelde karar ağaçlarına dayanmaktadır. Eğitim aşamasında çok sayıda karar ağacı oluşturularak problemin tipine göre tahmin yapılmaktadır. Algoritmadaki ağaç sayısı ve elde edilebilecek sonuç arasında doğrudan bir ilişki bulunmaktadır. Ağaç sayısı arttıkça daha kesin sonuçlar elde edilebilmektedir.

Hem sınıflandırma hem de regresyon işlemleri için kullanılan bir yöntem olması ve sınıflandırma problemlerindeki uygulamalar için aşırı uyum (overfitting) problemini önlemesi tercih edilme nedenlerindendir.

3.5.5. Topluluk öğrenme modelleri (Ensemble models)

Topluluk öğrenme modelleri birden fazla modeli bir araya getirmenin genellikle çok daha güçlü bir model üretebileceği hipotezine dayanır. Bu nedenle bir problemi çözmek için bir araya gelen birden fazla modelden oluşurlar. Bir araya gelen modellerin ürettiği tahminler birleştirilerek doğruluğu arttırmak amaçlanmaktadır. Topluluk öğrenme modelleri Torbalama (Bagging, Bootstrap Aggregating), Artırma (Boosting) ve İstif (Stacking) olmak üzere üç grupta incelenmektedir.

Torbalama: Orijinal veri kümesinden çoklu alt kümeler oluşturulur. Bu kümeler eğitim ve test aşamalarından geçirilir. Nihai tahminler, tüm modellerden gelen tahminler

birleştirilerek belirlenir. Sınıflandırma problemlerinde tahmin sonucu modellerden elde edilen çoğunluk oylama sonuçlarına göre karar verilerek belirlenir.


Artırma: Bir dizi zayıf sınıflandırıcıdan güçlü bir sınıflandırıcı oluşturmaya çalışan bir topluluk tekniğidir. Zayıf modeller seri halinde kullanılarak modeller oluşturulur. Modeller tahminleri geliştirmek için sıralı ve uyarlanabilir bir şekilde öğrenirler. Son model (güçlü sınıflandırıcı), tüm modellerin ağırlıklı ortalamasıdır.

İstif: En büyük yararı iyi performans gösteren modelin yeteneklerinden yararlanabilmesi ve topluluktaki herhangi bir tek modelden daha iyi performansa sahip tahminler yapabilmesidir. Bu nedenle gelen tahminlerin en iyi şekilde nasıl birleştirileceğini öğrenmek için bir meta-öğrenme algoritması kullanır.

3.6. Yapay Sinir Ağları (YSA)

YSA'nın çalışma şeklini insanlardaki sinir sisteminin çalışmasına benzetebiliriz. İnsanlar doğdukları andan itibaren bir öğrenme sürecine girerler. Gördükleri, tecrübe ettikleri, yorumladıkları olguları sonuçlara dönüştürürler. YSA ile insanlardakine benzer şekildeki bu öğrenme mantığının makinelerle uyarlanması sağlanmaktadır. Böylece makinelerin eğitilmesi, öğrenmesi ve öğrendiklerinden yola çıkarak karar vermesi amaçlanmaktadır.

İnsandaki sinir hücresinin yapısı dentrit, hücre gövdesi, akson ve sinapstan oluşmaktadır. Şekil 3.31'de insan sinir hücresi ile yapay nöronun benzetimi verilmiştir.



Şekil 3.31. İnsan sinir hücresi ile yapay nöronun karşılaştırılması

Dentrit: Hücreye gelen girişleri toplar.


Hücre gövdesi: Dentrit tarafından alınan işaretler birleştirilerek çıkış sinyallerine çevrilir.

Akson: Çıkış sinyalleri taşınarak diğer nöronlara iletilir.

Sinaps: Nöronlar arasındaki bağlantıyı sağlar.


Tek katmanlı YSA'lar yalnızca girdi ve çıktı katmanından oluşan bir YSA yapısı iken çok katmanlı ağlar (ÇKA) bilgi girişinin yapıldığı girdi katmanı, bir veya daha fazla gizli (ara) katman ve bir çıktı katmanından oluşmaktadır. Doğrusal olmayan problemlerin çözümünde tek katmanlı YSA'ların yetersiz kalmasıyla ÇKA'lar geliştirilmiştir. Gizli katman sayısı arttıkça modelin karmaşıklaştığını söylemek mümkündür.

Derin öğrenmede kullanılan yapay sinir ağlarında girdi ve çıktılar arasında birden fazla gizli katman bulunmaktadır. Bu nedenle derin öğrenmede kullanılan YSA'ların yapısı ve öğrenme süreci daha karmaşıktır. Makine öğrenmesi ve derin öğrenme genel olarak sınıflandırma, kümeleme ve regresyon problemlerinde kullanılmaktadır. Şekil 3.32'de genel YSA yapısı verilmiştir.



Şekil 3.32. YSA'nın genel yapısı


Giriş verisi olarak YSA'ya verilen veriler bazı ağırlık değerleri ile beraber çeşitli işlemlerden geçirilerek çıkışa taşınır. Şekil 3.33'te bir sinir hücresinin matematiksel modeli verilmiştir.



Şekil 3.33. YSA'nın matematiksel modeli


Giriş değerleri ($x_1, x_2, \dots, x_n$), ağırlık değerleriyle ($w_1, w_2, \dots, w_n$) çarpılır ve belli bir eşik değerini aştığında aktivasyon fonksiyonuna iletilir. Toplama fonksiyonu bir nörona gelen net girdiyi hesaplar. Bunun için çeşitli fonksiyonlar kullanılmaktadır. En yaygın olan ise ağırlıkların giriş değerleri ile çarpımının toplanmasıdır ($w_1x_1 + w_2x_2 + \dots + w_nx_n$). Ağırlık ve girdilerin çarpımının elde edilen toplamına eklenmesi gereken bias değeri (b) vardır. Bir sinir ağının başarılı bir tahminde bulunabilmesi için elde edilen doğrusallığın doğrusal olmayan hale dönüştürülmesi gerekir. Bunun için aktivasyon fonksiyonu kullanılmaktadır. Aktivasyon fonksiyonu ağın başarısını ciddi anlamda etkilediğinden aktivasyon fonksiyonunun seçimi probleme uygun olacak şekilde yapılmalıdır.

YSA'lar yapısına göre ileri beslemeli ve geri beslemeli olmak üzere 2'ye ayrılır. İleri beslemeli ağlarda modele verilen bilgiler önce giriş katmanından sonra gizli katmanlardan geçerek çıkış katmanına ulaşır ve sonuç elde edilir. Yani giriş katmanından çıkışa doğru tek yönlü bir hareket söz konusudur. Şekil 3.34'te örnek bir ileri beslemeli YSA'nın yapısı gösterilmiştir.



Şekil 3.34. İleri beslemeli bir YSA'nın yapısı

Geri beslemeli ağlarda ise bir nöronun çıktısı kendi katmanında veya kendinden önceki katmanda bulunan bir nörona girdi olarak verilebilir. Şekil 3.35'te örnek bir geri beslemeli YSA'nın yapısı gösterilmiştir.



Şekil 3.35. Geri beslemeli bir YSA'nın yapısı

Günümüzde uzay, otomotiv, bankacılık, savunma, finans, robotik, telekomünikasyon, güvenlik gibi birçok farklı alanda YSA'lar kullanılmaktadır. Böylece insanların günler, haftalar içinde yapacağı işleri YSA saniyeler içerisinde gerçekleştirebilmektedir.

3.6.1. Yapay sinir ağlarında öğrenme

YSA tıpkı insan beyni gibi öğrenebilen bir yapıdadır. Üzerinde çalışılacak olan veri seti öncelikle eğitim ve test verileri olmak üzere gruplanır. Genellikle verilerin %70-80'i eğitim verisi olarak geri kalan kısmı da test verisi olarak belirlenmektedir. Eğitim verisi üzerinden ağın eğitimi tamamlanıp test verileri üzerinde değerlendirmesi yapılır. Eğitim aşamasında ağı fazla çalıştırılırsa ağ verileri öğrenmek yerine verileri ezberleyecek bu da aşırı uyuma (overfitting) sebep olacaktır. Bu durumun sonucu olarak eğitim aşaması çok yüksek başarı ile tamamlanmasına karşın test aşamasına geçildiğinde düşük doğruluk oranları ile karşılaşma ihtimalimiz fazla olacaktır. Çünkü ağ eğitim esnasında ezberlediği verileri test verisinde arayacaktır. Ancak benzer veriler için doğru sonuçlar üretemeyecektir. Bu durumu engellemek için test veri seti içerisinde bir kısım ayrılarak doğrulama (validation) veri seti oluşturulur. Doğrulama sırasında optimum ağırlık değerlerinin bulunması amaçlanır. Bulunan ağırlık değerleri test verileri üzerinde test edilerek aşırı uyum olup olmadığı değerlendirilebilir. Böylece ağıımızın test verilerine aşırı uyum göstermesinin ya da eksik öğrenmesinin önüne geçilir.

YSA'da öğrenme algoritmaları denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak 3'e ayrılır.

Denetimli öğrenmede hem giriş verileri hem de etiket değerleri verilerek ağın eğitimi gerçekleştirilir. Sonrasında ağ ilk kez karşılaştığı verilerle test edilir. Eğitim aşamasında öğrendiklerinden yola çıkarak ağın daha önce karşılaşmadığı veriler için sonuç üretmesi beklenir.

Denetimsiz öğrenmede sadece giriş değerleri ağa verilir. YSA'nın kendi kendine öğrenerek çıkarım yapması beklenir.

Pekiştirmeli öğrenmede giriş verileri ağa verilir ve elde edilen sonucun danışman tarafından değerlendirilmesi istenir. Ödüllendirme ve cezalandırma yöntemiyle ağın ağırlıkları güncellenir.


3.6.1.1. Öğrenme Algoritmaları

YSA eğitim aşamasında başlangıçta rastgele ağırlık değerleri ile başlayıp ileri yayılım ile gizli katmanlardan ve çıktı katmanından geçerek bir çıkış değeri üretmektedir. Hatayı belirleyebilmek için ağdan alınan bu çıkış değeri ile gerçek değer arasında ne kadar fark olduğunun hesaplanması gerekmektedir. Amacımız optimum parametre

değerlerini bularak hata fonksiyonunu minimuma indirmektir. Hata fonksiyonuna maliyet (cost) fonksiyonu da denmektedir. Bu hata fonksiyonu genellikle kare hatası (Square Error) formülü ile hesaplanır. Eşitlik 3.17’de hata fonksiyonunu ifade eden denklem verilmiştir.

$$E_{\text{toplaml}} = \sum \frac{1}{2} (\text{gerçek değer} - \text{YSA'nın çıkış değeri})^2 \quad (3.17)$$

YSA’nın verilerle beslenerek ağdan çıkış alınması ileri yayılım olarak ifade edilmektedir. Bu aşamanın sonunda elde edilen çıkışlar hata fonksiyonuna verilir ve hatalar geriye yayılarak ağırlıklar güncellenir. Hata fonksiyonunun değeri büyük çıktığında yapılan bu işlemden geri yayılım (backpropagation) algoritması kullanılmaktadır. Şekil 3.36’da geri yayılım algoritmasının çalışma prensibi verilmiştir.



Şekil 3.36. Geri yayılım algoritmasının çalışması

Hata fonksiyonunun sonucunu minimum değer olan sıfıra yaklaştırabilmek için gradyan iniş metodu kullanılır. Sonuç sıfıra yaklaştıkça, çıkış değerleri de beklenen değerlere yaklaşır.

3.6.2. Yapay sinir ağlarının aktivasyon fonksiyonları


Aktivasyon fonksiyonları YSA’nın başarımını belirleyen en önemli parametrelerden biridir. Basamak fonksiyonu, Sigmoid, tanh, ReLU, softmax gibi fonksiyonlar sıklıkla kullanılmaktadır.

Basamak (Step) Fonksiyonu: Gelen giriş verisi için belirlenen bir eşik değerin altında veya üstünde olmasına göre çıkış verir.

Tek katmanlı YSA'da yaygın olarak kullanılmaktadır

Basamak aktivasyon fonksiyonunun denklemi Eşitlik 3.18'de, grafiği ise Şekil 3.37'de verilmiştir.


$$y = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (3.18)$$



Şekil 3.37. Basamak fonksiyonu

Sigmoid fonksiyonu: Değişkenleri 0 ile 1 arasında bir değere dönüştürmektedir. Softmax fonksiyonunda modeldeki tüm bağımlı değişkenler kategorik ölçekte ise kullanılmaktadır. Sigmoid fonksiyonunun eşitliği Eşitlik 3.19'da, grafiği ise Şekil 3.38'de verilmiştir.

$$\sigma = \frac{1}{1+e^{-z}} \quad (3.19)$$




Şekil 3.38. Sigmoid aktivasyon fonksiyonu

Tanh fonksiyonu: Değişkenleri -1 ile 1 arasında bir değere dönüştürmektedir. Düşük girdi değerleri -1'e yakın değerler verirken yüksek girdi değerleri çıktı olarak 1'e

yakın değerler vermektedir. Tanh fonksiyonunun denklemi Eşitlik 3.20’de, grafiği ise Şekil 3.39’da verilmiştir.

$$\sigma = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (3.20)$$




Şekil 3.39. Tanh fonksiyonu

ReLU: Gelen girdi değeri 0’dan büyük ise değeri değişmeden çıktı olarak verilir. Girdi 0’dan küçük ya da eşit ise çıktı 0’dır. Relu fonksiyonunun en belirgin avantajı nöronları aynı anda aktive etmemesidir. Yani bir nöron negatif değer üretirse, aktive edilmez. Bu da ReLU’nun tanh ve sigmoid fonksiyonundan daha verimli ve hızlı çalışması demektir.

Dezavantajı ise fonksiyonun türevi negatif değerlerde sıfır olduğundan Geri Yayılım (Back Propagation) esnasında parametrelerimizin değeri güncellenmez. Dolayısıyla öğrenme işlemi yapılamaz. Bu probleme Dying ReLU adı verilir.

ReLU fonksiyonunun denklemi Eşitlik 3.21’de grafiği ise Şekil 3.40’ta verilmiştir.


$$a = \max(0, z) \quad (3.21)$$



Şekil 3.40. ReLU fonksiyonu

Leaky RELU: Dying ReLU problemine karşı geliştirilen çözümlerden biridir. Leaky ReLU’da negatif değerler sıfıra çok yakındır fakat tam sıfır değildir. Böylece türevinin sıfır olması engellenmiş olur. Bu durum geri yayılım (Back Propagation) esnasında öğrenmenin negatif tarafta da gerçekleşeceği anlamına gelir. Leaky ReLU fonksiyonunun denklemi Eşitlik 3.22’de grafiği ise Şekil 3.41’de verilmiştir.


$$a = \max(0.01 \cdot z, z) \quad (3.22)$$



Şekil 3.41. Leaky ReLU fonksiyonu

Softmax: Verilen her bir girdi için bir sınıfa ait olma olasılığını gösteren $[0,1]$ arası çıktılar üretmektedir. Çoklu sınıflandırma problemleri için kullanılmaktadır. Softmax fonksiyonunun denklemi Eşitlik 3.23’te grafiği ise Şekil 3.42’de verilmiştir.

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad (j=1, \dots, K \text{ için}) \quad (3.23)$$



Şekil 3.42. Softmax fonksiyonu (Mittal ve ark., 2020)

3.7. Performans Metrikleri

Yapılan çalışmanın değerlendirilmesinde doğruluk, hata, duyarlılık, özgünlük ve kesinlik metrikleri kullanılmıştır. Bu metrikler karmaşıklık matrisinden alınarak hesaplanan değerlerdir. Şekil 3.43'te örnek bir karmaşıklık matrisi gösterilmiştir.

		Tahmin Edilen Sınıf	
		a_1	a_2
Gerçek Sınıf	a_1	DP	YN
	a_2	YP	DN

Şekil 3.43. Örnek bir karmaşıklık matrisi

Şekil 3.43'te karmaşıklık matrisinde yer alan a_1 ve a_2 ifadeleri sınıfları, DP, YN, YP ve DN değerleri sırasıyla Doğru Pozitif, Yanlış Negatif, Yanlış Pozitif ve Doğru Negatif değerlerini ifade etmektedir.

Doğru Pozitif (DP): Gerçekte a_1 sınıfında olan verilerden a_1 sınıfında olarak tahmin edilen veri sayısıdır.

Yanlış Negatif (YN): Gerçekte a_1 sınıfında olan verilerden a_2 sınıfında olarak tahmin edilen veri sayısıdır.

Yanlış Pozitif (YP): Gerçekte a_2 sınıfında olan verilerden a_1 sınıfında olarak tahmin edilen veri sayısıdır.

Doğru Negatif (DN): Gerçekte a_2 sınıfında olan verilerden a_2 sınıfında olarak tahmin edilen veri sayısıdır.

Şekil 3.44'te ise çoklu sınıflandırma problemlerinde kullanılan karmaşıklık matrisi gösterilmiştir.

		Tahmin Edilen Sınıf				
		a_1	a_2	a_3		a_n
Gerçek Sınıf	a_1	D_1	Y_{12}	Y_{13}	...	Y_{1n}
	a_2	Y_{21}	D_2	Y_{23}	...	Y_{2n}
	a_3	Y_{31}	Y_{32}	D_3	...	Y_{3n}
		...	...	...	...	...
	a_n	Y_{n1}	Y_{n2}	Y_{n3}	...	D_n

Şekil 3.44. Çoklu sınıflandırma problemlerinde kullanılan karmaşıklık matrisi

Şekil 3.44'te karmaşıklık matrisinde yer alan D doğru sınıflandırılan verileri Y ise yanlış sınıflandırılan verileri ifade etmektedir. Bu karmaşıklık matrisinin nasıl yorumlanacağı örnek olarak aşağıda açıklanmıştır.

D_1 : Gerçekte a_1 sınıfında olup a_1 sınıfında olarak tahmin edilen veri sayısıdır.

Y_{12} : Gerçekte a_1 sınıfında olup a_2 sınıfında olarak tahmin edilen veri sayısıdır.

Y_{13} : Gerçekte a_1 sınıfında olup a_3 sınıfında olarak tahmin edilen veri sayısıdır.

Y_{1n} : Gerçekte a_1 sınıfında olup a_n sınıfında olarak tahmin edilen veri sayısıdır.

Y_{21} : Gerçekte a_2 sınıfında olup a_1 sınıfında olarak tahmin edilen veri sayısıdır.

D_2 : Gerçekte a_2 sınıfında olup a_2 sınıfında olarak tahmin edilen veri sayısıdır.

3.7.1. Doğruluk

YSA'nın eğitimi ve testi tamamlandıktan sonra oluşturulan karmaşıklık matrisinde yer alan, doğru olarak sınıflandırılan veri sayısının toplam veri sayısına oranıdır. Dengesiz dağılıma sahip veri kümelerinde sağlıklı sonuç vermez. Doğruluk metriği Eşitlik 3.24 ile ifade edilir.

$$\text{Doğruluk(Accuracy)} = \frac{DP+DN}{DP+YN+DN+YP} \quad (3.24)$$

3.7.2. Hata

Karmaşıklık matrisinde yer alan yanlış sınıflandırılan veri sayısının toplam veri sayısına oranıdır. Doğruluk metriği hesaplandıktan sonra 1'den çıkarılarak da hesaplanabilir. Hata metriği Eşitlik 3.25 ile ifade edilir.

$$\text{Hata(Error)} = 1 - \text{Doğruluk} \quad (3.25)$$

3.7.3. Duyarlılık

Pozitif olarak tahmin edilmesi gereken veri sayısının kaç tanesinin pozitif olarak tahmin edildiğini göstermektedir. Recall olarak da ifade edilmektedir. Duyarlılık metriği Eşitlik 3.26 ile ifade edilir.

$$\text{Duyarlılık(Sensitivity)} = \frac{DP}{DP+YN} \quad (3.26)$$

3.7.4. Özgünlük

Gerçekte negatif sınıfa ait olan verileri doğru olarak tahmin etme oranını ifade etmektedir. Özgünlük metriği Eşitlik 3.27 ile ifade edilir.

$$\text{Özgünlük(Specifity)} = \frac{DN}{DN+YP} \quad (3.27)$$

3.7.5. Kesinlik

Karmaşıklık matrisinde yer alan pozitif gruptaki verilerin kaç tanesinin doğru sınıflandırıldığını ifade etmektedir. Kesinlik metriği Eşitlik 3.28 ile ifade edilir.

$$\text{Kesinlik(Precision)} = \frac{DP}{DP+YP} \quad (3.28)$$

3.7.6. F1 skoru

Kesinlik ve duyarlılık değerlerinin harmonik ortalamasını ifade etmektedir. Dengesiz dağılımlı veri setlerinde doğruluk metriği kullanmak hatalı olacağından yerine F1 Skoru değerine bakılabilir. F1 Skoru Eşitlik 3.29 ile ifade edilir

$$\text{F1 Skoru(F Measure)} = 2 \frac{\text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} = \frac{2\text{DP}}{2\text{DP} + \text{YN} + \text{YP}} \quad (3.29)$$



4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Tez çalışmasında şebeke kararlılığına bozucu etkisi olan sinyaller çeşitli matematiksel yöntemler ile üretilmiştir. Bu sinyallerden özellik çıkarımı yapılarak sinyallerin makine öğrenmesi yöntemleriyle ve YSA ile sınıflandırılması gerçekleştirilmiştir.

4.1. Kararlılığı Bozucu Sinyallerin Elde Edilmesi


Çalışmada gerilim çökmesi, gerilim sıçraması, gerilim kesintisi, harmonik, fliker, salınımlı geçici durum, darbeli geçici durum, harmonikli gerilim çökmesi, flikerlı gerilim çökmesi, harmonikli gerilim sıçraması, flikerlı gerilim sıçraması, kesinti ile harmoniğin aynı anda olduğu durum ve normal sinüs sinyali olmak üzere güç sistemlerinin kararlılığını bozan 13 farklı güç kalitesi problemi üzerinde durulmuştur.

Bu güç kalitesi problemlerinin sınıflandırılabilmesi için öncelikle Çizelge 4.1'deki matematiksel ifadelerden sinyaller üretilmiştir. Her sınıf için 1000 adet sinyal üretimi gerçekleştirilmiş, toplamda 13000 adet sinyal üzerinde çalışılmıştır. Kullanılan güç kalitesi problemlerinin sınıfları ve bu sınıflara karşılık gelen matematiksel ifadeler Çizelge 4.1'de verilmiştir. Çalışma Matlab ortamında gerçekleştirilmiştir.

Çizelge 4.1. Güç kalitesi sinyallerinin matematiksel denklemleri

Güç Kalitesi Problemi	Matematiksel Denklemler
Gerilim çökmesi	$y(t) = A[1 - \alpha(u(t - t_1) - u(t - t_2))]\sin(\omega t)$
Flikerlı gerilim çökmesi	$y(t) = A[1 + \alpha_f \sin(\beta \omega t)]\sin(\omega t) \times [1 - \alpha(u(t - t_1) - u(t - t_2))]$
Harmonikli gerilim çökmesi	$y(t) = A[1 - \alpha(u(t - t_1) - u(t - t_2))] \times [\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t)]$
Gerilim sıçraması	$y(t) = A[1 + \alpha(u(t - t_1) - u(t - t_2))]\sin(\omega t)$
Harmonikli gerilim sıçraması	$y(t) = A[1 + \alpha(u(t - t_1) - u(t - t_2))] \times [\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t)]$
Flikerlı gerilim sıçraması	$y(t) = A[1 + \alpha_f \sin(\beta \omega t)]\sin(\omega t) \times [1 + \alpha(u(t - t_1) - u(t - t_2))]$
Kesinti	$y(t) = A[1 - \alpha(u(t - t_1) - u(t - t_2))]\sin(\omega t)$
Fliker	$y(t) = A[1 + \alpha_f \sin(\beta \omega t)]\sin(\omega t)$
Harmonik	$y(t) = A[\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t)]$
Salınımlı geçici durum	$y(t) = A[\sin(\omega t) + \alpha^{-c(t-t_1)/\tau} \sin \omega_n(t - t_1)(u(t_2) - u(t_1))]$
Darbeli geçici durum	$y(t) = A[1 - \alpha(u(t - t_1) - u(t - t_2))]\sin(\omega t)$
Harmonikli kesinti	$y(t) = A[1 - \alpha(u(t - t_1) - u(t - t_2))] \times [\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t)]$
Normal	$y(t) = A[1 \mp \alpha(u(t - t_1) - u(t - t_2))]\sin(\omega t)$

Matematiksel eşitlikler ile kararlılığı bozucu etkenlerin sinyalleri üretildikten sonra özellik çıkarma işlemine geçilmiştir. Sinyal üretimi yapılırken gerçeğe yakın olması için sinyallere farklı seviyelerde gürültü eklenmiştir. Elde edilen sinyallerin ayırt edilebilmesi ve daha az bilgiyle işlem yapabilmek için belirgin ortak özelliklerin çıkarılması gerekmektedir. Çıkarılan bu özellikler sınıflandırıcılara verilerek gelen sinyalin hangi sınıfa ait olduğu belirlenmiştir. Şekil 4.1’de işlem basamakları kısaca gösterilmiştir.



Şekil 4.1. Güç kalitesi problemlerinin sınıflandırılması için işlem basamakları


4.2. Özellik Çıkarımı

Çalışmada elde edilen sinyallerin hem belirli özellikleri çıkarılarak hem de dalgacık dönüşümü ile analizi yapılmıştır. Literatür taraması yapıldığında, özellik çıkarımı ve güç kalitesi problemlerinin sınıflandırılması amacıyla belli başlı yöntemler kullanıldığı gözlemlenmiştir. Özellik çıkarımı için FD, SD, HHD, DD ve ADD yaygın olarak kullanılan dönüşüm yöntemleridir (Mahela vd., 2015). Yapılan çalışmalar neticesinde ADD ile en yüksek başarı oranları elde edildiği gözlemlenmiştir.

Güç kalitesi problemlerinin sınıflandırılması için ise DVM, KNN, karar ağaçları, YSA, bulanık uzman sistemler, GA ve diğer çeşitli sınıflandırma yöntemleri bulunmaktadır (Mahela vd.,2015). Literatür çalışmaları incelendiğinde DVM ile en yüksek başarı elde edildiği görülmüştür.

FD ile zaman bölgesindeki bir işaretin, frekans bölgesindeki karşılığı elde edilmektedir. Ancak işaret içerisindeki farklı frekans değerlerinin karşılık geldiği zaman değeri bilinemez. Bu durum durağan işaretler için sorun teşkil etmemektedir. Ancak durağan olmayan işaretler sabit periyoda sahip olmadığından ve ani değişimler içerdiğinden durağan olmayan işaretler için sorun oluşturmaktadır. Bu nedenle FD durağan işaretlere uygulanması halinde en iyi sonucu vermektedir. Bu sorun Kısa Süreli Fourier Dönüşümü (KSFD) ile çözülebilmektedir (Erişti, 2010). KSFD’de pencereleme işlemiyle işaret küçük çerçevelere ayrılır ve çerçeve içinde kalan kısa süreli işaretlerin

durağan olduğu kabul edilerek, her çerçeve için FD hesaplanır. KSFD'nin dezavantajı olan sabit pencere kullanımı problemi dalgacık dönüşümü ile aşılmıştır. Analiz boyunca pencere boyutları değiştiğinden istenilen zaman-frekans çözünürlüğü elde edilir. Ancak DD'de uygun dalgacık tipinin seçimi önemlidir. FD sonsuz uzunlukta olduğu varsayılan ve değişik frekanslardaki düzenli sinüs dalgalarını kullanarak işareti küçük parçalara ayırırken, DD ana dalgacık adı verilen sınırlı süreli, düzensiz ve asimetrik işaret parçalarının, ölçeklenmiş ve kaydırılmış hallerini kullanır. DD, fonksiyonların farklı frekanstaki bileşenlerine ayrılıp ayrı ayrı her bileşen üzerinde çalışılabilmeye olanak sağlar. DD'nin FD'ye göre üstünlük sağladığı durumlardan biri hızlı değişimlere, keskin ve sivri uçlara sahip olan sinyallerdir. DD işaret işleme teknikleri tarafından görülmeyen detayları ortaya çıkardığından sıklıkla tercih edilmektedir. Dalgacık dönüşümünde kullanılan bazı ana dalgacık modelleri Şekil 4.2'de verilmiştir.




Şekil 4.2. Örnek dalgacık şekilleri (a) Meyer (b) Coiflet4 (c) Morlet (d) Symlet4 (e) Meksika şapkası (f) Daubechies4 (g) Haar (h) Daubechies20 (i) Shannon

Bu çalışma kapsamında ADD kullanılarak sinyal özellikleri çıkarılmış, sınıflandırmalar yapılmış ve bulunan sonuçlar karşılaştırmalı olarak verilmiştir.

ADD'de N uzunluğundaki bir sinyal için yaklaşım katsayıları ($cA1$) ve detay katsayıları ($cD1$) olmak üzere iki katsayı kümesi hesaplanır. Sinyalden ölçeklendirme filtresi LoD ile yaklaşım katsayıları elde edilir. Benzer şekilde, dalgacık filtresi HiD ile detay katsayıları elde edilmektedir.

Şekil 4.3'te ADD ile sinyalden yaklaşım ve detay katsayılarının elde edilmesi ile ilgili görsel verilmiştir.




Şekil 4.3. ADD ile sinyalden yaklaşım ve detay katsayılarının elde edilmesi

ADD'nin sürekli dalgacık dönüşümüne göre en önemli avantajı ise hesaplama yükü ve kullandığı bilgi miktarının daha az olmasıdır.

4.3. Çalışmanın Uygulanması ve Sınıflandırma Yöntemlerinin Karşılaştırılması

Sinyallerin sınıflandırılması için YSA, KNN, karar ağaçları, Naive Bayes Sınıflandırıcı ve DVM gibi sınıflandırıcılar kullanılmıştır. Elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiş ve en yüksek doğruluğa sahip 2 sınıflandırıcı için karmaşıklık matrisi verilmiştir.

Üretilen sinyallerden enerji, standart sapma, mutlak değerin ortalaması, eğrilik, basıklık, ortalama (medyan) mutlak sapma, ortalama frekans, medyan frekans, toplam harmonik bozulma, rms, rms oranının tepe büyüklüğü ve entropi olmak üzere 13 adet özellik çıkarılmıştır. Çıkarılan bu özellikler sınıflandırıcılar için girdi verisi olarak kullanılmıştır. Kullanılan yöntemlerin tümünde 10 katlı çapraz doğrulama yapılmıştır. Elde edilen sonuçlar karmaşıklık matrisleriyle birlikte verilmiştir. Şekil 4.4'te sınıflandırma için işlem basamakları ve çıkarılan özellikler, Çizelge 4.2'de ise çıkarılan özelliklerin bazılarının matematiksel karşılığı verilmiştir.



Şekil 4.4. Sınıflandırma için işlem basamakları ve çıkarılan özellikler

Çizelge 4.2. Çıkarılan özelliklerin bazılarının matematiksel karşılığı

Çıkarılan özellikler	Denklemler
Ortalama değer	$\mu = \frac{1}{N} \sum_{i=1}^N x_i$
Eğrilik	$\sigma = \frac{1}{(N-1)\sigma^3} \sum_{i=1}^N x_i - \mu ^3$
Basıklık	$\frac{1}{(N-1)\sigma^4} \sum_{i=1}^N x_i - \mu ^4$
Enerji	$E = \sum_{n=-\infty}^{\infty} x(n) ^2$
Shannon entropisi	$E1(s) = - \sum_i s_i^2 \log(s_i^2)$
Log enerji entropisi	$E3(s) = \sum_i \log(s_i^2)$
RMS değeri	$x_{rms} = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n ^2}$
RMS oranının tepe büyüklüğü	$\frac{\ x\ _{\infty}}{\sqrt{\frac{1}{N} \sum_{n=1}^N x_n ^2}}$

Oluşturulan modellerin performansını görebilmek için çeşitli yöntemlere başvurulmaktadır. Sınıflandırıcıların değerlendirilmesi için karmaşıklık matrisi sıklıkla tercih edilmektedir. Karmaşıklık matrisi gerçekte hangi sınıfa ait olduğunu bildiğimiz verilerin ne kadarının doğru ne kadarının yanlış tahmin edildiğini gösteren bir matristir. Bu matriste köşegen üzerindeki değerler o sınıfa ait doğru tahmin edilen değeri göstermektedir. Dolayısıyla köşegen üzerindeki değerlerin yüksek olması önemlidir.

13 farklı bozucu etkiye ait sinyallerden 13 adet özellik çıkarılmasıyla yapılan sınıflandırma çalışmasında en yüksek doğruluk oranı Kübik DVM ile %94.4 olarak

bulunmuştur. Sonrasında sırasıyla ikinci dereceden DVM (Quadratic SVM) ile %93.7, Orta Gauss DVM ile %92 ve doğrusal DVM ile %91.7 doğruluk oranları elde edilmiştir. Şekil 4.5'te Kübik DVM için karmaşıklık matrisi, Şekil 4.6'da İkinci dereceden DVM için karmaşıklık matrisi ve Çizelge 4.3'te yapılan sınıflandırma için sınıflandırıcıların doğruluk oranları, sınıflandırıcıların eğitim süreleri ve tahmin hızları verilmiştir. Tahmin hızında gözlem/sn olarak ifade edilen birim, 1 saniyedeki gözlem sayısı olarak tanımlanabilmektedir. Sınıflandırıcıların eğitim süreleri ve tahmin hızları kullanılan verinin yapısına ve bilgisayarın özelliklerine bağlı olarak değişebilmektedir.

Gerçek sınıf	1	91.7%	0.4%	0.1%		0.5%	5.3%	1.1%		0.9%					91.7%	8.3%
	2	0.2%	90.3%	0.3%		0.5%	4.9%				3.8%				90.3%	9.7%
	3		0.5%	94.8%						3.6%	1.1%				94.8%	5.2%
	4				99.8%				0.2%						99.8%	0.2%
	5	0.7%	0.8%	0.1%		89.5%	7.5%	0.7%			0.6%		0.1%		89.5%	10.5%
	6	1.4%	1.0%			0.6%	96.7%	0.3%							96.7%	3.3%
	7	1.7%	0.1%			0.4%	2.1%	95.2%		0.5%					95.2%	4.8%
	8	0.2%			0.2%				99.6%						99.6%	0.4%
	9	1.4%		5.0%			0.1%	0.7%		92.6%	0.2%				92.6%	7.4%
	10		4.1%	3.9%		0.2%				0.4%	91.4%				91.4%	8.6%
	11											93.9%	6.1%		93.9%	6.1%
	12											8.7%	91.3%		91.3%	8.7%
	13													100.0%	100.0%	
															TPR	FNR
															Tahmin edilen sınıf	

Şekil 4.5. Kübik DVM için karmaşıklık matrisi

Gerçek sınıf	1	92.0%	0.1%	0.1%		0.2%	6.0%	0.6%		1.0%					92.0%	8.0%
	2	0.1%	88.2%	0.3%		0.3%	6.8%			0.1%	4.2%				88.2%	11.8%
	3		0.4%	97.0%			0.1%			2.2%	0.3%				97.0%	3.0%
	4				99.9%				0.1%						99.9%	0.1%
	5	1.4%	1.6%			87.5%	8.4%	0.6%			0.5%				87.5%	12.5%
	6	1.2%	0.7%			0.3%	97.8%								97.8%	2.2%
	7	2.2%		0.1%		0.2%	2.4%	95.0%		0.1%					95.0%	5.0%
	8	0.2%			0.1%				99.7%						99.7%	0.3%
	9	0.8%		6.5%				0.4%		92.2%	0.1%				92.2%	7.8%
	10		5.1%	5.0%		0.5%			0.2%	89.2%					89.2%	10.8%
	11										91.4%	8.6%			91.4%	8.6%
	12										11.5%	88.5%			88.5%	11.5%
	13												100.0%		100.0%	
Tahmin edilen sınıf													TPR	FNR		

Şekil 4.6. İkinci dereceden DVM için karmaşıklık matrisi

Çizelge 4.3. 13 özellik çıkarılarak yapılan sınıflandırmada kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması


Sınıflandırıcı çeşidi	Doğruluk oranı	Eğitim Süresi (sn)	Tahmin hızı (obs/sec)
Doğrusal DVM (Linear SVM)	%91.7	42.056	15000
İkinci Dereceden DVM (Quadratic SVM)	%93.7	148.62	6600
Kübik DVM (Cubic SVM)	%94.4	375.77	8600
Ayrıntılı Gauss DVM (Fine Gaussian SVM)	%90.8	175.43	570
Orta Gauss DVM (Medium Gaussian SVM)	%92	95.922	2100
Kaba Gauss (Coarse Gaussian SVM)	%87.2	160.7	1600
Ayrıntılı Karar Ağaçları (Fine Tree)	%87.8	5.8366	250000
Orta Karar Ağaçları (Medium Tree)	%74.9	5.5763	250000
Kaba Karar Ağaçları (Coarse Tree)	%35.7	4.2679	220000
Gaussian Naive Bayes	%69.2	3.2628	150000
Kernel Naive Bayes	%77.9	157.66	350
Ayrıntılı KNN	%86.2	15.192	4000
Orta KNN (Medium KNN)	%86.4	15.141	3900
Kaba KNN (Coarse KNN)	%79.8	18.119	3200
Kosinüs KNN (Cosine KNN)	%85.8	28.821	3800
Kübik KNN (Cubic KNN)	%85.3	395.89	160
Ağırlıklı KNN (Weighted KNN)	%87.6	32.882	3600
Topluluk Öğrenmesi (Boosted Trees)	%83.5	134.4	25000
Topluluk Öğrenmesi (Bagged Trees)	%93.3	77.682	13000
Topluluk Öğrenmesi (Subspace Discriminant)	%66.9	91.857	9100
Topluluk Öğrenmesi (Subspace KNN)	%76.7	111.54	4800
Topluluk Öğrenmesi (RUSBoosted Trees)	%74.9	215.86	41000
YSA	%63.92	-	-

Karmaşıklık matrisinde x eksenini tahmin edilen sınıfı, y eksenini ise gerçek etiket değerini belirtmektedir. 1,2, 3, ... ,13 olarak gösterilen rakamların her biri bir sınıfı temsil etmektedir. Rakamlara karşılık gelen sınıfların isimleri Çizelge 4.4’te gösterilmiştir.

Çizelge 4.4. Sınıfların gösterimi


No	Sınıf
1	Gerilim çökmesi
2	Gerilim sıçraması
3	Fliker
4	Harmonik
5	Darbeleri Geçici Durum
6	Salınımlı Geçici Durum
7	Kesinti
8	Harmonikli kesinti
9	Flikerli gerilim çökmesi
10	Flikerli gerilim sıçraması
11	Harmonikli gerilim çökmesi
12	Harmonikli gerilim sıçraması
13	Normal

ROC (Receiver Operating Characteristics, İşlem Karakteristik Eğrisi) sınıflandırma modelinin performansını gösteren bir diğer metriktir. Bu eğri için x eksenini yanlış pozitif oranını, y eksenini ise doğru pozitif oranını belirtmektedir. Grafiğin sol üst köşesi Eğrinin altında kalan alan (AUC, Area Under Curve) olarak adlandırılmaktadır ve bu alan 0 ile 1 arasında değişen bir değer almaktadır. Bu değer 1’e yakın olması performansın yüksek olduğu anlamına gelmektedir. Yani AUC farklı sınıfların ne kadar iyi ayırt edilebildiğinin bir ölçüsüdür. Ancak ROC eğrisi her sınıf için ayrı ayrı ilgili değerleri göstermektedir. Sınıflar seçilerek karşılaştırmalar yapılabilmektedir. Şekil 4.7’de örnek bir ROC eğrisi gösterilmiştir.




Şekil 4.7. Kübik DVM için ROC eğrisi

Aynı özellikler ileri beslemeli geri yayımlı bir YSA'ya girdi olarak verilmiş ve ağ Levenberg-Marquardt algoritması ile eğitilmiştir. Oluşturulan ağ yapısında 10 katlı çapraz doğrulama yapılmıştır. Şekil 4.8'de oluşturulan ağın tasarlanan genel yapısı ve Şekil 4.9'da YSA'nın karmaşıklık matrisi verilmiştir. YSA'nın nöron sayısı ve sayısı kullanılan aktivasyon fonksiyonları deneme yanılma yöntemi ile belirlenmiştir.



Şekil 4.8. Oluşturulan YSA'nın genel yapısı




Şekil 4.9. Oluşturulan YSA için karmaşıklık matrisi

Literatür incelendiğinde ADD kullanılarak yapılan sınıflandırma işlemlerinden daha başarılı sonuçlar alındığı görülmüştür. ADD için en çok kullanılan ve doğruluk oranına katkısı en fazla olan Deubechies dalgacığı seçilmiştir. Tezin kalan kısmında farklı Deubechies dalgacıklarının sınıflandırma başarısına etkisi incelenecektir.


4.3.1. Daubechies dalgacık modellerinin karşılaştırılması

Bu bölümde farklı Daubechies dalgacık modelleri kullanılarak sinyal verilerinden 10 adet özellik çıkarılarak sınıflandırıcıların doğruluk oranları tespit edilmiş ve karşılaştırmalı olarak verilmiştir.

Db1 dalgacığı kullanılarak yapılan çalışmadan Şekil 4.10 ve Şekil 4.11'deki karmaşıklık matrisleri elde edilmiştir. Kübik DVM'den %88.1 ile en yüksek doğruluk elde edildiği görülmektedir. Sınıflandırıcının tahmin etmekte en çok zorlandığı sınıf ise harmonikli gerilim sıçraması olmuştur. Bu sınıfı %54.7 oranında doğru tahmin etmiş ancak ciddi anlamda harmonikli gerilim çökmesi ile karıştırmıştır. Çizelge 4.5'te db1 dalgacığı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması verilmiştir.



Şekil 4.10. Db1 dalgacığı kullanılarak yapılan sınıflandırmada Kübik DVM'ye ait karmaşıklık matrisi



Şekil 4.11. Db1 dalgacığı kullanılarak yapılan sınıflandırmada İkinci dereceden DVM'ye ait karmaşıklık matrisi

Çizelge 4.5. Db1 dalgacığı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması

Sınıflandırıcı çeşidi	Doğruluk oranı	Eğitim Süresi (sn)	Tahmin hızı (gözlem/sn)
Doğrusal DVM	%84.8	63.198	15000
İkinci Dereceden DVM	%87.9	630.05	5500
Kübik DVM	%88.1	1191.5	7300
Ayrıntılı Gauss DVM	%79.9	219.64	440
Orta Gauss DVM	%84.7	140.03	1400
Kaba Gauss DVM	%75.6	221.35	1200
Ayrıntılı Karar Ağaçları	%76.8	187.94	240000
Orta Karar Ağaçları	%54.6	187.96	270000
Kaba Karar Ağaçları	%31.5	189.87	340000
Gaussian Naive Bayes	-	-	-
Kernel Naive Bayes	%63.3	315.28	420
Ayrıntılı KNN	%75.2	175.97	2700
Orta KNN	%75.1	179	17000
Kaba KNN	%70.6	187.95	6200
Kosinüs KNN	%72.8	201.42	4000
Kübik KNN	%73.9	232.35	1600
Ağırlıklı KNN	%76.8	236	17000
Topluluk Öğrenmesi (Boosted Trees)	%71.7	322.13	25000
Topluluk Öğrenmesi (Bagged Trees)	%86.4	357.91	12000
Topluluk Öğrenmesi (Subspace Discriminant)	%79.9	333.99	11000
Topluluk Öğrenmesi (Subspace KNN)	%84.7	357.73	3600
Topluluk Öğrenmesi (RUSBoosted Trees)	%75.6	461.44	25000
YSA	%60.54	-	-

Db1 dalgacığı kullanılarak YSA için oluşturulan karmaşıklık matrisi Şekil 4.12’de verilmiştir.

YSA Algoritmasında Kullanılan Test Verisi İçin Karmaşıklık Matrisi

Gerçek sınıf	Darbeli Geçici Durum	Fliker	Flikerli Gerilim Düşmesi	Flikerli Gerilim Yükselmesi	Gerilim düşmesi	Gerilim yükselmesi	Harmonik	Harmonikli Gerilim Düşmesi	Harmonikli Gerilim Yükselmesi	Harmonikli Kesinti	Kesinti	Normal	Salınlımlı Geçici Durum		
Darbeli Geçici Durum	56	5				1	13	1	1	1	7		15	56.0%	44.0%
Fliker	7	53	2			1	33				2		2	53.0%	47.0%
Flikerli Gerilim Düşmesi	5		52	1			4			25	10		3	52.0%	48.0%
Flikerli Gerilim Yükselmesi	4	3	7	54			3	3		8	7		11	54.0%	46.0%
Gerilim düşmesi	4	9	1		51	22	8				1		4	51.0%	49.0%
Gerilim yükselmesi	11	31			7	29	15			1	1		5	29.0%	71.0%
Harmonik	1						97				1		1	97.0%	3.0%
Harmonikli Gerilim Düşmesi								88	12					88.0%	12.0%
Harmonikli Gerilim Yükselmesi				1				82	14			3		14.0%	86.0%
Harmonikli Kesinti	2		12	1						58	20		7	58.0%	42.0%
Kesinti	6	1				1	1			9	75		7	75.0%	25.0%
Normal												100		100.0%	
Salınlımlı Geçici Durum	23						5		1		11		60	60.0%	40.0%

47.1%	52.0%	70.3%	94.7%	87.9%	53.7%	54.2%	50.6%	50.0%	56.9%	55.6%	97.1%	52.2%
52.9%	48.0%	29.7%	5.3%	12.1%	46.3%	45.8%	49.4%	50.0%	43.1%	44.4%	2.9%	47.8%

Tahmin edilen sınıf


Darbeli Geçici Durum Fliker Flikerli Gerilim Düşmesi Flikerli Gerilim Yükselmesi Gerilim düşmesi Gerilim yükselmesi Harmonik Harmonikli Gerilim Düşmesi Harmonikli Gerilim Yükselmesi Harmonikli Kesinti Kesinti Normal Salınlımlı Geçici Durum

Şekil 4.12. Db1 dalgacığı kullanıldığında YSA için elde edilen karmaşıklık matrisi

Aynı işlem db2 dalgacığı kullanılarak tekrarlandığında Şekil 4.13 ve Şekil 4.14'teki sonuçlar elde edilmiştir. Kübik DVM'den %89.3 doğruluk oranı ile en yüksek başarı elde edildiği görülmektedir. İkinci en yüksek doğruluk oranı ise İkinci dereceden DVM'ye aittir. Db2 ile çıkarılan özellikler neticesinde harmonikli gerilim sıçramasını %55.8 oranında doğru tahmin ettiği görülmüştür. Ancak bu başarı oranının yeterli olmadığı bilinmektedir. Şekil 4.13'teki karmaşıklık matrisi Kübik DVM'ye, Şekil 4.14'teki ise İkinci dereceden DVM'ye aittir. Çizelge 4.6'da db2 dalgacığı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması verilmiştir.

Gerçek sınıf	1	92.2%	0.6%	0.1%			4.5%	1.0%		1.0%					0.6%	92.2%	7.8%
	2	0.1%	88.5%	0.4%		0.2%	4.9%	0.1%			5.7%				0.1%	88.5%	11.5%
	3	0.3%	0.9%	99.6%		0.1%				4.0%	4.1%					99.6%	9.4%
	4				99.0%				1.0%							99.0%	1.0%
	5	0.7%	0.6%			88.7%	6.6%	1.4%		0.3%	1.1%				0.6%	88.7%	11.3%
	6	0.7%	1.6%			1.5%	95.0%	0.1%							1.1%	95.0%	5.0%
	7	0.9%	0.1%	0.1%		1.3%	2.1%	95.0%		0.4%	0.1%					95.0%	5.0%
	8	0.7%			3.1%	0.1%			96.1%							96.1%	3.9%
	9	1.2%		5.5%		0.1%	0.1%	1.2%		91.1%	0.8%					91.1%	8.9%
	10		6.0%	3.7%		1.1%				0.7%	88.5%					88.5%	11.5%
	11											80.6%	19.4%			80.6%	19.4%
	12											44.2%	55.8%			55.8%	44.2%
	13													100.0%		100.0%	
																TPR	FNR
Tahmin edilen sınıf																	

Şekil 4.13. Db2 dalgacığı kullanıldığında Kübik DVM'ye ait karmaşıklık matrisi




Şekil 4.14. Db2 dalgacı kullanıldığında İkinci dereceden DVM'ye ait karmaşıklık matrisi

Çizelge 4.6. Db2 dalgacı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması

Sınıflandırıcı çeşidi	Doğruluk oranı	Eğitim süresi (sn)	Tahmin hızı (gözlem/sn)
Doğrusal DVM	%85.1	58.893	14000
İkinci Dereceden DVM	%88.7	503.59	4900
Kübik DVM	%89.3	927.82	8800
Ayrıntılı Gauss	%82.3	235.17	390
Orta Gauss DVM	%86.4	135.59	1400
Kaba Gauss DVM	%76.8	225.71	1200
Ayrıntılı Karar Ağaçları	%76.5	221.91	210000
Orta Karar Ağaçları	%56.1	226.18	210000
Kaba Karar Ağaçları	%31.1	229.62	170000
Gaussian Naive Bayes	-	-	-
Kernel Naive Bayes	%67	374.72	380
Ayrıntılı KNN	%76	211.6	19000
Orta KNN	%76.6	216.8	12000
Kaba KNN	%70.5	226.95	5500
Kosinüs KNN	%75.6	240.91	3900
Kübik KNN	%75.7	280.84	1300
Ağırlıklı KNN	%78.1	285.49	13000
Topluluk Öğrenmesi (Boosted Trees)	%73.4	377.46	25000
Topluluk Öğrenmesi (Bagged Trees)	%87	416.5	11000
Topluluk Öğrenmesi (Subspace Discriminant)	%55.2	389.44	11000
Topluluk Öğrenmesi (Subspace KNN)	%80.1	414.47	3300
Topluluk Öğrenmesi (RUSBoosted Trees)	%56.2	505.77	30000
YSA	%47	-	-

Db2 dalgacığı kullanılarak çıkarılan özelliklerin YSA'ya giriş olarak verilmesiyle elde edilen karmaşıklık matrisi Şekil 4.15'te verilmiştir.



Şekil 4.15. Db2 dalgacığı kullanıldığında YSA için elde edilen karmaşıklık matrisi

Db3 dalgacığı kullanılarak işlemler tekrarlandığında Şekil 4.16 ve Şekil 4.17'deki sonuçlar elde edilmiştir. İkinci dereceden DVM'den %89.1 doğruluk oranı ile en yüksek başarı elde edildiği görülmektedir. İkinci en yüksek doğruluk oranı ise %88.2 ile Bagged Trees Topluluk modeline aittir. Db3 ile çıkarılan özellikler neticesinde harmonikli gerilim sıçramasını %55.8 oranında doğru tahmin ettiği görülmüştür. Ancak bu başarı oranının yeterli olmadığı bilinmektedir. Şekil 4.16'daki karmaşıklık matrisi Bagged Trees Topluluk öğrenmesine, Şekil 4.17'deki ise Kübik DVM'ye aittir. Çizelge 4.7'de db3 dalgacığı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması verilmiştir.

Gerçek sınıf	1	91.9%	0.8%	0.1%		0.2%	4.2%	1.1%		1.5%			0.2%	91.9%	8.1%
	2	0.1%	86.6%	0.7%		0.1%	4.6%			0.1%	7.8%			86.6%	13.4%
	3	0.4%	0.6%	89.9%						4.1%	5.0%			89.9%	10.1%
	4				99.1%				0.9%					99.1%	0.9%
	5	0.7%	0.6%	0.1%		89.8%	5.5%	2.0%		0.1%	1.1%			89.8%	10.2%
	6	1.2%	1.4%			2.0%	95.0%	0.1%						95.0%	5.0%
	7	1.6%	0.1%			1.6%	1.7%	94.7%		0.3%				94.7%	5.3%
	8	0.6%			3.3%				96.1%					96.1%	3.9%
	9	1.4%		4.9%		0.4%		1.5%		91.3%	0.5%			91.3%	8.7%
	10	0.1%	5.4%	3.5%	0.1%	1.2%				0.5%	89.1%	0.1%		89.1%	10.9%
	11										79.0%	21.0%		79.0%	21.0%
	12										41.3%	58.7%		58.7%	41.3%
	13												100.0%	100.0%	
														TPR	FNR
Tahmin edilen sınıf															

Şekil 4.16. Db3 dalgacığı kullanılarak yapılan sınıflandırmada İkinci dereceden DVM'ye ait karmaşıklık matrisi


Gerçek sınıf	1	92.7%	0.5%	0.3%		0.1%	3.2%	1.3%		1.9%				92.7%	7.3%
	2	0.1%	87.2%	1.2%		0.4%	3.8%				7.3%			87.2%	12.8%
	3	0.2%	0.6%	95.5%			0.1%			2.6%	0.9%			95.5%	4.5%
	4				99.3%				0.7%					99.3%	0.7%
	5	0.9%	0.8%	0.2%		89.0%	6.1%	1.2%		0.2%	1.6%			89.0%	11.0%
	6	1.8%	2.4%			2.9%	92.6%	0.2%	0.1%					92.6%	7.4%
	7	2.1%		0.3%		1.7%	1.9%	91.6%		2.4%				91.6%	8.4%
	8	0.1%			4.4%			0.1%	95.4%					95.4%	4.6%
	9	3.8%		4.6%		0.1%		4.7%		86.7%	0.1%			86.7%	13.3%
	10		7.9%	3.7%		1.2%				0.3%	86.9%			86.9%	13.1%
	11										70.4%	29.6%		70.4%	29.6%
	12										40.0%	60.0%		60.0%	40.0%
	13												100.0%	100.0%	
														TPR	FNR
Tahmin edilen sınıf															

Şekil 4.17. Db3 dalgacığı kullanılarak yapılan sınıflandırmada Kübik DVM'ye ait karmaşıklık matrisi

Çizelge 4.7. Db3 dalgacığı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması

Sınıflandırıcı çeşidi	Doğruluk oranı	Eğitim süresi (sn)	Tahmin hızı (gözlem/sn)
Doğrusal DVM	%85.7	58.262	13000
İkinci Dereceden DVM	%89.1	604.06	5100
Kübik DVM	%87.1	1155	7500
Ayrıntılı Gauss	%83.9	227.31	410
Orta Gauss DVM	%86.5	132.66	1500
Kaba Gauss DVM	%77.8	225.62	1100
Ayrıntılı Karar Ağaçları	%78.7	222.21	180000
Orta Karar Ağaçları	%54.4	221.87	200000
Kaba Karar Ağaçları	%31.4	225.2	240000
Gaussian Naive Bayes	%70.2	211.88	110000
Kernel Naive Bayes	%66.5	375.86	340
Ayrıntılı KNN	%75.6	201.23	25000
Orta KNN	%76.3	204.83	15000
Kaba KNN	%67.1	215.25	5400
Kosinüs KNN	%75.7	229.68	3700
Kübik KNN	%75	266.64	1400
Ağırlıklı KNN	%78.1	271.21	12000
Topluluk Öğrenmesi (Boosted Trees)	%71.1	377.15	21000
Topluluk Öğrenmesi (Bagged Trees)	%88.2	425.74	11000
Topluluk Öğrenmesi (Subspace Discriminant)	%56	387.78	10000
Topluluk Öğrenmesi (Subspace KNN)	%75.4	414.4	3500
Topluluk Öğrenmesi (RUSBoosted Trees)	%54.4	525.75	27000
YSA	%54.62	-	-

Db3 dalgacığı kullanılarak çıkarılan özelliklerin YSA'ya giriş olarak verilmesiyle elde edilen karmaşıklık matrisi Şekil 4.18'de verilmiştir.



Şekil 4.18. Db3 dalgacığı kullanıldığında YSA için elde edilen karmaşıklık matrisi

Db4 dalgacığı kullanılarak 13 çeşit bozucu etkinin her birinden 10 adet özellik çıkarılmasıyla Şekil 4.19 ve Şekil 4.20’deki sonuçlar elde edilmiştir. En yüksek doğruluk oranı Bagged Tree Topluluk öğrenmesi ve Kübik DVM ile %89.2 olarak bulunmuştur. Ancak Bagged Tree Topluluk modelinin sınıflandırma zamanı açısından daha kısa sürede tamamlanması modelin seçiminde etkili olmuştur. Şekil 4.19’daki karmaşıklık matrisi Bagged Trees Topluluk öğrenmesine, Şekil 4.20’deki ise Kübik DVM’ye aittir. Çizelge 4.8’de db4 dalgacığı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması verilmiştir.

Gerçek sınıf	1	92.7%	0.6%	0.2%		0.6%	3.0%	0.8%		2.1%					92.7%	7.3%	
	2	0.2%	87.8%	0.7%		0.5%	4.1%				6.7%				87.8%	12.2%	
	3	0.1%	0.7%	95.9%		0.1%				2.2%	1.0%				95.9%	4.1%	
	4				98.7%					1.3%					98.7%	1.3%	
	5	1.5%	1.0%	0.4%		87.8%	6.5%	0.9%		0.3%	1.6%				87.8%	12.2%	
	6	2.0%	1.6%			3.6%	92.8%								92.8%	7.2%	
	7	2.0%		0.2%		2.2%	1.3%	92.1%		2.2%					92.1%	7.9%	
	8				4.9%			0.2%	94.9%						94.9%	5.1%	
	9	3.2%		4.6%				2.1%		90.0%	0.1%				90.0%	10.0%	
	10		7.5%	3.2%		1.7%				0.3%	87.3%				87.3%	12.7%	
	11											74.5%	25.5%		74.5%	25.5%	
	12											34.3%	65.7%		65.7%	34.3%	
	13													100.0%	100.0%		
Tahmin edilen sınıf																TPR	FNR

Şekil 4.19. Db4 dalgacığı kullanılarak yapılan sınıflandırmada Bagged Trees Topluluk öğrenmesine ait karmaşıklık matrisi

Gerçek sınıf	1	92.2%	0.8%	0.3%		0.4%	3.7%	1.0%		1.6%					92.2%	7.8%
	2	0.1%	84.9%	1.1%		0.5%	4.7%				8.7%				84.9%	15.1%
	3	0.4%	0.9%	89.5%		0.1%				4.9%	4.2%				89.5%	10.5%
	4				98.5%				1.5%						98.5%	1.5%
	5	0.9%	0.6%	0.3%		88.9%	6.0%	1.5%		0.4%	1.4%				88.9%	11.1%
	6	1.3%	1.2%			2.2%	95.1%	0.1%						0.1%	95.1%	4.9%
	7	1.2%	0.1%			1.9%	1.7%	94.8%		0.3%					94.8%	5.2%
	8	0.7%			2.9%				96.4%						96.4%	3.6%
	9	1.9%		4.6%		0.3%		1.3%		91.6%	0.3%				91.6%	8.4%
	10		6.0%	3.4%		2.0%				0.6%	87.9%	0.1%			87.9%	12.1%
	11											80.9%	19.1%		80.9%	19.1%
	12											41.4%	58.6%		58.6%	41.4%
	13													100.0%	100.0%	
Tahmin edilen sınıf															TPR	FNR

Şekil 4.20. Db4 dalgacığı kullanılarak yapılan sınıflandırmada Kübik DVM'ye ait karmaşıklık matrisi

Çizelge 4.8. Db4 dalgacığı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması

Sınıflandırıcı çeşidi	Doğruluk oranı	Eğitim süresi (sn)	Tahmin hızı (gözlem/sn)
Doğrusal DVM	%85.5	48.831	15000
İkinci Dereceden DVM	%88.6	579.58	6500
Kübik DVM	%89.2	1021	8300
Ayrıntılı Gauss	%83.7	195.86	490
Orta Gauss DVM	%86	115.11	1600
Kaba Gauss DVM	%77.3	198.14	1200
Ayrıntılı Karar Ağaçları	%78.9	103.33	250000
Orta Karar Ağaçları	%66.8	104.6	270000
Kaba Karar Ağaçları	%31.5	105.85	280000
Gaussian Naive Bayes	%68.3	95.919	130000
Kernel Naive Bayes	%65.7	230.46	410
Ayrıntılı KNN	%75.3	80.941	28000
Orta KNN	%74.6	84.569	16000
Kaba KNN	%65.2	93.017	6200
Kosinüs KNN	%74.7	105.47	4200
Kübik KNN	%73.4	134.92	1800
Ağırlıklı KNN	%76.8	138.69	17000
Topluluk Öğrenmesi (Boosted Trees)	%68.3	232.2	30000
Topluluk Öğrenmesi (Bagged Trees)	%89.2	267.92	13000
Topluluk Öğrenmesi (Subspace Discriminant)	%54.8	243.85	10000
Topluluk Öğrenmesi (Subspace KNN)	%73.2	265.82	4100
Topluluk Öğrenmesi (RUSBoosted Trees)	%66.8	383.18	35000
YSA	%51.46	-	-

Db4 dalgacığı kullanılarak çıkarılan özelliklerin YSA'ya giriş olarak verilmesiyle elde edilen karmaşıklık matrisi Şekil 4.21'de verilmiştir.

YSA Algoritmasında Kullanılan Test Verisi İçin Karmaşıklık Matrisi

Gerçek sınıf	Darbeli Geçici Durum	64	1	1		1	2	5			1	5		20	64.0%	36.0%
	Fliker	12	40				1	41						6	40.0%	60.0%
	Flikerli Gerilim Düşmesi	6	1	43	8			2			18	17		5	43.0%	57.0%
	Flikerli Gerilim Yükselmesi	8	1	22	33				7	1	16	6		6	33.0%	67.0%
	Gerilim düşmesi	4	12			47	22	10			1	1		3	47.0%	53.0%
	Gerilim yükselmesi	13	22	1		15	28	15				2		4	28.0%	72.0%
	Harmonik	45	5				2	43						5	43.0%	57.0%
	Harmonikli Gerilim Düşmesi								37	63					37.0%	63.0%
	Harmonikli Gerilim Yükselmesi								32	68					68.0%	32.0%
	Harmonikli Kesinti	7		16	7			3	3		26	28		10	26.0%	74.0%
	Kesinti	2				2		2			9	69		16	69.0%	31.0%
	Normal												100		100.0%	
	Salınlı Geçici Durum	12	2			3		6			1	5		71	71.0%	29.0%

37.0%	47.6%	51.8%	68.8%	69.1%	50.9%	33.9%	46.8%	51.5%	36.1%	51.9%	100.0%	48.6%
63.0%	52.4%	48.2%	31.3%	30.9%	49.1%	66.1%	53.2%	48.5%	63.9%	48.1%		51.4%

Tahmin edilen sınıf

Darbeli Geçici Durum Fliker Flikerli Gerilim Düşmesi Flikerli Gerilim Yükselmesi Gerilim düşmesi Gerilim yükselmesi Harmonik Harmonikli Gerilim Düşmesi Harmonikli Gerilim Yükselmesi Harmonikli Kesinti Kesinti Normal Salınlı Geçici Durum

Şekil 4.21. Db4 dalgacığı kullanıldığında YSA için elde edilen karmaşıklık matrisi

Db8 dalgacığı kullanılarak 10 adet özellik çıkarıldığında Şekil 4.22 ve Şekil 4.23'teki sonuçlar elde edilmiştir. En yüksek doğruluk oranı Bagged Trees Topluluk öğrenmesi ile %90.8 olarak bulunmuştur. Şekil 4.22'deki karmaşıklık matrisi İkinci dereceden DVM'ye, Şekil 4.23'teki karmaşıklık matrisi ise Bagged Trees Topluluk öğrenmesine aittir. Çizelge 4.9'da db8 dalgacığı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması verilmiştir.

Gerçek sınıf	1	92.2%	0.4%	0.2%		0.2%	5.7%	0.2%		1.1%					92.2%	7.8%
	2	0.3%	88.8%	0.8%		0.1%	5.2%	0.1%			4.7%				88.8%	11.2%
	3	0.3%	0.9%	97.0%						1.5%	0.3%				97.0%	3.0%
	4				99.1%				0.9%						99.1%	0.9%
	5	1.0%	1.1%	0.1%		86.7%	8.5%	1.3%		0.3%	1.0%				86.7%	13.3%
	6	1.1%	1.2%			1.8%	95.9%								95.9%	4.1%
	7	1.7%	0.2%	0.1%		1.8%	2.2%	93.8%		0.2%					93.8%	6.2%
	8	0.3%			6.1%				93.6%						93.6%	6.4%
	9	0.8%		5.6%		0.4%		0.5%		92.7%					92.7%	7.3%
	10		6.0%	5.1%		1.4%			0.3%	87.2%					87.2%	12.8%
	11										82.0%	18.0%			82.0%	18.0%
	12										53.6%	46.4%			46.4%	53.6%
	13												100.0%		100.0%	
Tahmin edilen sınıf															TPR	FNR

Şekil 4.22. Db8 dalgacıği kullanılarak yapılan sınıflandırmada İkinci dereceden DVM'ye ait karmaşıklık matrisi


Gerçek sınıf	1	90.8%	0.8%	0.2%		0.2%	3.7%	1.9%		2.4%					90.8%	9.2%
	2	0.4%	87.8%	0.9%		0.3%	3.7%	0.1%			6.8%				87.8%	12.2%
	3	0.1%	0.7%	95.5%		0.2%				2.7%	0.8%				95.5%	4.5%
	4				98.1%				1.9%						98.1%	1.9%
	5	1.2%	1.1%	0.1%		88.9%	6.0%	1.4%		0.1%	1.1%			0.1%	88.9%	11.1%
	6	1.7%	2.5%	0.1%		2.5%	93.1%		0.1%						93.1%	6.9%
	7	3.1%	0.1%	0.2%		1.8%	1.3%	91.7%		1.8%					91.7%	8.3%
	8				5.4%			0.1%	94.5%						94.5%	5.5%
	9	3.4%		5.2%		0.1%		3.8%		87.3%	0.2%				87.3%	12.7%
	10		8.1%	4.1%		1.1%			0.2%	86.5%					86.5%	13.5%
	11										83.2%	16.8%			83.2%	16.8%
	12										17.2%	82.8%			82.8%	17.2%
	13												100.0%		100.0%	
Tahmin edilen sınıf															TPR	FNR

Şekil 4.23. Db8 dalgacıği kullanılarak yapılan sınıflandırmada Bagged Trees Topluluk öğrenmesine ait karmaşıklık matrisi

Çizelge 4.9. Db8 dalgacığı kullanılan sınıflandırıcıların doğruluk oranlarının karşılaştırılması

Sınıflandırıcı çeşidi	Doğruluk oranı	Eğitim süresi (sn)	Tahmin hızı (gözlem/sn)
Doğrusal DVM	%85.1	59.484	14000
İkinci Dereceden DVM	%88.9	443.55	6500
Kübik DVM	%88.8	1004	8500
Ayrıntılı Gauss DVM	%83.5	185.65	540
Orta Gauss DVM	%85.3	118	1900
Kaba Gauss DVM	%77.2	191.22	1400
Ayrıntılı Karar Ağaçları	%79.9	181.43	250000
Orta Karar Ağaçları	%66.3	184.9	250000
Kaba Karar Ağaçları	%31.5	183.37	350000
Gaussian Naive Bayes	%69.2	179.55	130000
Kernel Naive Bayes	%65.8	305.24	440
Ayrıntılı KNN	%74.9	172.65	36000
Orta KNN	%74.7	175.62	21000
Kaba KNN	%65.7	182.45	7800
Kosinüs KNN	%74.6	194.44	4500
Kübik KNN	%73.6	222.38	1800
Ağırlıklı KNN	%76.4	226.04	18000
Topluluk Öğrenmesi (Boosted Trees)	%69.2	313.2	29000
Topluluk Öğrenmesi (Bagged Trees)	%90.8	349.54	13000
Topluluk Öğrenmesi (Subspace Discriminant)	%56.9	325.19	12000
Topluluk Öğrenmesi (Subspace KNN)	%75	344.42	4500
Topluluk Öğrenmesi (RUSBoosted Trees)	%66	433.29	38000
YSA	%57.46	-	-

Db8 dalgacığı kullanılarak çıkarılan özelliklerin YSA'ya giriş olarak verilmesiyle elde edilen karmaşıklık matrisi Şekil 4.24'te verilmiştir.



Şekil 4.24. Db8 dalgacığı kullanıldığında YSA için elde edilen karmaşıklık matrisi

Yapılan işlemler sonucunda dalgacık dönüşümü yapılmadan özellik çıkarıldığında maksimum doğruluk Kübik DVM ile %94.4 olarak bulunmuştur. Dalgacık dönüşümü yapıldığında ise db1 dalgacığı kullanıldığında Kübik DVM ile %88.1, db2 kullanıldığında Kübik DVM ile %89.3, db3 dalgacığı kullanıldığında İkinci Dereceden DVM ile %89.1, db4 dalgacığı kullanıldığında Topluluk Öğrenmesi (Bagged Trees) ve Kübik DVM ile %89.2 ve db8 dalgacığı kullanıldığında %90.8 doğruluk oranı elde edilmiştir. Dalgacık dönüşümünde en yüksek doğruluk db8 dalgacığı kullanıldığında elde edilmiştir. YSA'nın diğer makine öğrenmesi yöntemlerine göre daha düşük sonuçlar verdiği gözlemlenmiştir. Elde edilen maksimum doğruluk oranları Çizelge 4.10'da verilmiştir.

Çizelge 4.10. Maksimum doğruluk oranlarının karşılaştırılması

	Sınıflandırıcı Çeşidi	Dalgacık Tipi	Max Doğruluk Oranı	Tahmin hızı (gözlem/sn)
Dalgacık dönüşümü olmadan	Kübik DVM	-	%94.4	8600
Dalgacık dönüşümü yapıldığında	Kübik DVM	db1	%88.1	7300
	Kübik DVM	db2	%89.3	8800
	İkinci Dereceden DVM	db3	%89.1	5100
	Topluluk Öğrenmesi (Bagged Trees)-Kübik DVM	db4	%89.2	8300-13000
	Topluluk Öğrenmesi (Bagged Trees)	db8	%90.8	13000

Yapılan sınıflandırma sonuçları incelendiğinde en yüksek doğruluk oranının %94.4 ile dalgacık dönüşümü yapılmadan Kübik DVM ile elde edildiği görülmektedir. Dalgacık dönüşümü yapıldığında ise en yüksek sonuç %90.8 ile Bagged Trees topluluk öğrenmesine aittir.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Yapılan çalışmada gerilim kararlılığı üzerinde önemli derece etkisi olan güç kalitesi problemlerinin sınıflandırılması üzerinde durulmuştur. Çalışmada YSA, KNN, DVM, karar ağaçları, rastgele orman algoritması ve topluluk öğrenmesi gibi makine öğrenmesi yöntemlerinin doğruluk oranlarının karşılaştırılması yapılmıştır. Özellik çıkarılırken hem belirlenen 13 adet özellik çıkarılarak hem de ayrık dalgacık dönüşümü ile 10 adet özellik çıkarılarak çalışma gerçekleştirilmiştir. Literatür incelemelerinin sonucunda Deubechies dalgacıklarının bu işlemler için sıklıkla kullanıldığı gözlemlenmiştir. Bu nedenle özellik çıkarımında farklı Deubechies dalgacık türlerinin sınıflandırma başarısına etkisi test edilmiştir. Çalışmanın sonucunda en yüksek doğruluk oranları DVM ve Bagged Trees Topluluk öğrenmesi yapıları ile elde edilmiştir.

Db1 dalgacığı kullanılarak yapılan çalışmadan %88.1 ile en yüksek doğruluk oranı Kübik DVM'den elde edildiğı görölmektedir. Aynı işlem db2 dalgacığı kullanılarak tekrarlandığında Kübik DVM'den %89.3 doğruluk oranı ile en yüksek başarı elde edilmiştir. Db3 dalgacığı kullanılarak işlemler tekrarlandığında İkinci dereceden DVM'den %89.1 doğruluk oranı ile en yüksek başarı elde edildiğı görölmektedir. Db4 dalgacığı kullanılarak en yüksek doğruluk oranı Bagged Tree Topluluk öğrenmesi ve Kübik DVM ile %89.2 olarak bulunmuştur. Db8 dalgacığı kullanılarak en yüksek doğruluk oranı Bagged Trees Topluluk öğrenmesi ile %90.8 olarak bulunmuştur. Ancak üretilen sinyallerden enerji, standart sapma, mutlak değerin ortalaması, eğrilik, basıklık, ortalama (medyan) mutlak sapma, ortalama frekans, medyan frekans, toplam harmonik bozulma, rms, rms oranının tepe büyüklüğü ve entropi olmak üzere 13 adet özellik çıkarılarak gerçekleştirilen sınıflandırmanın daha başarılı olduğı görölmektedir. Bu şekilde yapılan sınıflandırmadan %94.4 doğruluk oranı elde edilirken Daubechies dalgacıkları kullanılarak yapılan sınıflandırmadan db8 dalgacığı ile %90.8 doğruluk oranı elde edilmiştir.

Kullanılan yöntemler süre açısından değeriendirilecek olursa Bagged Tree Topluluk öğrenmesinin İkinci Dereceden DVM ve Kübik DVM'ye göre daha kısa sürede sınıflandırmayı tamamladığı görölmüştür.

Tüm bu sınıflandırma işlemleri şebekede meydana gelen bozukluğun tanımlanması ve çözüme kavuşturulabilmesi adına kritiktir. Problemin ne olduğunun

anlaşılması kararlılığı sağlamak için atılacak ilk adımdır. Gerçekleştirilen tez çalışmasında elde edilen en iyi sınıflandırma sonuçları, yapılan kaynak araştırmasındaki çalışmalarla karşılaştırmalı olarak Çizelge 4.11’de sunulmuştur.

Çizelge 4.11. Bu tez çalışmasında elde edilen sınıflandırma sonuçları ile literatürdeki çalışmaların karşılaştırması

Yazar	Sınıf sayısı	Veri sayısı	Kullanılan yöntem	Veri tipi	Gürültü durumu	Doğruluk
Janik ve Lobos (2006)	6	300	RBF ve DVM	Matematiksel denklemlerden üretilen veriler	Gürültülü ve Gürültüsüz	-
Erişti ve ark. (2010)	7	1400	DVM	Güç sisteminin modellenmesiyle elde edilen veriler	Gürültülü	%99.71
Erişti ve ark. (2014)	5	10109	S dönüşümü / ST- ELM	Gerçek veriler ve matematiksel denklemlerden üretilen veriler	Gürültülü	%99.50
Yuanhang ve ark. (2015)	2	4000	Relief algoritması / Çoklu DVM	New England 39 baralı sistemin analizi ile elde edilen veriler	-	%93.03
Hao ve ark. (2016)	5	-	Zaman alanı karakteristik analizi	IEEE 9 baralı test modelinin analizi ile üretilen veriler	-	-
Borrás ve ark. (2016)	10	1000	Dalgacık çoklu çözünürlük analizi / DVM	Gerçek zamanlı laboratuvar ortamında oluşturulan deneysel veriler	Gürültülü	%94.2
Liquan ve ark. (2017)	11	2200	Dalgacık dönüşümü / DVM ve PSO-DVM	Matematiksel denklemlerden üretilen veriler	Gürültülü	%95.8333
Patil ve ark. (2019)	4	-	YSA	Gerçek veriler	-	%95.2381
Zhang ve ark. (2020)	7	1180	S dönüşümü / DVM sınıflandırıcı	Simülasyon verileri ve gerçek deney verileri	Gürültülü	%99.71
Abdullah ve ark. (2020)	17	17000	DVM	Matematiksel denklemlerden üretilen veriler	Gürültüsüz	%97.90
Bu tez çalışması	13	13000	DVM, YSA, KNN, karar ağaçları, Rastgele orman algoritması, Topluluk öğrenme algoritması	Matematiksel denklemlerden üretilen veriler	Gürültülü	%94.4

Çizelge 4.11’de literatürde yapılan çalışmalar için kullanılan yöntemler, verilerin nasıl üretildiği ve gürültü durumları da yer almaktadır. Çizelgede en iyi sonucu veren değerler koyu renk ile belirtilmiştir. Çizelge incelendiğinde doğruluk bakımından en yüksek sonuç %99.71 olarak görülmektedir. Literatürdeki çalışmalardan elde edilen sonuçların bu tez çalışmasından elde edilen sonuçlara göre daha yüksek olduğu görülmektedir. Bu durum kullanılan bilgisayarın özelliklerinden, sinyal verileri oluşturulurken kullanılan parametrelerin farklı olması, yapılan diğer bazı çalışmalarda özellik seçim algoritmaları kullanılmış olması gibi pek çok nedenden kaynaklanabilmektedir. Ancak gerçekleştirilen tez çalışmasının, kullanılan sınıf sayısı ve sınıflandırıcıların çeşitliliği bakımından zengin olduğu görülmektedir.

5.2 Öneriler

Gerçekleştirilen tez çalışması ile yapılan kaynak araştırmasında elde edilen sonuçlar karşılaştırıldığında tez çalışmasının literatüre göre daha düşük doğruluk oranlarına sahip olduğu gözlenmiştir.

İleriki çalışmalarda;

- Özellik çıkarımı aşamasında özellik seçim yöntemleri kullanılarak daha iyi sonuçlar elde edilebilir.
- Derin öğrenme yöntemleri kullanılarak farklı modeller üzerinde sınıflandırma işleminin doğruluğu test edilerek karşılaştırılması sağlanabilir.
- Sınıflandırması yapılan bu bozunum olaylarının çözümleri aşamasında yapay zeka teknikleri kullanılarak sistemi yönlendiren, ne yapılması gerektiğine karar veren, kararlılık sınırlarına sistemi nasıl getirebileceği konusunda yol gösteren bir çalışma yapılabilir.

KAYNAKLAR

- Abdullah, Khan, M.U., Ali, W., Shahzad, M. F., Aziz S., 2020, A signal analysis approach towards detection and classification of power quality disturbances', *1st International Conference of Smart Systems and Emerging Technologies, SMART-TECH 2020*, 71–76.
- Abualigah, L. M., Khader, A. T., Hanandeh, E. S., 2018, A hybrid strategy for krill herd algorithm with harmony search algorithm to improve the data clustering, *Intelligent Decision Technologies*, 12(1),3–14.
- Akwukwaegbu, I.O, Ibe, O. G., 2013, Concepts of Reactive Power Control and Voltage Stability Methods in Power System Network, *IOSR Journal of Computer Engineering*, 11(2), 15–25.
- Albatsh F.M., Shameemet A., Tofael A., Mahmood, F.B.K., and Saha, A., Chowdhury, M.Z.A., Ramli, N.A., 2017, A Comparative analysis of line stability indices for dynamic voltage stability, *International Conference on Engineering Technology and Technopreneurship (ICE2T)*, 1-6.
- Al Hamrani, M. M. 2002, Reactive Power Optimization Using Adaptive Excitation Control of Synchronous Motors Master Thesis, *Oregon State University Electrical and Computer Engineering*, USA.
- Amjady, N., Fallahi, F., 2010, Determination of frequency stability border of power system to set the thresholds of under frequency load shedding relays, *Energy Conversion and Management*, 51(10), 1864–1872.
- Arıcı, N., İskender, A., 2020, Fotovoltaik Güneş Santrallerinde Şebeke Bağlantı Sorunları ve Çözümleri, *Journal of Polytechnic*, 0900(1), 215–222.
- Arifoğlu, U., 2020, Güç Sistemlerinin Analizi, Papatya Yayıncılık Eğitim, İstanbul.
- Aydın, F., Uyaroğlu, Y., Yalçın, M. A., 2009, Enerji İletim Sistemlerinde Seri Kapasitörlerin Gerilim Kararlılığı Açısından Sistem Büyümelerine Etkileri, *Elektrik Mühendisleri Odası Dergisi*, 47–51.
- Bayındır, R., Demirbaş, Ş., Sesveren, Ö., 2008, Reaktif Güç Kompanzasyonu için Zeki Bir Simülatör Tasarımı ve Gerçekleştirilmesi, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 23(3), 681–688.
- Baysal, M., Uzunoğlu, M. and Kocatepe, C., 2007, Güç Sistem Gerilim Kararlılığında Yük Modellemelerinin Önemi, *12. Elektrik-Elektronik-Bilgisayar Mühendisliği Ulusal Kongresi*, Eskişehir, 321-325.
- Belkacem, S., 2021, Machine Learning Approaches to Rank News Feed Updates on Social Media, Phd Thesis, Université des Sciences et de la Technologie Houari Boumediene, Alger.
- Bollen, M. ve Gu, I., 2006. Signal processing of power quality disturbances, Wiley.

- Borrás, M. D., Bravo, J. C., Moñtano, J. C., 2016, Disturbance Ratio for Optimal Multi-Event Classification in Power Distribution Networks, *IEEE Transactions on Industrial Electronics*, 63(5), 3117–3124.
- Cai, L., Thornhill, N. F., Kuenzel, S., Pal, B.C., 2017, Real-Time Detection of Power System Disturbances Based on k -Nearest Neighbor Analysis, *IEEE Access*, 5, 5631–5639.
- Choudhury S., Khandelwal N., Dash T. P., 2021, A Unified Scheme of PSS and SVC for Voltage Profile Improvement in Electrical Grid Network, *2021 1st Odisha International Conference on Electrical Power Engineering, Communication and Computing Technology(ODICON)*, 1-6.
- Demirören A., Zeynelgil L., 2004, Elektrik Enerji Sistemlerinin Kararlılığı Kontrolü ve Çalışması, Birsan Yayınevi, İstanbul.
- Eğridere, B., 2006, Elektrik Enerji Sistemlerinde Gerilim Kararlılığı Ve İyileştirilmesinin İncelenmesi, Yüksek Lisans, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Ekinci, S., 2015, SIMULINK kullanarak güç sistem geçici hal kararlılık analizi, *SAÜ Fen Bilimleri Enstitüsü Dergisi*, 19(3), 313–320.
- El-Sherbiny, M., Mehta, D., 1973, Dynamic System Stability Part I - Investigation Of The Effect Of Different Loading And Excitation Systems, *IEEE Transactions on Power Apparatus and Systems*, 1538–1546.
- Eminoğlu, U., Hocaoglu, M., 2005, Enerji İletim Sistemlerinde Azami Yüklenebilirlik Noktasının Paralel Kompanzasyon İle Değişiminin Farklı Yük Modelleri İçin İncelenmesi, *Elektrik, Elektronik, Bilgisayar Mühendisliği 11. Ulusal Kongresi*, 300–303.
- Erişti, B., Yıldırım, Ö., Erişti, H., Demir, Y., 2016, A Real-Time Power Quality Disturbance Detection System Based On The Wavelet Transform, *51st International Universities Power Engineering Conference, UPEC 2016*. IEEE, 1–5.
- Erişti, H., Uçar, A., Demir, Y., 2007, Destek Vektör Makineler ve Dalgacık Dönüşümü Kullanarak Güç Sistemlerinde Geçici Rejim Bozulmalarının Sınıflandırılması, *12. Elektrik Elektronik ve Bilgisayar Mühendisliği Kongresi*, 2–5.
- Erişti H., 2010, Güç kalitesi için dalgacık dönüşümü ve destek vektör makine tabanlı bir olay tanıma tekniğinin geliştirilmesi, Doktora, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- Erişti, H., Demir, Y., 2011, Gerçek zamanlı güç kalitesi izleme sistemleri ile elektrik dağıtım sistemlerindeki güç kalitesinin incelenmesi, *Elektrik-Elektronik ve Bilgisayar Sempozyumu 201*, 351–356.
- Erişti, H., Erişti, B., Yıldırım, Ö., 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 and Energy Systems*, 61, 553–562.
- Ertay, M. M., Aydoğmuş, Z., 2012, Güç Sistemlerinde FACTS Uygulamaları, *Uluslararası Teknolojik Bilimler Dergisi*. 4(2), pp. 40–58.
- Genet, B., 2009, On monitoring methods and load modeling to improve voltage stability assessment efficiency, Doktora, Université Libre de Bruxelles Faculté des Sciences appliquées, Belgium.
- Goh, H. H., Chua, Q. S., Lee, S. W., Kok, B. C., Goh, K. C., Teo, K. T.K., 2015, Evaluation for Voltage Stability Indices in Power System Using Artificial Neural Network, *Procedia Engineering*, 118, 1127–1136.
- Gurusinghe, D. R., Ongsakul, W., 2012, Particle swarm optimization for voltage stability analysis, *IEEE Electrical Power and Energy Conference, EPEC 2012*, 315–322.
- Hao, L., 2016, Wei-Feng, Q., Chang-Qing, S., Hong-Bin, L., The Multiple Power Quality Disturbance Classification Based on Power System Time Domain Analysis, *6th International Conference on Intelligent Systems Design and Engineering Applications, ISDEA 2015*, 867–870.
- Haque, M. H., 1996, Load flow solution of distribution systems with voltage dependent load models, *Electric Power Systems Research*, 36(3), 151–156.
- IEEE Power and Energy Society, 2019, *IEEE Recommended Practice for Monitoring Electric Power Quality, IEEE Standard 1159-2009*.
- Janik, P., Lobos, T., 2006, Automated classification of power-quality disturbances using SVM and RBF networks', *IEEE Transactions on Power Delivery*, 21(3), 1663–1669.
- Kalyani S., ve Swarup, K. S., 2009, Binary SVM Approach for Security Assessment and Classification in Power Systems, *Annual IEEE India Conference*, 1-4.
- Kamaruzzaman, Z. A., Mohamed, A., Shareef, H., 2015, Effect of grid-connected photovoltaic systems on static and dynamic voltage stability with analysis techniques – a review, *Przeglad Elektrotechniczny*, 91(6), 134–138.
- Kawabe K., Yokoyama A., 2013, Study on short-term voltage stability improvement using batteries on extra-high voltage network, *IEEE Grenoble Conference*, 1-3.
- Krarti, M., 2018, Utility Rate Structures and Grid Integration, *Optimal Design and Retrofit of Energy Efficient Buildings, Communities, and Urban Centers*, 189–245.
- Kundur, P., 1994, *Power System Stability and Control*, Mc Graw-Hill Inc., New York
- Kyomugisha, R., Muriithi, C. M., Edimu, M., 2021, Voltage Stability Enhancement of the Uganda Power System Network, *2021 IEEE PES/IAS PowerAfrica*, 2021, 1-5.
- Liquan, Z., Meijiao, G., Lin, W., 2017, Classification of multiple power quality disturbances based on the improved SVM, *Proceedings of the 2017 International Conference on*

- Wireless Communications, Signal Processing and Networking, WiSPNET 2017*, 2018-Janua(4), 2625–2628.
- Lokesh, M., Kulkarni A. D., Ananthapadmanabha T., Gurav N., Sandeep Kumar K. J., 2021, Enhancement of Transient Stability and Voltage Quality of Microgrid with Multiple DERs, *2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS)*, 686-691.
- Lv, G. Wang, X., Zhang, H., Zhang, C., 2005, PQ disturbances identification based on SVMs classifier, *Proceedings of 2005 International Conference on Neural Networks and Brain Proceedings, ICNNB'05*, 1(1), 222–226.
- Mittal, A. Soorya, A., Nagrath, P., Hemanth, D.J., 2020, Data augmentation based morphological classification of galaxies using deep convolutional neural network, *Earth Science Informatics*, 13(3), pp. 601–617.
- Moulin, L. S., Silva, A.P Alves, El-Sharkawi M.A., Marks R.J., 2004, Support Vector Machines for Transient Stability Analysis of Large-Scale Power Systems, 19(2), 818–825.
- Ova, A., 2017, Güç Sistemlerinde PV-QV Eğrisi Yöntemi İle Statik Gerilim Kararlılığı Analizi., Yüksek Lisans, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.
- Patil, P., Muley, K., Agrawal, R., 2019, Identification of Power Quality Disturbance Using Neural Network, *Proceedings of the 3rd International Conference on Electronics and Communication and Aerospace Technology, ICECA 2019*, 990–996.
- Razmi, P., Asl, M. G., Canarella, G., Emami, A. S., 2021, Topology identification in distribution system via machine learning algorithms, *PLoS ONE*, 16(6 June), 1–20.
- Rokach, L., Maimon, O., 2014, *Data Mining with Decision Trees Theory and Applications (2nd ed.)*, Singapore.
- Saidian, A., Mirabbasi, D., Heidari, M. 2010, The effect of size of DG on voltage flicker and voltage sag in closed-loop distribution system, *Proceedings of the 2010 5th IEEE Conference on Industrial Electronics and Applications, ICIEA 2010*, 68–72.
- Sivaraman, P., Sharmeela, C., 2021, Power quality and its characteristics, *Power Quality in Modern Power Systems*, pp. 1–60.
- Shekhawat, N., Gupta, A. K., Kumar Sharma A., 2018, Voltage Stability Assessment Using Line Stability Indices, *3rd International Conference and Workshops on Recent Advances and Innovations in Engineering (ICRAIE)*, 1-4.
- Shukla, A., Verma K., Siddiqui S. A., 2016, Voltage stability improvement of distribution networks by enhancing DGs impacts, *2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)*, 1-6.
- Tiwari, A., Ajjarapu, V., 2007, Event Identification and Contingency Assessment for Voltage Stability via PMU, *39th North American Power Symposium*, 413-420.

- Tür, M. R., Ay, S., Shobole, A., Wadi, M., 2018, Calculation of optimal value of spinning reserve requirement for unit commitment in power systems by considering lost parameters, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 2018(18–2), 1171–1185.
- Undrill, J., 2019, Notes on Frequency Control for the Australian Energy Market Operator, *Aemc*.
- Yalçınöz, T., Altun, H., Karadal, H., 2004, Farklı Topolojiye Sahip MLP Yapay Sinir Ağları ile Enerji Sistemlerinde Gerilim Kararlılığı Analizi, *The 13th Turkish Symposium on Artificial Intelligence and Artificial Neural Networks*, 547-554, İzmir, Turkey.
- Yeşilbudak, M., Bayındır R., Çetinkaya Ü., 2015, Güç Sistemlerinde Gerilim Kararlılığını Etkileyen Faktörler" , *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 595-602.
- Yuanhang, Dai., Weiling, Zhang., Yong, M., 2015, Multi-support vector machine power system transient stability assessment based on relief algorithm, *2015 IEEE PES Asia- Pacific Power and Energy Engineering Conference (APPEEC)*, 3, 1–5.
- Zhang, P., Feng, Q., Chen, R., Wang, D., Ren, L., 2020, Classification and Identification of Power Quality in Distribution Network, *5th International Conference on Power and Renewable Energy, ICPRE 2020*, (4), 533–537.