

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÜÇ TRANSFORMATÖRLERİ SFRA TARAMA FREKANS
CEVABI ANALİZİ SONUÇLARININ YAPAY ZEKA
UYGULAMALARI İLE KARŞILAŞTIRILMASI

DOKTORA TEZİ

Hakan ÇUHADAROĞLU

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik Mühendisliği Bilim Dalı

HAZİRAN 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÜÇ TRANSFORMATÖRLERİ SFRA TARAMA FREKANS
CEVABI ANALİZİ SONUÇLARININ YAPAY ZEKA
UYGULAMALARI İLE KARŞILAŞTIRILMASI

DOKTORA TEZİ

Hakan ÇUHADAROĞLU

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik Mühendisliği Bilim Dalı

Tez Danışmanı: Prof. Dr. Yılmaz UYAROĞLU

HAZİRAN 2025

Hakan Çuhadaroğlu tarafından hazırlanan “GÜÇ TRANSFORMATÖRLERİ SFRA TARAMA FREKANS CEVABI ANALİZİ SONUÇLARININ YAPAY ZEKA UYGULAMALARI İLE KARŞILAŞTIRILMASI” adlı tez çalışması 11.06.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektrik Mühendisliği Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı : **Unvan Adı SOYADI**
Sakarya Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI (Danışman)**
Sakarya Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI**
Sakarya Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI**
(Gerekliyse) Üniversitesi

Jüri Üyesi : **Unvan Adı SOYADI**
(Gerekliyse) Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

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

(...../...../20.....).

Hakan ÇUHADAROĞLU





Ulu Türk Milletine...



TEŞEKKÜR

Öncelikle, akademik rehberliği, değerli yorumları ve yönlendirmeleriyle tez çalışmamın her aşamasında katkı sağlayan danışmanım Sayın Prof. Dr. Yılmaz UYAROĞLU'na şükranlarımı sunarım. Bu süreçte manevi desteğini her daim hissettirdiği için eşim Kutsal Sevi'ye ve sabırlarıyla yanımda olan çocuklarım Münevver Derin ile Deniz'e teşekkür ederim. İş ortamında anlayışları ve destekleriyle katkı sunan değerli çalışma arkadaşlarım Gökşin Sönmez ve Haluk Yılmaz'a; yazılım geliştirme süreçlerinde teknik destek sağlayan Sude Nur ve Emirhan'a teşekkür ederim.

Ayrıca, her zaman yanımda olan aileme de sonsuz teşekkürlerimi sunarım.

Hakan ÇUHADAROĞLU



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1. Literatür Araştırması	11
2. TRANSFORMATÖRLERİN YAPISI, ÇALIŞMA PRENSİBİ VE TEST YÖNTEMLERİ	21
2.1. Transformatör	21
2.2. Faraday Yasası ve Lenz Kanunu	24
2.3. Transformatörlerin Yapısı ve Çeşitleri	25
2.3.1. Güç transformatörleri	25
2.4. Transformatör Testleri	27
2.4.1. İkaz akım testi	29
2.4.2. AC izolasyon testleri	31
2.4.3. DC izolasyon testleri	34
2.4.4. Sarım oranı testi	36
2.4.5. Sargı direnci testi	38
2.4.6. Frekans tarama cevabı analizi (Sweep frequency response analysis, SFRA)	38
2.4.7. Frekans tepkisi basit eşdeğer devresi	40
2.4.8. Zaman ve frekans domeni	41
2.4.9. Transfer fonksiyonu	42
2.4.10. Transformatör frekans tepkisi eşdeğer devresi	45
2.4.11. SFRA ölçüm yöntemleri ve bağlantı şekilleri	48
3. MAKİNE ÖĞRENMESİ TEKNİKLERİ	51
3.1. Makine Öğrenmesi Modelleri	52
3.1.1. Lojistik regresyon (Logistic regression)	52
3.1.2. Rastgele ormanlar algoritması (Random Forest)	54
3.1.3. En yakın komşu algoritması (K-nearest neighbors (KNN))	55
3.1.4. Destek vektör sınıflandırma algoritması (support vector classifier SVC)	57
3.1.5. Karar ağaçları	59
3.1.6. Gradient boosting classifier (GBC)	61
4. MATERYAL VE YÖNTEM	63
4.1. Verilerin Toplanması ve Veri Seti Oluşturulması	64
4.1.1. SFRA testlerinin yapılması	64

4.1.2. Veri ön işleme ve veri setinin oluşturulması	66
4.2. Kullanılan Araçlar ve Yazılımlar	68
4.2.1. Yazılım dili ve çalışmada kullanılan kütüphaneler	68
4.2.2. Entegre geliştirme ortamı (IDE)	71
4.3. Makine Öğrenme Algoritmalarının Değerlendirilmesi	72
4.4. Model Performansının Değerlendirilmesi	76
4.4.1. Hata matrisi (confusion matrix) analizi	76
4.4.2. Çalışma sonucunda elde edilen performans değerlendirme grafikleri	79
4.5. Çalışma Sonucunda Elde Edilen Karşılaştırma Grafikleri	89
5. SONUÇLAR	97
6. TARTIŞMA VE SONUÇ	101
KAYNAKLAR	103
ÖZGEÇMİŞ	109



KISALTMALAR

AC	: Alternatif Akım (Alternating Current)
CAP	: Kümülatif Doğruluk Profili (Cumulative Accuracy Profile)
CNN	: Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)
DAR	: Dielektrik Absorpsiyon Oranı
dB	: Desibel
DGA	: Yağda Çözülmüş Gaz Analizi (Dissolved Gas Analysis)
DL/T	: Çin Standartı Kodu
DQN	: Deep Q-Networks
DT	: Karar Ağacı (Decision Tree)
EMK	: Elektromotor Kuvvet (Electromotive Force)
EV	: Electrical Vehicle (Elektrikli Araç)
F1-Score	: Genel F1 Ölçümü
FFT	: Hızlı Fourier Dönüşümü
FN	: Yanlış Negatifler (False Negatives)
FP	: Yanlış Pozitifler (False Positives)
FPR	: Yanlış Pozitif Oranı (False Positive Rate)
GBC	: Gradient Boosting Classifier
GUI	: Graphical User Interface
Hz	: Hertz
ICA	: Bağımsız Bileşenler Analizi (Independent Component Analysis)
IDE	: Entegre Geliştirme Ortamı
IEC	: Uluslararası Elektroteknik Komisyonu (International Electrotechnical Commission)
IEEE	: Elektrik ve Elektronik Mühendisleri Enstitüsü (Institute of Electrical and Electronics Engineers)
K-NN	: K En Yakın Komşu (K-Nearest Neighbors)
KS	: Kolmogorov-Smirnov
kV	: Kilovolt
kWh	: Kilowatt-saat
MATLAB	: Matrix Laboratory
MHz	: Megahertz

ML	: Machine Learning
MLPNN	: Çok Katmanlı Yapay Sinir Ağı (Multilayer Perceptron Neural Network)
MSE	: Ortalama Kare Hata (Mean Squared Error)
MVA	: Megavolt-Amper
NLP	: Natural Language Processing
PRC	: Precision-Recall Curve
RBF	: Radial Basis Function
RLC	: Direnç (R), Endüktans (L), Kapasitans (C)
RMSE	: Kök Ortalama Kare Hata (Root Mean Squared Error)
ROC	: Receiver Operating Characteristic
SFRA	: Frekans Tarama Cevabı Analizi (Sweep Frequency Response Analysis)
SVC	: Destek Vektör Sınıflandırma (Support Vector Classifier)
SVM	: Destek Vektör Makineleri (Support Vector Machines)
TEİAŞ	: Türkiye Elektrik İletim AŞ
TN	: Doğru Negatifler (True Negatives)
TP	: Doğru Pozitifler (True Positives)
TPR	: Doğru Pozitif Oranı (True Positive Rate)
YZ	: Yapay Zekâ

SİMGELER

R	: Direnç
X	: Reaktans
I	: Akım
V	: Gerilim (Volt)
E	: İndüklenen EMF
N	: Transformatör Sarım Sayısı
$\mathcal{E}$	: İndüklenen EMK
L	: Endüktans
C	: Kapasitörün Kapasitansı
A	: Kapasitör Plakalarının Yüzey Alanı
d	: Kapasitör Plakaları Arasındaki Mesafe
ω	: Açısal Hız
PF	: Güç Faktörü
P	: Aktif Güç
S	: Görünür Güç
Q	: Reaktif Güç
Z	: İmpedans



TABLO LİSTESİ

Sayfa

Tablo 2.1. Eşdeğer devre büyüklükleri.....	23
Tablo 2.2. İzolasyon malzemeleri (Short,2016).	31
Tablo 2.3. İzolasyon malzemelerinin dielektrik sabitleri.	31
Tablo 2.4. DC izolasyon ölçüm değerlendirme tablosu (Myers ve ark,1981).	36
Tablo 2.5. SFRA yönteminde, temel dalga ile ölçülen dalganın karşılaştırılması yoluyla hata türleri saptanması (Pandya ve ark,2013).	47
Tablo 4.1. Farklı algoritmaların performans sonuçları.....	74
Tablo 5.1. Çalışmadaki sınıflara ait ks istatistikleri sonuçları.....	97
Tablo 5.2. Genel model performansı.	98
Tablo 5.3. MSE ve RMSE sonuçları.	99



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. 80MVA 110 KV Güç Trafosu Örneği (SCOTECH, t.y.).....	3
Şekil 1.2. Transformatörün İşlevsel Gösterimi (Rawlins, 2000)	5
Şekil 1.3. Transformatörün Elektriksel Gösterimi (Rawlins, 2000)	6
Şekil 1.4. Transformatör Sekonder Kısım Gerilim İndüklenmesi (Rawlins, 2000)	6
Şekil 1.5. Güç Transformatörü (Durusel Elektrik, t.y.)	7
Şekil 1.6. Tipik SFRA Test Bağlantıları (El-Faraskoury,2015)	10
Şekil 2.1. İdeal Transformatör Eşdeğer Şeması (IEC 60076-11,2004)	22
Şekil 2.2. Yüklü Transformatörün (a) Fiziksel Modeli ve (b) Eşdeğer Devre Diyagramı (Abdulkareem ve ark, 2014)	22
Şekil 2.3. Core Tip Nüve ve (b) Shell Tip Nüve (ABB,2004).....	25
Şekil 2.4. Güç Transformatörünün Genel Yapısı (Velasco Costa ve ark, 2022)	26
Şekil 2.5. Saha Montajı Öncesi Transformatör Tankı	28
Şekil 2.6. Sahada Montaj Sırasında 400/230/34 kV Güç Transformatörü	28
Şekil 2.7. İkaz Akımı Testi Ölçüm Şeması (Brusetti,2016)	30
Şekil 2.8. Nüve İçin İkaz Akımı Eşdeğer Devresi (Brusetti,2016) (Yıldız,2018)	30
Şekil 2.9. Transformatörün Genişletilmiş Eşdeğer Devre Şeması (Short,2016)	32
Şekil 2.10. Elektriksel İzolasyon Modeli (Short,2016).....	32
Şekil 2.11. İzolasyon Kayıp Açısı Vektörel Gösterimi (Yıldız,2018).....	33
Şekil 2.12. İzolasyon Toplam Akımı Vektörel Gösterimi (Yıldız,2018)	33
Şekil 2.13. İki Sargılı Transformatörün İzolasyon Durumu (Yıldız,2018).....	34
Şekil 2.14. DC İzolasyon Elektrik Devre Şeması (IEEE Std 43-2006)	35
Şekil 2.15. DC İzolasyon Akımları Grafiği (IEEE Std 43-2006)	35
Şekil 2.16. Dyn5 Bağlantılı Transformatör Vektör Diyagramı (Prasetyo ve ark, 2021)	37
Şekil 2.17. Ses Sinyalinin Osiloskop Üzerinde Gösterimi (Kraetge ve ark,2009)	39
Şekil 2.18. (a) İkinci Dereceden RLC Devresi ve (b) SFRA Cevabı (Sweetser ve ark,2003)	40
Şekil 2.19. Transformatörün iki uçlu empedans devre modeli (Sweetser ve ark,2003)	42
Şekil 2.20. Kazancın Frekansla Değişiminin Logaritmik Olarak Gösterimi (Sweetser ve ark,2003).....	44
Şekil 2.21. Kazancın Frekansla Değişiminin Lineer Olarak Gösterimi (Sweetser ve ark,2003)	45
Şekil 2.22. (a) Transformatör Nüve ve Sargıları- (b) Transformatör Eşdeğer Devresi (Kraetge ve ark,2009).....	46
Şekil 2.23. Örnek SFRA Değerlendirme Grafiği (TEİAŞ,2020).....	48
Şekil 2.24. SFRA Analize Ait Temel Ölçüm Prensi Şeması (Korenciak ve ark, 2020)	49
Şekil 2.25. Sahada SFRA ve Bağlantısı.....	49
Şekil 3.1. Lojistik Regresyon Modeli (Fatima ve ark, 2023).....	54
Şekil 3.2. Rastgele Ormanlar Algoritması Şematik Gösterim (Khan ve ark, 2021) ..	55

Şekil 3.3. K-NN Çalışma Prensibi (Altunkaynak ve ark, 2020)	57
Şekil 3.4. SVC Sınıflandırma Algoritmasının Şematik Gösterimi (Hu ve ark,2022)	58
Şekil 3.5. Karar Ağaçları Örnek Şematik Gösterim (Çamur & Uçar, 2021)	60
Şekil 3.6. Gradient Boosting Classifier Çalışma Şeması (Zhang ve ark,2021)	62
Şekil 4.1. Çalışmanın Akış Diyagramı.....	64
Şekil 4.2. Test Transformatörü Üzerinde Yapılan SFRA Test Düzenegi	65
Şekil 4.3. SFRA Verilerinin Toplanması İçin Hazırlanan Test Düzenegi	65
Şekil 4.4. SFRA İçin Omicron Programı Ara yüzü	66
Şekil 4.5. Düzenlenmiş Veri Setinin Örnek Bir Parçası	68
Şekil 4.6. Çalışmada Kullanılan Python Kütüphaneleri	69
Şekil 4.7. Gradient Boosting Sınıflandırıcısının Oluşturulması ve Eğitimi.....	76
Şekil 4.8. Hata Matrisinin Yapısı (Yalman ve ark,2022).....	77
Şekil 4.9. Çalışmaya Ait Hata Matrisi	79
Şekil 4.10. Öğrenme Eğrisi Grafiği (Learning Curve).....	80
Şekil 4.11. Kalibrasyon Eğrisi Grafiği (Calibration Curve)	82
Şekil 4.12. Kazanım Grafiği (Gain Chart)	83
Şekil 4.13. Sınıf 0 İçin KS İstatistiği (Kolmogorov-Smirnov) Grafiği.....	84
Şekil 4.14. Sınıf 1 İçin KS İstatistiği (Kolmogorov-Smirnov) Grafiği.....	84
Şekil 4.15. Sınıf 2 İçin KS İstatistiği (Kolmogorov-Smirnov) Grafiği.....	85
Şekil 4.16. Sınıf 0 İçin Kümülatif Doğruluk Eğrisi CAP (Cumulative Accuracy Profile).....	87
Şekil 4.17. Sınıf 1 İçin Kümülatif Doğruluk Eğrisi CAP (Cumulative Accuracy Profile).....	87
Şekil 4.18. Sınıf 2 İçin Kümülatif Doğruluk Eğrisi CAP (Cumulative Accuracy Profile).....	88
Şekil 4.19. 1U-1N Test Verisine Ait Karşılaştırma Grafiği.....	89
Şekil 4.20. 1U-1N Test Verisine Ait Konsol Çıktısı.....	90
Şekil 4.21. 1V-1M-Test Verisine Ait Karşılaştırma Grafiği.....	90
Şekil 4.22. 1V-1M-Test Verisine Ait Konsol Çıktısı.....	91
Şekil 4.23. 1V-1N-1W ÇKD Alt Test Verisine Ait Karşılaştırma Grafiği	92
Şekil 4.24. 1V1N1W ÇKD Alt Test Verisine Ait Konsol Çıktısı.....	93
Şekil 4.25. 1W-1N Test Verisine Ait Karşılaştırma Grafiği.....	93
Şekil 4.26. 1W-1N Test Verisine Ait Konsol Çıktısı.....	94
Şekil 4.27. 1W-1N-1V Sargı Kayma Arızalı Test Verisine Ait Karşılaştırma Grafiği	94
Şekil 4.28. 1W-1N-1V Sargı Kayma Arızalı Test Verisine Ait Konsol Çıktısı	95

GÜÇ TRANSFORMATÖRLERİ SFRA TARAMA FREKANS CEVABI ANALİZİ SONUÇLARININ YAPAY ZEKA UYGULAMALARI İLE KARŞILAŞTIRILMASI

ÖZET

Elektrik enerjisi, günümüzde vazgeçilmez bir kaynak haline gelmiş ve kullanımı her geçen gün artmaktadır. Aydınlatma ile başlayan bu süreç, elektrik motorlarının bulunmasıyla sanayide, ev eşyalarında, iklimlendirme sistemlerinde, ulaşımda ve tıbbi cihazlarda kendini göstermiştir. Elektrikli araçların yaygınlaşmasıyla elektrik enerjisi, kara yolu ulaşımında da kritik bir rol üstlenmiştir. Türkiye'de kişi başı elektrik tüketimi, yüzyılın başında birkaç kWh bile değilken, bugün 3900 kWh seviyelerine ulaşmıştır. Yenilenebilir enerji kaynaklarının artışıyla, elektrik en çevre dostu enerji kaynağı haline gelmiştir. Elektrikli araçların kullanımındaki artış, elektrik talebini de belirgin ölçüde artırmıştır. Artan enerji talebi, transformatörlerin üzerindeki yükü artırmış ve yeni test ve bakım yöntemlerinin geliştirilmesi ihtiyacını ortaya çıkarmıştır. Bu bağlamda, yapay zekâ ve makine öğrenimi teknikleri, transformatörlerin test sonuçlarını daha hızlı ve hatasız analiz etmek için büyük bir potansiyele sahiptir.

Transformatörlerin uzun ömürlü ve güvenilir çalışabilmesi için arızaların doğru sınıflandırılması kritik öneme sahiptir. SFRA testi, transformatörlerin frekans yanıtlarını analiz ederek, olası arızaları erken tespit etmede etkili bir yöntemdir. Bu çalışma, transformatörlerde elektriksel, mekanik ve termal arızaların tespitine odaklanmakta ve bu tür arızaların sistem performansı üzerindeki etkisini incelemektedir. Yapay zekâ ve makine öğrenimi algoritmaları, SFRA verilerini analiz ederek insan kaynaklı hataları ortadan kaldırmakta ve daha hızlı, doğru sonuçlar elde edilmesine olanak tanımaktadır. Bu teknolojiler, büyük veri kümelerini işleyerek norm dışı sapmaları, eğilimleri ve olası arıza belirtilerini tespit edebilmekte; SFRA testlerinden elde edilen veriler ışığında transformatörlerin durumunu gerçek zamanlı olarak değerlendirebilmektedir. Bu sayede, olası arızalar erken tespit edilerek önleyici bakım önlemleri alınmakta ve transformatörlerin arıza riski en aza indirilmektedir. Ayrıca, yapay zekâ sistemleri, farklı transformatörler arasında karşılaştırmalar yaparak tipik performans eğrilerini ve anormallikleri belirleyebilme yeteneğine sahiptir.

SFRA testleri sonuçları genellikle bode diyagramları ile grafik ve tablolara dökülerek sunulmakta olup, on binlerce satırlık sayısal veri içermektedir. Bu durum, sonuçların yorumlanmasını ve karşılaştırılmasını zorlaştırmakta, insan hatası riskini artırmaktadır. Bu çalışmada, SFRA verilerinin yapay zekâ ve makine öğrenimi yöntemleri ile bir arada kullanılması hedeflenmiştir. Bu amaçla bir test düzeni kurulmuş ve SFRA verileri toplanarak sayısallaştırılmış, ardından düzenlenip analiz edilebilir hale getirilmiştir. Bu çalışmanın en önemli noktalarından bir tanesi olarak transformatör durumları üç etiket altında incelenmiştir: çekirdek arızalı, sargı kayması arızalı ve sağlıklı transformatör.

Çalışmada altı farklı makine öğrenimi algoritması denenmiştir: Lojistik Regresyon, Rastgele Ormanlar, En Yakın Komşu, Destek Vektör Makineleri, Karar Ağaçları ve Gradient Boosting. Tüm algoritmalar matematiksel performans parametreleri ile

değerlendirilmiş ve çoklu sınıflandırma görevlerinde en verimli algoritma olan Gradient Boosting Classifier (GBC) tercih edilmiştir. GBC algoritması, geniş veri setlerinden öğrenerek arıza tahminlerini yüksek doğrulukla gerçekleştirmiş ve transformatörlerin sağlık durumlarını değerlendirmede etkili sonuçlar vermiştir. Bu algoritma, arıza tespiti ve yerinin belirlenmesinde üstün performans göstermekte ve veri analizinde hız ve doğruluk açısından önemli avantajlar sağlamaktadır. Çalışmanın sonuçlarını değerlendirmek amacıyla hata matrisi analizi yapılmış; ayrıca Learning Curve, Calibration Curve, Gain Chart, Cumulative Accuracy Profile ve KS istatistiği gibi performans grafikleri oluşturulmuştur. Her bir transformatör durumu (çekirdek arızalı, sargı kayması arızalı, sağlıklı transformatör) için karşılaştırma grafikleri sunulmuş ve sonuçlar detaylı şekilde incelenmiştir. Yapay zekâ algoritmalarının performans parametreleri de GBC algoritması için hesaplanmış ve çalışmanın başarısı matematiksel olarak ortaya konmuştur. Bu çalışma, özellikle makine öğrenimi ve yapay zekâ tekniklerini SFRA testi ile entegre bir şekilde kullanarak transformatörlerin arızalı ve sağlıklı durumlarının teşhisinde yenilikçi bir yaklaşım sunmaktadır. Gradient Boosting algoritması, arızaların tespiti ve sınıflandırılmasında yüksek performans sergileyerek bu alandaki potansiyelini kanıtlamıştır.

COMPARISON OF POWER TRANSFORMER SFRA (SWEEP FREQUENCY RESPONSE ANALYSIS) RESULTS WITH ARTIFICIAL INTELLIGENCE APPLICATIONS

SUMMARY

Electric energy has emerged as one of the most indispensable resources of the 21st century, playing a pivotal role in the economic, technological, and social development of nations. In the context of a rapidly evolving global landscape, the continuity and sustainability of modern life are fundamentally intertwined with the reliable generation, transmission, and utilization of electric power. Today, electricity is not merely a convenience but a critical enabler of progress, shaping the way people live, work, and interact with the world around them.

From residential usage to large-scale industrial operations, from agricultural automation systems to modern transportation networks, electric energy permeates nearly every domain of human activity. The exponential growth of technology has resulted in an increasing dependency on electrical systems. The proliferation of electrically powered appliances, machines, and systems—such as smart home devices, HVAC (heating, ventilation, and air conditioning) systems, electrically driven manufacturing processes, and medical diagnostic and therapeutic equipment—has fundamentally transformed the infrastructure of contemporary society. One of the most notable developments in recent years has been the widespread adoption of electric vehicles (EVs), which has introduced a new dimension to energy demand and grid management. As EVs become increasingly common in urban and rural areas alike, they place additional demands on the electrical infrastructure. This shift toward electrified transportation systems not only contributes to reduced greenhouse gas emissions but also underscores the need for a resilient, stable, and intelligent energy grid capable of handling dynamic and high-load conditions.

In the specific case of Turkey, a clear illustration of this transformation can be observed in the dramatic increase in per capita electricity consumption. While electricity usage per individual was limited to just a few kilowatt-hours at the beginning of the 20th century, it has now surged to approximately 3900 kWh per year, signifying a rapid trajectory of electrification and industrialization. This steep rise in energy consumption reflects not only increased access to electricity but also the growing technological sophistication and urbanization of the country.

However, the growing demand for electricity comes with considerable technical and operational challenges, particularly concerning the reliability and stability of the power transmission and distribution network. At the heart of this network lie transformers, which serve as critical components for voltage regulation and efficient power delivery over long distances. These devices ensure that electricity generated at power plants can be safely and effectively transmitted to end users, regardless of geographic location.

Despite their central role in the grid, transformers are susceptible to degradation and failure over time due to several contributing factors. Prolonged operation under heavy loads, exposure to adverse environmental conditions (such as moisture, dust, and temperature fluctuations), natural aging of insulation and other materials, and unforeseen external disturbances (including short circuits or lightning strikes) can all compromise the structural integrity and operational efficiency of transformers. If such issues are not identified and addressed in a timely manner, they can lead to unexpected outages, safety hazards, and significant economic losses.

Therefore, the early detection and accurate diagnosis of transformer faults is of utmost importance for maintaining the overall health of the electrical grid. Traditional diagnostic techniques, such as dissolved gas analysis (DGA), insulation resistance testing, and other offline and online methods, have been widely adopted across the industry. However, while these conventional approaches are useful in identifying certain fault types, they may not always be effective in detecting incipient or internal faults, particularly during the early stages when symptoms are subtle and not easily discernible. This limitation underscores the necessity of complementing traditional test methods with advanced diagnostic tools and technologies. By doing so, utilities and energy providers can shift from reactive maintenance approaches toward more proactive and predictive maintenance strategies, enhancing both operational reliability and cost-effectiveness.

At this point, the Sweep Frequency Response Analysis (SFRA) method plays a crucial role. SFRA testing involves applying low-amplitude signals between a transformer's input and output terminals to measure its frequency response characteristics. The resulting Bode diagrams reveal changes within the internal structure of the transformer. Issues such as core loosening, winding displacement, and short circuits can thus be identified. However, interpreting these diagrams generally requires experience and expertise.

For this reason, the integration of Artificial Intelligence (AI) and Machine Learning (ML) algorithms with SFRA data marks a new era in fault diagnosis. Machine learning algorithms can successfully perform pattern recognition and classification tasks based on large datasets. This study addresses three primary conditions in transformers: core faults, winding displacement faults, and healthy status. Six different algorithms were tested: Logistic Regression, Random Forest, k-Nearest Neighbors, Support Vector Machines, Naïve Bayes, and Gradient Boosting Classifier (GBC).

As a result of the study, the GBC algorithm demonstrated superior accuracy rates. This algorithm efficiently processes large volumes of data and minimizes the likelihood of false positives. Its performance was evaluated through confusion matrix analysis and various graphical methods. These include Learning Curve, Calibration Curve, Gain Chart, Cumulative Accuracy Profile, and KS statistics. Through these tools, the learning capacity, stability, and generalization capability of the algorithm were analyzed in depth.

The Gradient Boosting Classifier (GBC) stood out among the tested algorithms for its remarkable ability to produce consistent and accurate results, even when trained on relatively small and imbalanced datasets. This capability is particularly valuable in real-world transformer fault diagnosis scenarios, where obtaining large quantities of labeled fault data can be both time-consuming and costly. The robustness of GBC against data limitations underscores its adaptability and efficiency in practical applications.

During the training phase, hyperparameter tuning was meticulously performed to ensure optimal model performance. Techniques such as grid search and randomized search were employed to identify the most suitable values for parameters like learning rate, number of estimators, and tree depth. Additionally, k-fold cross-validation was used to evaluate the model's ability to generalize to unseen data, thus minimizing the risk of overfitting. As a result, the GBC model demonstrated both high precision and recall, contributing to a well-balanced and reliable classification system.

One of the most significant advantages of incorporating such machine learning models into fault diagnosis processes is the reduction of subjective interpretation. Traditional diagnostic methods, particularly those relying on SFRA test results, often depend on the experience and judgment of expert engineers to interpret frequency response curves. This human-dependent process introduces variability and potential inaccuracies. In contrast, AI-based models can provide standardized, repeatable, and data-driven insights, reducing the room for error and improving the overall reliability of diagnostics.

From a broader perspective, the integration of AI-driven diagnostic systems into routine transformer maintenance holds transformative potential. In particular, it paves the way for the adoption of predictive maintenance strategies, which focus on anticipating failures before they occur rather than responding after the fact. Predictive maintenance leverages real-time and historical data to monitor the health of equipment continuously, identify early signs of deterioration, and schedule maintenance activities at the most cost-effective and operationally convenient times. This proactive approach not only minimizes unplanned outages and maintenance costs but also helps extend the service life of critical assets like transformers.

Furthermore, as energy transmission and distribution networks become increasingly digitalized, the incorporation of AI-supported diagnostic tools is rapidly becoming essential. These tools can be integrated into smart grid infrastructures, enabling automated, continuous monitoring of transformer conditions and real-time decision-making. By embedding machine learning models directly into the grid's control systems, utilities can optimize load balancing, reduce downtime, and enhance system resilience against unexpected disruptions.

In conclusion, this study clearly illustrates the transformative impact that Artificial Intelligence and Machine Learning technologies can have on the field of power transformer diagnostics. The synergy between a robust testing methodology like Sweep Frequency Response Analysis (SFRA) and advanced machine learning algorithms enhances the accuracy, speed, and objectivity of fault detection processes. Among the evaluated models, the Gradient Boosting Classifier demonstrated exceptional performance, setting a benchmark for future research and industrial implementations.

As the global demand for electric energy continues to grow, ensuring the stability, efficiency, and resilience of energy systems has never been more critical. Under these circumstances, reliance on conventional testing methods alone is insufficient. Instead, investing in intelligent, data-driven diagnostic systems has become an operational necessity. Such systems not only help utilities respond faster to emerging faults but also enable them to anticipate and prevent failures, thus ensuring uninterrupted energy delivery.

Finally, it is important to highlight that academic research of this nature serves a dual purpose. On one hand, it contributes to the theoretical understanding of machine

learning applications in electrical engineering. On the other hand, it offers practical, scalable solutions that can be directly applied in the field. For mission-critical infrastructure like transformers, the use of AI-enhanced fault detection methods promises greater operational efficiency, reduced maintenance costs, and improved asset longevity. In the future, such technologies will play an indispensable role in shaping a more intelligent, sustainable, and resilient energy infrastructure.



1. GİRİŞ

Son yüzyılda modern uygarlığı şekillendiren teknolojik devrimler, iletişim, ulaşım ve elektrik gücü alanlarındaki temel gelişmelerden doğmuştur. Buluşçuların iletişim ve ulaşım alanlarındaki başarıları, telefon, televizyon, kara ve hava ulaşım araçlarındaki icatların günlük yaşamın vazgeçilmez parçaları haline gelmesine yol açmıştır. Elektrikli araçların kullanılmaya başlamasıyla, elektrik enerjisi ihtiyacı olağan artışına ilave olarak, bir binek elektrikli aracın (Electrical Vecihle-EV) ortalama yılda 12000km yol kat edeceğini istatistiğe dayanarak, yılda araç başına 2000kWh elektrik enerjisi ihtiyacı ortaya çıkmaktadır. Tüm ülkelerin enerji altyapısını yani, iletim hatlarını, trafo merkezlerini, dağıtım şebekelerini hızla arttırmasını zaruri hale getirmiştir, tüm bu gelişmeler neticesinde yeni transformatör ihtiyacı artacak, mevcut transformatörlerin yükü artması nedeniyle, test ve bakımları çok daha önemli hale gelmektedir, Test sonuçlarının yorumlarınsa makine öğrenmesi ve yapay zekâ kullanılması, zaman ve hataların aza indirgenmesi açısından çok önem arz etmektedir. Ayrıca küresel iklim değişikliği nedeniyle Dünya da kısıtlı miktarda bulunan içilebilir tatlı su kaynakları gün geçtikçe azalmaktadır. Yakın gelecekte kuraklığın artarak devam edeceği tartışma götürmez bir olgu olarak dünyanın karşında durmaktadır. Şu an ortadoğu ülkelerinde yaygın olarak elektrik enerjisi ile deniz suyundan içme ve kullanma suyu elde edilmesi(distilasyon), dünyanın pek çok orta kuşak ülkelere yaygınlaşacaktır, günümüzde deniz suyundan içme kullanma suyu elde edilmesi için ortalama 3kWh/m³ elektrik enerjisi gerekmektedir.

Türkiye, çelik üretiminde dünya da üst sıralarda yer almaktadır. Çelik ve çelik ürünleri üretiminin yanı sıra metal ve çelik işlemede yıllar içinde büyük birikim elde etmiştir, bunların bir sonucu olarak da Metal işleme konusunda, devletinde teşviki ile başta ticari ve askeri gemi üretimi, metal aksamli askeri ekipmanları insanli insansız hava araçları, otomotiv ve transformatör ve transformatör kazanı üretiminde dünyada ilk sıralarda yer almaktadır. Her güç transformatörün müşteriye özel tasarlandığı ve emek yoğun bir üretim, montaj ve devreye alma süreci olduğu göz önüne alınarak, sektörde yetişmiş insan ve bilgi birikimi önem arz etmektedir.

Elektrik enerjisinin yaygın olarak kullanılmasını mümkün kılan transformatör, günlük yaşamda göz önünde olmayan, ancak hayati öneme sahip bir ayardır. Transformatörler, hareket etmeyen, neredeyse tamamen sessiz olan ve genellikle perde arkasında bulunan cihazlardır. Ancak bu mütevazı cihazlar, çağdaş elektrik güç sistemlerinin ayrılmaz bir parçasıdır (Chakravorti ve ark. 2013).

Transformatörün temel işlevi, düşük akımlı yüksek gerilimli elektriğı, hemen hemen hiç enerji kaybı olmaksızın yüksek akımlı düşük gerilimli duruma (veya tam tersi) dönüştürmektir. Bu dönüşüm, elektrik enerjisinin en verimli şekilde yüksek gerilimle iletilip düşük gerilimle üretilip kullanılması gerektiğı için büyük bir öneme sahiptir. Elektrik enerjisinin iletiminde yüksek gerilim kullanmak, enerji kayıplarını minimize ederken, düşük gerilim kullanmak güvenliğı artırır ve cihazların çalışması için gereklidir (Fofana ve ark. 2016). Eğer transformatörler olmasaydı, elektrik jeneratörleri ile tüketiciler arasındaki mesafenin en aza indirilmesi zorunluluğı doğacak ve bu da birçok yerleşim yerinin ve endüstri merkezinin kendi güç istasyonlarını kurmalarını gerektirecek ve elektrik enerjisi çok daha az kullanışlı bir hale gelecekti.

Elektrik güç sistemlerindeki hayati rolüne ek olarak, transformatörler elektrikle çalışan birçok cihazın da önemli bir parçasıdır. Masa lambalarından pil şarj cihazlarına, oyuncak trenlerden televizyonlara kadar birçok cihazda gerilimi ayarlamak için transformatörler kullanılır. Transformatörlerin boyutları kullanım alanlarına göre büyük farklılıklar gösterebilir; bazen çok küçük boyutlarda olabilirken, bazen de 500 ton ağırlığa ulaşabilmektedir (Şekil 1.1). Bu çeşitlilik, transformatörlerin ne kadar geniş bir uygulama yelpazesinde kullanıldığını göstermektedir (Coltman, 1998).



Şekil 1.1. 80MVA 110 KV Güç Trafosu Örneği (SCOTECH, t.y.)

Transformatörün temel işlevi, 1831 yılında İngiliz fizikçi Michael Faraday tarafından keşfedilmiştir. Faraday, elektromanyetizma ve elektromanyetik indüksiyon üzerine yaptığı çalışmalarla, elektrik enerjisinin dönüştürülmesi sürecinin temel ilkelerini ortaya koymuştur. Faraday'ın çalışmaları, 1820'de bir iletkenle geçen elektrik akımının, iletken etrafında manyetik alan yarattığını göstermiş olan Danimarkalı fizikçi Hans Christian Ørsted için ilham kaynağı olmuştur. Ørsted'in bu keşfi o zaman için çok önemlidir, çünkü bu olaya kadar elektrik ve manyetizma birbiriyle ilgisiz kuvvetler olarak bilinmektedir. 1831'de Faraday, manyetik alanın bir iletkenle akım endükleyebilmesi için alanın değişken olması gerektiğini göstermiştir. Faraday, alanın değişmesini, alanı yaratan elektrik devresini açıp kapayarak sağlamaktaydı; aynı etki, yönü zamanla değişen bir akımla da sağlanabilmektedir. Elektrik ve manyetizmanın bu etkileşimi elektromanyetik endüksiyon olarak bilinmektedir. Ancak, Faraday'ın keşfinden yaklaşık elli yıl sonra, çağdaş anlamda kullanışlı bir transformatör geliştirilebilmiştir. Bu transformatör, elektrikle aydınlatma endüstrisinde devrim yaratan tüm gerekli bileşenlere sahiptir (Coltman, 1998).

19. Yüzyılın sonlarında, alternatif akımlı (AC) güç sistemleri tüm dünyada yaygın olarak kullanılmaya başlandı ve transformatörler, elektrik enerjisinin iletiminde ve dağıtımında anahtar bir rol üstlenmiştir. 20. yüzyılın başlarındaki transformatörler, bugünlüklere kıyasla daha sınırlı kapasiteye sahipti. Ancak teknolojiye hızlı ilerlemeler, transformatörlerin hem güç hem de gerilim kapasitelerinin önemli ölçüde artmasını sağladı. Modern transformatörler, 20. yüzyılın başındaki atalarına kıyasla güç bakımından 500 kat, gerilim bakımından ise 15 kat daha fazla kapasiteye sahiptir. Ayrıca, güç birimi başına ağırlık 10 kat azalmış ve verimlilik genellikle %99'un


üzerine çıkmıştır. Bu gelişmeler, teorik çalışmaların ve mühendisliğin birleşmesinin bir sonucudur. Transformatörlerin sürekli olarak geliştirilen ve iyileştirilen tasarımları, gelecekte de elektrik enerjisinin yaygın ve verimli kullanımını güvence altına alacaktır (Chakravorti ve ark. 2013). Günümüzde transformatörler, yalnızca elektrik güç sistemlerinde değil, aynı zamanda birçok elektrikli cihazda da kritik bir rol oynamaktadır. Evlerde kullanılan masa lambalarından, endüstriyel uygulamalardaki ağır makinelerden, sağlık sektöründeki tıbbi cihazlara kadar birçok alanda transformatörler bulunmaktadır. Örneğin, telefon şarj cihazları, bilgisayar güç kaynakları ve çeşitli ev aletleri gibi günlük yaşamda sıkça kullanılan cihazlarda gerilimi düzenlemek için transformatörler kullanılmaktadır. Bu cihazlar, farklı voltaj seviyelerinde çalışabilmeleri için transformatörler sayesinde güvenli ve verimli bir şekilde elektrik enerjisini kullanabilirler. Transformatör teknolojisindeki ilerlemeler, enerji verimliliğini artırmaya ve çevresel etkileri azaltmaya yönelik yenilikleri de beraberinde getirmiştir. Yüksek verimli transformatörler, enerji kayıplarını minimize ederek hem ekonomik hem de çevresel faydalar sağlamaktadır. Ayrıca, transformatörlerin tasarımında kullanılan malzemeler ve üretim tekniklerindeki gelişmeler, daha kompakt ve hafif transformatörlerin üretilmesine olanak tanımıştır. Bu da özellikle taşınabilir cihazlarda ve dar alanlarda kullanım için büyük avantajlar sunmaktadır (Coltman, 1998).

Transformatör, modern elektrik güç sistemlerinin bel kemiğini oluşturan, sessiz ama etkili bir teknolojik devrimdir. Faraday'ın temel ilkeleri üzerine inşa edilen ve sürekli gelişen bu cihaz, elektrik enerjisinin verimli bir şekilde üretilmesini, iletilmesini ve kullanılmasını sağlamaktadır. Transformatörlerin sürekli olarak geliştirilen ve iyileştirilen tasarımları, gelecekte de elektrik enerjisinin yaygın ve verimli kullanımını güvence altına alacaktır. Bu gelişmeler, transformatörlerin yalnızca elektrik güç sistemlerinde değil, aynı zamanda günlük yaşamın her alanında ne kadar vazgeçilmez bir teknoloji olduğunu bir kez daha göstermektedir.


Endüksiyon en iyi şekilde Faraday'ın bir manyetik alanın yönünü ve kuvvetini anlatmak için ortaya attığı kuvvet çizgileri yoluyla anlaşılabilir. Çember şeklinde sarılmış bir telden geçen akımın yarattığı manyetik alan için çizilmiş kuvvet çizgileri görülmektedir. İlkinden bağımsız ikinci bir tel döngü, değişken bir manyetik alan içine konulduğunda, döngüde içine aldığı kuvvet çizgilerinin zamana göre değişimiyle orantılı bir gerilim oluşmaktadır. Yapılan bobin iki sarımlıysa, böyle bir

etkileşim her sarımda meydana gelir ve sonuçta gerilim iki katına çıkar; üç sarım varsa gerilim üç katına çıkar ve bu durum sarım sayısıyla gerilim arasındaki doğru orantıyı göstermektedir. (Gerilim, yükleri hareket ettiren basınç, akım da yüklerin akma oranı olarak düşünülebilir. Bunların çarpımı—gerilim volt, akım amper birimiyle—watt olarak elektriksel güce eşittir) (Coltman, 1998).


Bir transformatörde akımla beslenen ve manyetik alanı üreten sarıma birincil ("primary") adı verilir. Manyetik alanı tutan sarıma da ikincil ("secondary") denir. Birincil ve ikincil sarım arasında karşılıklı endüksiyon vardır; yani ikincil sarımda akan akım birincilde bir gerilim endüklerken, aynı yolla birincil de ikincil sarımda gerilim yaratmaktadır. Ayrıca, birincil sarım kendi kuvvet çizgilerini de içine aldığından kendi üzerinde de gerilim endükler, bu olay öz-endüksiyon ("self-induction") olarak bilinir ve ikincil sarımda da meydana gelmektedir (Coltman, 1998). Transformatörün işlevsel gösterimi Şekil 1.2’de, elektriksel gösterimi Şekil 1.3’te verilmektedir. Transformatörün sekonder kısım gerilim indüklenmesi Şekil 1.4’te gösterilmiştir.



Şekil 1.2. Transformatörün İşlevsel Gösterimi (Rawlins, 2000)



Şekil 1.3. Transformatörün Elektriksel Gösterimi (Rawlins, 2000)



Şekil 1.4. Transformatör Sekonder Kısım Gerilim İndüklenmesi (Rawlins, 2000)

Transformatörlerin çeşitli türleri bulunmaktadır ve bu türler, farklı uygulama alanlarına göre sınıflandırılır. Güç transformatörleri, modern elektrik güç sistemlerinin en kritik bileşenlerinden biridir ve yüksek voltaj ile büyük güç kapasiteleri sayesinde enerji iletim ve dağıtımında önemli bir rol oynar. Bu transformatörler, enerji santrallerinden şehir merkezlerine ve endüstriyel bölgelere elektrik enerjisinin taşınmasını sağlar. Güç transformatörleri genellikle 33 kV ve üzeri gerilim seviyelerinde çalışır ve büyük ölçekli enerji transferleri için tasarlanmıştır. Yüksek gerilim seviyelerinde çalışarak enerji kayıplarını minimize ederler ve uzun mesafelere enerji iletimini mümkün kılarlar (Karaisas ve ark. 2023).

Güç transformatörlerinin ana bileşenleri primer ve sekonder sargılar, manyetik çekirdek ve yalıtım malzemeleridir. Primer ve sekonder sargılar, elektrik enerjisinin giriş ve çıkış noktalarını oluşturur. Manyetik çekirdek, enerji dönüşümünü sağlayan manyetik devreyi oluşturur ve genellikle enerji kayıplarını minimize etmek amacıyla silikon çelikten yapılır. Yalıtım malzemeleri ise sargılar arasında ve sargılar ile çekirdek arasında elektriksel yalıtım sağlar, bu da transformatörün güvenli ve verimli çalışmasını temin eder (Karaisas ve ark. 2023).

Güç transformatörleri, kullanım alanlarına göre farklı tiplerde olabilir. Yükseltici (step-up) transformatörler, enerji santrallerinde üretilen elektriğin voltajını yükseltmek

iin kullanılır, bu sayede elektrik enerjisi iletim hatları zerinden daha verimli bir ekilde tařınabilir. Dřrc (step-down) transformatrler ise elektrięin yksek voltajdan daha dřk voltaj seviyelerine indirildięi yerlerde kullanılır, bu da řehir merkezleri ve endstriyel tesislerde enerji tketicilerine uygun voltaj seviyelerinde elektrik saęlanması mmkn kılar (Coltman, 1998).

G transformatrleri (řekil 1.5), zellikle enerji santrallerinde retilen elektrięin verimli bir ekilde iletilmesi ve daęıtılmasını saęlar. Yksek gerilim seviyelerinde alıřmaları sayesinde, uzun mesafelere enerji iletimi sırasında oluřabilecek enerji kayıplarını minimize ederler. Bu zellikleri ile, elektrik enerjisinin geniř alanlara yayılmasını ve eřitli tketim noktalarına gvenli bir ekilde ulařmasını mmkn kılarlar. Modern transformatr teknolojisindeki ilerlemeler, enerji verimlilięini artırmakta ve evresel etkileri azaltmaktadır. Bu geliřmeler, enerji sektrnde srdrlebilir ve gvenilir bir enerji altyapısının oluřturulmasına katkıda bulunmaktadır. G transformatrlerinin doęru seimi ve bakımı, enerji sistemlerinin performansını optimize etmek iin nemlidir ve bu nedenle enerji sektrnde dikkatle ele alınmalıdır (Karaisas ve ark. 2023).



řekil 1.5. G Transformatr (Durusel Elektrik, t.y.)

Daęıtım transformatrleri, enerji daęıtım aęlarının kritik bileřenlerindendir ve dřk voltaj gereksinimlerine sahip son kullanıcılar iin elektrik enerjisinin verimli ve gvenilir bir ekilde iletilmesini saęlar. Bu transformatrler genellikle řehir ii daęıtım sistemlerinde kullanılır ve 33 kV altındaki gerilim seviyelerinde alıřır. Daęıtım transformatrlerinin performansı, enerji kayıplarını minimize ederek ve maliyet etkin


özmler sunarak enerji sistemlerinin genel verimliliğini artırır. Yağ soğutmalı ve kuru tip olmak üzere iki ana türü bulunur. Yağ soğutmalı transformatörler, iç yapılarındaki yağın doğal dolaşımı ile soğutma sağlarken, kuru tip transformatörler hava ile soğutulur ve yangın riski düşük, çevre dostu çözümler sunmaktadır (Shahriar ve ark, 2022).

Transformatörlere uygulanan testler, güvenilirlik, performans doğrulama, güvenlik, arızaların önlenmesi, yasal uygunluk, yaşlanma ve değişim takibi, kurulum ve devreye alma doğrulaması ve performans optimizasyonu gibi çeşitli nedenlerle gerçekleştirilir. Bu bağlamda, testler transformatörlerin güvenilirliğini sağlamak için büyük önem taşımaktadır. Her transformatörün belirli bir güç kapasitesine ve verimliliğe sahip olması gerektiğinden, bu performans gereksinimlerinin karşılandığını doğrulamak için çeşitli testler uygulanır. Transformatörler, yüksek gerilim ve akım taşıdıkları için güvenlik standartlarına uygunlukları da titizlikle test edilmelidir. Bu testler, izolasyon direnci, sargı dayanıklılığı ve diğer güvenlik kriterlerini değerlendirerek güvenliğı sağlar. Testler aynı zamanda transformatörlerde erken aşamada ortaya çıkabilecek potansiyel sorunları tespit ederek ciddi arızaların önlenmesine katkıda bulunur. Bu proaktif bakım yaklaşımı, arıza sürelerini ve bakım maliyetlerini minimize etmektedir. Transformatör üretimi ve işletimi, ulusal ve uluslararası çeşitli standartlara tabi olup, testler bu standartlara uygunluğun belirlenmesinde kullanılır. Zamanla, transformatörler mekanik ve elektriksel strese maruz kalarak performans değişiklikleri gösterebilir. Periyodik olarak gerçekleştirilen testler, transformatörlerin yaşlanma sürecini ve performansındaki değişiklikleri izleyerek, bakım ve değiştirme planlarının oluşturulmasına olanak tanımaktadır. Yeni kurulan veya sahada devreye alınan transformatörlerin, güvenli ve doğru bir şekilde çalıştığını doğrulamak amacıyla test edilmesi gereklidir. Bu testler, kurulum hatalarını ve üretimden kaynaklanan olası sorunları tespit etmeye yarar. Test sonuçları ayrıca transformatörlerin performansını optimize etmek için gerekli bilgileri sağlar, bu da enerji verimliliğini artırmak ve operasyonel maliyetleri azaltmak açısından önemlidir. Transformatör testleri, rutin testler, tip testleri, özel testler ve devreye alma testleri dört ana kategoriye ayrılabilir. Bu testler, transformatörlerin güvenilirliğini, performansını ve güvenliğini sağlamak amacıyla gerçekleştirilir.

Frekans tarama cevabı analizi (Sweep Frequency Response Analysis SFRA), güç transformatörlerinin çekirdek, sargılar ve sıkıştırma yapılarının mekanik bütünlüğünü değerlendirmek için kullanılan bir yöntemdir. Elektriksel transfer fonksiyonlarını geniş bir frekans aralığında ölçerek yapılmaktadır. SFRA, üç ana yöntemle değerlendirilir: zaman bazlı, tip bazlı ve faz karşılaştırması. Zaman bazlı karşılaştırma, mevcut SFRA sonuçlarının aynı ünitenin önceki sonuçlarıyla karşılaştırılmasıdır. Tip bazlı karşılaştırma, bir transformatörün SFRA sonuçlarının aynı tipteki başka bir transformatörün sonuçlarıyla karşılaştırılmasıdır. Faz karşılaştırması ise bir fazın SFRA sonuçlarının aynı transformatörün diğer fazlarının sonuçlarıyla karşılaştırılmasıdır. SFRA süreci, transformatöre farklı frekanslarda sinyaller göndererek başlamaktadır. Transformatör, belirli frekanslarda test edildiğinde özel bir imza üretir ve bu imza bir eğri olarak çizilir (Hayt ve ark,2011). İletkenler arasındaki mesafe bir kapasitans oluşturur. İletkenlerin veya sargıların hareketi bu kapasitansı değiştirir. Bu kapasitans, karmaşık L (indüktans), R (direnç) ve C (kapasitans) ağına dahil olduğundan, herhangi bir değişiklik bu eğride yansımaktadır. İlk SFRA testi, transformatörün frekans yanıtının imzasını elde etmek için gerçekleştirilir. Bu referans, gelecekteki karşılaştırmalar için kullanılır. Sargı pozisyonundaki değişiklikler, yalıtımın bozulması gibi durumlar kapasitans veya indüktans değişikliğine neden olarak ölçülen eğrileri etkilemektedir. Testler, periyodik olarak veya kısa devre gibi büyük dış olaylar sırasında gerçekleştirilir ve sonuçlar ilk imzayla karşılaştırılarak olası sorunlar test edilir (Hayt ve ark,2011).

SFRA analizi, sargı deformasyonları (eksensel ve radyal), yüksek ve düşük gerilim sargıları arasındaki yer değişiklikleri, kısmi sargı çökmesi, kısa devreler veya açık devre sargıları, çekirdeğin veya ekranların hatalı topraklaması, çekirdek hareketi, kırılmış sıkıştırma yapıları ve problemlili iç bağlantılar gibi sorunları tespit edebilmektedir. Tipik SFRA test bağlantısı örnek olarak Şekil 1.6'da verilmektedir. SFRA, sağlam transformatörlerin başlangıç imzasını almak, düzenli bakım kapsamında periyodik kontroller yapmak, kısa devre gibi büyük dış olaylardan hemen sonra, transformatör taşınması veya yer değiştirmesi sırasında, devreye alma öncesi kontroller gibi çeşitli durumlarda kullanılmaktadır (Hayt ve ark,2011) (Mohan,2011). Bode diyagramları, SFRA testleri sırasında elde edilen verilerin analizinde kullanılır. Bode diyagramları, bir sistemin frekans cevabını grafiksel olarak gösterir ve genlik ile faz açısını frekansın bir fonksiyonu olarak sunar. Genlik diyagramı, frekansa karşı

genlik (dB cinsinden) grafiğidir. Faz diyagramı ise, frekansa karşı faz açısını (derece cinsinden) göstermektedir. Bu grafikler, transformatörün frekans yanıtının değerlendirilmesini ve olası anormalliklerin tespit edilmesini sağlamaktadır. Bode diyagramları, transformatörün frekans cevabını görselleştirir ve analiz eder, böylece transformatörün mekanik ve elektriksel bütünlüğü hakkında detaylı bilgi sağlanır (Mohan,2011) (IEEE C57.149,2012).



Şekil 1.6. Tipik SFRA Test Bağlantıları (El-Faraskoury,2015)

Bu çalışmada transformatörlerde sıklıkla karşılaşılan çekirdek kısa devresi ve sargı kayması gibi iç arızaların tespiti amacıyla, SFRA ölçümleri ile elde edilen verileri yapay zekâ ve makine öğrenimi algoritmaları kullanarak analiz etmek hedeflenmiştir. Bu teknolojiler, büyük veri setlerini işleyebilme kapasitesine sahip olup, norm dışı sapmaları, eğilimleri ve olası arıza belirtilerini tespit edebilir. Yapay zekâ tabanlı sistemler, SFRA test sonuçlarını izleyerek transformatörlerin durumunu gerçek zamanlı değerlendirme yeteneği sağlar. Böylece, olası arızalar daha erken aşamalarda tespit edilerek, önleyici bakım tedbirleri alınabilir ve transformatörlerin arıza riskleri en aza indirilebilir. Ayrıca, yapay zekâ sistemleri farklı transformatörler arasında kıyaslamalar yaparak, tipik performans eğrilerini ve olası anormallikleri belirlemede etkin bir şekilde kullanılabilir. Yapay zekâ ve makine öğrenimi algoritmaları, SFRA testlerinden elde edilen geniş veri setlerini analiz ederek, zaman içinde değişen performans verilerini depolayıp uzun vadeli eğilimleri ve sapmaları tespit edebilir. Örneğin, belirli bir frekans aralığında sürekli görülen sapmalar, sargı deformasyonları veya çekirdek hasarları gibi mekanik sorunlara işaret edebilir. Yapay zekâ algoritmaları bu verileri analiz ederek, insan gözlemiyle tespit edilmesi zor olan küçük değişiklikleri bile fark edebilir. Bunun yanında, yapay zekâ sistemleri her bir transformatörün geçmiş performans verilerini güncel verilerle karşılaştırarak anormal davranışları hızla tanımlayabilir. Bu karşılaştırmalar, transformatörlerin farklı çalışma

koşullarına verdikleri tepkileri değerlendirmek için de kullanılabilir. Yapay zekâ sistemleri ayrıca, farklı transformatörler arasında karşılaştırmalar yaparak genel performans eğilimlerini belirleyebilir ve bu durum, üreticiler ile bakım ekipleri için değerli bilgiler sağlar. Örneğin, belirli bir modelin diğer modellere kıyasla daha sık arıza yaptığı tespit edilirse, bu modelin tasarımı veya bakım prosedürlerinde yapılacak değişiklikler gerektiği anlaşılabilir.

Bu bilgilerden yola çıkarak bu çalışmada SFRA ile yapay zekâ teknolojisi birlikte kullanılarak tespit edilen probleme yönelik en ergonomik ve optimum çözüm üretilmeye çalışılmıştır. Çalışmaya yönelik literatür çalışmaları, transformatör ve transformatörlere ait teorik ve saha bilgileri, yapay zekâ makine öğrenmesi algoritmalarına ilişkin bilgiler ayrı bölümler halinde bu tez çalışmasında sıra ile paylaşılmıştır. Çalışmanın uygulanması; deney ve simülasyon aşamaları, çalışmanın performansının matematiksel olarak değerlendirilmesi bölüm 4 ve bölüm 5'te detaylı şekilde paylaşılmaktadır.

1.1. Literatür Araştırması

Literatürde bu konuya ilişkin birçok çalışma bulunmaktadır. Turan ve arkadaşları yapmış oldukları çalışmada, güç transformatörlerindeki arızaların tespiti için bulanık mantık tabanlı Rogers ve IEC oran yöntemlerini kullanmışlardır (Turan ve ark,2024). Elektrik enerjisinin iletimi ve dağıtımında önemli bir role sahip olan güç transformatörlerinde oluşabilecek arızaların önceden tespiti, sistemin ve ekipmanların korunması açısından kritik öneme sahiptir. Yağda çözünmüş gaz analizi (DGA) kullanılarak bu arızalar daha başlangıç aşamasında tespit edilebilir. DGA yöntemleri, klasik ve akıllı sistemler olarak ikiye ayrılmaktadır. Klasik yöntemlerin doğruluğunu artırmak amacıyla akıllı sistemler geliştirilmiştir. Bu çalışmada, TEİAŞ'tan alınan gaz limit değerleri kullanılarak bulanık mantık tabanlı IEC ve Rogers oran yöntemleri MATLAB programında uygulanmış ve sonuçlar analiz edilmiştir. Çalışmanın bulgularına göre, bulanık mantık tabanlı yöntemler klasik yöntemlere göre daha yüksek doğrulukta arıza tespiti sağlamıştır. Özellikle bulanık mantık tabanlı Rogers oran yöntemi, %91,67 doğruluk oranı ile en başarılı sonuçları vermiştir. Bu sonuçlar, akıllı sistemlerin klasik yöntemlere kıyasla daha güvenilir arıza tespiti sağladığını göstermektedir (Turan ve ark,2024).

Literatürde Bjelić ve arkadaşlarının yaptığı çalışmada (Bjelić ve ark, 2024), SFRA verilerine dayalı transformatör sağlık değerlendirmesi için makine öğrenimi yöntemlerinin kullanıldığı çalışma bulunmaktadır. Bu çalışmada, iç kısa devre arızalarına sahip transformatörlerden elde edilen verilerle ANN ve ANFIS algoritmaları kullanılarak arıza durumu tahmin edilmiştir. Ayrıca, k-ortalama kümeleme ile benzer arıza grupları oluşturulmuştur.

Bu tezde ise Python ortamında yaklaşık 6 adet ayrı model geliştirerek ayrı ayrı performans analizleri yapılmış ve modeller karşılaştırılmıştır. En yüksek başarı değerleri veren Gradient Boosting Classifier (GBC) algoritması kullanılarak SFRA verileri üzerinden transformatör arıza sınıflandırması gerçekleştirilmiştir.

Atalar ve arkadaşlarının yaptığı çalışmada, güç transformatörlerindeki arızaların tespiti için yağda çözünmüş gaz analizi (DGA) yöntemi kullanılarak IEC oran metodu ve bulanık mantık yöntemi incelenmiştir (Atalar ve ark,2024). Güç transformatörlerinin enerji iletimindeki kritik rolü ve arızaların erken tespiti önemi vurgulanmıştır. Arızaların erken tespiti, enerji kesintilerini ve maddi kayıpları önleyerek sistemin ve ekipmanların korunmasını sağlamaktadır. Çalışmada, IEC oran metodu ile Hidrojen (H_2), Metan (CH_4), Etilen (C_2H_4), Etan (C_2H_6) ve Asetilen (C_2H_2) gazlarının oranları değerlendirilmiştir. IEC oran metodu, bu gazların belirli oranlarını kullanarak arıza tiplerini tespit eder, ancak bazı kısıtlamaları bulunmaktadır. Özellikle, bazı arızaları tespit edememe veya birden fazla arızanın varlığını belirleyememe gibi dezavantajları vardır. Bulanık mantık yöntemi ise klasik yöntemlerin doğruluğunu artırmak için kullanılmıştır. Bulanık mantık sistemi, insan algısına daha yakın sonuçlar üreterek daha doğru arıza tespiti sağlar. Bu yöntem, IEC oran metoduna uyarlanmış ve gaz oranlarının dilsel değişkenler olarak ifade edilmesiyle arıza değerlendirmesi yapılmıştır. Bulanık mantık sistemi, çoklu arızaların tespitinde daha iyi sonuçlar vermektedir. Deneysel çalışmalarda, 2004 yılında işletmeye alınmış bir transformatör üzerinde analizler yapılmıştır. Farklı tarihlerde alınan yağ örneklerinin gaz konsantrasyonları analiz edilerek IEC oran metodu ve bulanık mantık yöntemi ile karşılaştırılmıştır. Elde edilen sonuçlar, bulanık mantık yönteminin klasik IEC oran metoduna göre daha yüksek doğruluk sağladığını göstermiştir (Atalar ve ark,2024).

Demirçalı ve arkadaşlarının yaptığı çalışmada, enerji sistemlerinin en kritik ve pahalı ekipmanlarından biri olan güç transformatörlerinde meydana gelen arızaların

tanılanması ve sınıflandırılması için Destek Vektör Makineleri (DVM) kullanılmıştır (Demirçalı ve ark,2012). Güç transformatörlerinin sorunsuz çalışması, enerjinin sürdürülebilir ve verimli bir şekilde iletilmesi açısından büyük önem taşır. Herhangi bir arıza durumu enerji kesintisine ve ciddi mali kayıplara neden olabilir, bu nedenle arızaların erken teşhisi kritik bir öneme sahiptir. Yağda çözünmüş gaz analizi (YGA), güç transformatörlerindeki arızaların erken tespiti için kullanılan yaygın ve etkili bir yöntemdir. Bu teknik, yağda çözünmüş hidrojen (H_2), metan (CH_4), asetilen (C_2H_2), etilen (C_2H_4), etan (C_2H_6), karbon monoksit (CO) ve karbondioksit (CO_2) gibi gazların tür ve miktarlarını belirleyerek transformatörün durumu hakkında bilgi verir. Bu gazların miktarları ve türleri, transformatörde meydana gelen arızaların türünü belirlemede önemli ipuçları sağlar. Destek Vektör Makineleri (DVM), makine öğrenmesi algoritmaları arasında önemli bir yer tutar ve sınıflandırma problemlerinde yüksek doğruluk sağlar. Çalışmada, YGA verileri kullanılarak geliştirilen çok katmanlı DVM sınıflandırıcısı ile güç transformatörü arızalarının tanılanması hedeflenmiştir. DVM modelinin parametreleri, örgü arama algoritması ile optimize edilmiştir. Bu yöntem, transformatör arızalarını yüksek doğruluk oranı ile sınıflandırmada klasik yöntemlere göre üstünlük sağlamıştır. Çalışmada, farklı güç transformatörlerine ait 148 adet YGA verisi kullanılmıştır. Bu veriler eğitim ve doğrulama olmak üzere iki sete ayrılmış ve model bu verilerle test edilmiştir. YGA verileri, bir normal sınıf (NF) ve beş hata sınıfı (kısmi deşarj- KD, düşük enerjili deşarj- D1, yüksek enerjili deşarj- D2, düşük ve orta dereceli termik hata- T1&T2, yüksek sıcaklık termik hata- T3) olarak sınıflandırılmıştır. DVM sınıflandırıcısı, doğrulama verilerinin %97,22'sini doğru bir şekilde sınıflandırarak yüksek bir performans sergilemiştir. Sonuçlar, DVM'nin güç transformatörü arıza tanılmasında klasik yöntemlere kıyasla daha yüksek doğruluk oranı ve tutarlılık sağladığını göstermiştir. Bu çalışma, DVM'nin enerji sistemlerinde meydana gelebilecek olası transformatör hatalarını çevrimiçi olarak hızlı ve doğru bir şekilde tanımlayabilecek kapasitede olduğunu ortaya koymuştur. Bu sayede, transformatörlerin sorunsuz çalışması, enerji kesintilerinin ve mali kayıpların önlenmesi sağlanabilmektedir (Demirçalı ve ark,2012).

Özgönel ve arkadaşlarının yaptığı çalışmada, transformatörlerin iç arızalarının tespiti için dinamik temel bileşenler analizi (PCA) ve bağımsız bileşenler analizi (ICA) yöntemleri incelenmiş ve karşılaştırılmıştır (Özgönel ve ark,2024). Geleneksel

olarak, transformatörlerin sayısal korumasında ayrık Fourier dönüşümleri ve dalgacık dönüşümleri gibi yöntemler kullanılmaktadır. Ancak bu çalışmada önerilen PCA ve ICA yöntemlerinin, transformatör iç arızalarının algılanması ve normal çalışma akımlarından ayırt edilmesindeki etkinliği araştırılmıştır. Deneysel çalışmalar, 1000VA, 380/220V, Y/Y, 50Hz özelliklerinde özel bir üç fazlı transformatör üzerinde gerçekleştirilmiştir. Deneylerde, hem sarım-sarım iç arızaları hem de enerjilenme durumları incelenmiş ve önerilen yöntemlerin başarımı MATLAB™ ortamında test edilmiştir. Mıknatıslanma akımları, transformatörlerin enerjilenme anında anma akımının çok üzerinde değerlere ulaşabilmekte ve bu durum diferansiyel rölelerin yanlış açmasına neden olabilmektedir. İç arıza akımları ise genellikle düşük genlikli olup, etkin bir tespit algoritması gerektirmektedir. Bu çalışmada, PCA ve ICA yöntemleri kullanılarak iç arızalar ve mıknatıslanma akımları başarılı bir şekilde ayrıştırılmıştır. PCA, yüksek korelasyonlu çok değişkenli verilerin doğrusal dönüşümü ile boyut azaltma ve veri analizi sağlar. Bu yöntemle, veri matrisi öz değerler ve öz vektörler kullanılarak ayrıştırılır ve hata tespiti için kalıntılar hesaplanır. Çevrim dışı eğitim sürecinde, veri matrisi ölçeklendirilir ve kovaryans matrisi hesaplanarak ana bileşenler elde edilir. Çevrim içi tespit sürecinde ise yeni veri vektörleri otomatik olarak ölçeklendirilir ve hata matrisi hesaplanarak arıza tespiti yapılır. ICA ise çok değişkenli verilerde bağımsız bileşenleri çıkarma yöntemidir. Bu yöntem, bileşenlerin istatistiksel olarak bağımsız olması ve gauss dağılımına uymaması prensibine dayanır. ICA, kör kaynak ayırma problemlerinde kullanılır ve karışık sinyallerden orijinal kaynak sinyallerinin ayrıştırılması için kullanılır. Deneysel çalışmalar sırasında, transformatörün birincil ve ikincil sargılarında iç arızalar oluşturulmuş ve bu arızalar PCA ve ICA yöntemleri ile analiz edilmiştir. Her iki yöntem de iç arıza durumunda ayırt edici özellikler sunmuş olup, transformatör akımlarının frekans bileşenleri yüksek örnekleme frekansı ile detaylı bir şekilde incelenmiştir. İç arıza ve mıknatıslanma akımları, PCA ve ICA yöntemleri ile başarılı bir şekilde ayrıştırılmıştır. Sonuç olarak, PCA ve ICA yöntemlerinin transformatör iç arıza tespitinde etkili olduğu gösterilmiştir. ICA yöntemi, PCA'ya göre daha hızlı ve gerçek zamanlı uygulamalar için daha uygun olabilir. Ancak ICA ile hata tanımlamak, PCA'ya göre daha karmaşık kurallar yazılmasını gerektirebilir. Gelecek çalışmalarda, bu yöntemlerin yapay sinir ağları ile kullanılarak arızanın detaylı tespiti üzerinde durulacaktır (Özgönenel ve ark,2024).

Mlakić ve arkadaşlarının yapmış olduğu çalışmada, yapay zekâ (YZ) ve derin öğrenme (DL) yöntemlerinin enerji tesislerindeki transformatör arızalarının tespitinde nasıl kullanılabileceği incelenmiştir (D. Mlakić ve ark,2018). Derin öğrenme, nesne keşfi, konuşma ve görüntü tanıma gibi temel tanıma görevlerinde önemli ilerlemeler sağlamıştır. Bu bağlamda, özellikle konvolüsyonel sinir ağları (CNN) kullanılarak enerji tesislerinin termal görüntü analizi gerçekleştirilmiştir. Termal görüntüleme, elektrik ekipmanlarının ısıl durumunu belirlemek ve olası arızaları önceden tespit etmek için kritik bir araçtır. Bu çalışmada, 10/0.4 kV hizmet transformatörlerinin termografik görüntüleri analiz edilerek ısı enerjisinin yoğunluk derecesi ve dağılımı incelenmiştir. Transformatörlerdeki erken ısınma, genellikle bir arızanın ilk belirtisi olup, kızılötesi termografi ile bu arızalar temassız bir şekilde tespit edilebilmektedir. CNN, insan görsel sisteminin biyolojik mimarisini temel alarak geliştirilmiş bir yapay sinir ağıdır. Görsel korteksin yapısını ve işlevini anlamak, CNN'lerin görüntü tanıma ve sınıflandırma görevlerinde nasıl çalıştığını anlamak açısından önemlidir. Bu çalışma kapsamında, Matlab yazılımında AlexNet adı verilen CNN ağı kullanılmıştır. Bu ağ, binlerce farklı görüntü ile eğitilerek yeni görüntülerde nesne tanıma yeteneğine sahiptir. Çalışmada, termal görüntüler Matlab ortamına yüklenmiş ve CNN ağı ile analiz edilmiştir. Analiz sonucunda, transformatörlerdeki sıcak noktalar tespit edilmiş ve bu noktaların yoğunluğuna göre transformatörün çalışma durumu değerlendirilmiştir. Örnek uygulamada, bir 10/0.4 kV transformatörün termal görüntüleri analiz edilerek, sıcak noktaların tespiti ve transformatörün durumu hakkında bilgi sağlanmıştır. Bu yöntem, olası büyük hasarların önlenmesi ve enerji kayıplarının minimize edilmesi açısından büyük önem taşımaktadır. Sonuç olarak, bu çalışma derin öğrenme yöntemlerinin enerji tesislerinin termal görüntülerinin analizi için esnek ve uyarlanabilir bir yöntem olduğunu göstermektedir. CNN ağının, insan uzmanlığına ihtiyaç duyulan durumlarda bile başarılı sonuçlar verdiği görülmüş olup, gelecekte bu yöntemin diğer yapay zekâ araçları ile karşılaştırılması ve daha geniş uygulama alanlarında test edilmesi planlanmaktadır (D. Mlakić ve ark,2018).

Pamuk, çalışmasında güç transformatörlerindeki mekanik arızaların tespiti için SFRA kullanmıştır. Güç transformatörleri, elektrik şebekesinde kritik öneme sahip cihazlar olup, mekanik bozulmaların erken tespiti enerji sürekliliği ve verimliliği açısından hayati öneme sahiptir. SFRA, transformatör sargılarındaki yer değişimleri ve çekirdek bozulmaları gibi arızaların tespitinde etkili bir yöntemdir. Bu yöntem, düşük frekansta

indüktans, yüksek frekansta kapasitans davranışlarını analiz ederek, transformatör içindeki arızaların izlenmesine olanak tanır. Çalışmada, SFRA özellikle sarım kısa devresi, üç faz toprak arızası, nüve mıknatıslanma arızası gibi çeşitli arızaların tespitindeki etkinliği gösterilmiştir. Her bir arıza durumu için alınan frekans cevapları analiz edilerek, transformatörlerin fabrika çıkışı veya referans değerleri ile karşılaştırılmış ve arızaların tanımlanması sağlanmıştır. SFRA diğer arıza tespit yöntemlerine göre avantajları, önceki referans ölçümlerine daha az bağımlı olması ve mekanik arızaların daha geniş bir yelpazede yüksek duyarlılıkla tespit edilebilmesidir. Pamuk, transformatörlerin planlı bakım süreçlerinde SFRA kullanımının, arızaların erken tespitine ve onarım süreçlerinin hızlandırılmasına olanak sağladığını ifade etmektedir (Pamuk,2014).

Demirci ve arkadaşlarının yaptıkları çalışmada, elektrik şebekelerinin kritik ekipmanlarından olan güç transformatörlerinin arıza teşhisinde veri ön işleme yöntemlerinin sınıflandırıcı algoritmaların performansına etkisini incelemektedir (Demirci ve ark,2018). Transformatörlerdeki olası arızaların erken tespiti, elektrik kesintilerine ve büyük enerji kayıplarına yol açabileceğinden büyük önem taşımaktadır. Bu çalışmada, Çözünmüş Gaz Analizi (DGA) yöntemi kullanılarak elde edilen gaz verileri, çeşitli sınıflandırıcı algoritmalara giriş verisi olarak kullanılmış ve arıza teşhis performansları değerlendirilmiştir. Farklı veri ön işleme yöntemleri uygulanarak, bu işlemlerin sınıflandırıcı algoritmaların performansına etkisi karşılaştırılmıştır. Çalışmada kullanılan veri ön işleme yöntemleri; gaz yüzdeleri dönüşümü, logaritmik dönüşüm, normalizasyon, standardizasyon ve logaritmik dönüşüm + standardizasyon işlemleridir. Bu yöntemlerin her biri, gaz verilerinin belirli bir formata dönüştürülerek sınıflandırma algoritmaları için daha uygun hale getirilmesini amaçlamaktadır. Kullanılan sınıflandırma algoritmaları ise Destek Vektör Makinesi (SVM), K En Yakın Komşu (KNN), Karar Ağacı (DT) ve Çok Katmanlı Yapay Sinir Ağı (MLPNN) yöntemleridir. Deneylerde, IEC TC10 veri seti kullanılarak farklı veri ön işleme yöntemlerinin sınıflandırma performansları karşılaştırılmıştır. Ham veri seti ile yapılan arıza teşhis işleminde en yüksek doğruluk %77,21 ile KNN algoritmasından elde edilmiştir. Gaz yüzdeleri dönüşümü uygulanan veriler ile yapılan arıza teşhis işleminde ise en yüksek teşhis doğruluğu %85,04 ile MLPNN algoritmasında elde edilmiştir. Logaritmik dönüşüm ve logaritmik dönüşüm + standardizasyon işlemlerinde de sınıflandırıcı algoritmaların doğrulukları artmıştır.

Sonuçlar, veri ön işleme yöntemlerinin arıza teşhis performansını önemli ölçüde artırabileceğini göstermektedir. Bu bulgular, güç transformatörleri arıza teşhisinde daha doğru ve güvenilir sonuçlar elde edilmesine katkı sağlayabilir. Bu çalışmada, transformatör arıza teşhisinde veri ön işleme yöntemlerinin etkisi kapsamlı bir şekilde incelenmiş ve farklı yöntemlerin sınıflandırıcı algoritmalar üzerindeki etkisi değerlendirilmiştir. Sonuçlar, veri ön işleme yöntemlerinin arıza teşhis performansını önemli ölçüde artırabileceğini göstermektedir. Bu bulgular, güç transformatörleri arıza teşhisinde daha doğru ve güvenilir sonuçlar elde edilmesine katkı sağlayabilir (Demirci ve ark,2018).

Ryder, çalışmasında SFRA'nın transformatörlerdeki çeşitli hataları tespit etme ve ayırt etme kapasitesini değerlendirmektedir (Ryder ve ark,2002). 100 kVA'lık bir dağıtım transformatörü üzerinde gerçekleştirilen kapsamlı simülasyonlar, SFRA'nın çoğu hatayı başarıyla tespit edebildiğini, ancak çekirdek topraklamasının olmaması ve tank içindeki yabancı cisimlerin tespit edilemediğini ortaya koymaktadır. SFRA, belirli hataları tespit etmede etkili olsa da bazı hataları ayırt etmede yetersiz kalabilmektedir. SFRA, geniş bir frekans aralığında transformatör sargılarının empedansını ölçerek ve sonuçları referans verilerle karşılaştırarak hasarı belirleyen güçlü bir teşhis yöntemidir. Çalışmanın başında, SFRA'nın hangi hataları tespit edebileceğini ve her hata türünün SFRA sonuçlarında nasıl bir değişiklik oluşturduğunu belirlemek amaçlanmıştır. Simülasyonlarda kullanılan transformatör, Alstom tarafından üretilen, 100 kVA'lık, üç fazlı, delta-topraklı yıldız bağlantılı bir dağıtım transformatörüdür. SFRA ölçümleri için standart 50Ω test empedansı kullanılmış ve sonuçlar, frekansın logaritmik ölçekli bir grafikte kazanç (amplitüd) olarak sunulmuştur. Çalışma, farklı hata senaryolarında SFRA'nın tepkisini incelemiştir. Kötü tank topraklaması, çekirdek topraklamasının olmaması, çoklu çekirdek topraklaması, tank içindeki yabancı cisim, tank içindeki kapalı döngüler, kötü temaslar, ek sargılar, kısa devreli sargılar ve gevşek sargılar gibi çeşitli hatalar simüle edilmiştir. Sonuçlar, SFRA'nın bu hatalardan çoğunu tespit edebildiğini, ancak çekirdek topraklamasının olmaması ve tank içindeki yabancı cisimlerin tespit edilemediğini göstermiştir. Çoklu çekirdek topraklaması ve tank içindeki kapalı döngüler ise ayırt edilememiştir. Hataların SFRA ile tespit edilebilirliği, hatanın türüne ve büyüklüğüne bağlı olarak değişiklik göstermiştir. Örneğin, gevşek sargılar ve manyetizasyon değişiklikleri SFRA verilerinde ayırt edilebilir değişiklikler oluştururken, büyük ölçekli topraklama hataları ve dolaşan

akımlar SFRA sonuçlarında belirgin değişikliklere neden olmuştur. Sonuç olarak, SFRA, transformatörlerde geniş bir hata yelpazesini tespit edebilen etkili bir yöntemdir. Ancak, tüm hata türlerini tespit edemez ve bazı hataları ayırt etmekte yetersiz kalabilir. SFRA'nın diğer teşhis yöntemleriyle birlikte kullanılması, transformatörlerin durumu hakkında daha kapsamlı bir değerlendirme yapılmasını sağlar. Bu çalışma, SFRA'nın transformatör teşhisindeki potansiyelini ve sınırlamalarını ortaya koyarak, daha güvenilir ve kapsamlı bir teşhis stratejisi geliştirilmesine katkıda bulunmaktadır (Ryder ve ark,2002).

Antón ve arkadaşları yapmış oldukları çalışmada, senkron jeneratörlerdeki sarım kısa devre hatalarının tespiti için SFRA ile makine öğrenimi tekniklerini birleştirmişlerdir (Antón ve ark, 2021). Elektrik sistemlerinde büyük bir role sahip olan senkron jeneratörlerde oluşabilecek sarım kısa devre hatalarının önceden tespiti, jeneratörlerin güvenli çalışması ve bakım sürecinin hızlandırılması açısından kritik öneme sahiptir. SFRA kullanılarak bu hatalar, makine durdurulduğunda yapılan testlerle tespit edilebilir. SFRA yöntemine ek olarak makine öğrenimi algoritmaları kullanılarak hatanın şiddeti ve konumu tahmin edilmiştir. Bu çalışmada, 40 MVA senkron jeneratör rotoru üzerinde yapılan 252 SFRA testi ile hataların tespiti gerçekleştirilmiş ve elde edilen sonuçlar analiz edilmiştir. Çalışmanın bulgularına göre, makine öğrenimi ile desteklenen SFRA yöntemi, klasik yöntemlere göre daha yüksek doğrulukta arıza tespiti sağlamıştır. Özellikle ardışık makine öğrenimi süreci, hata şiddeti ve konumunun doğru tahmin edilmesinde başarılı sonuçlar vermiştir (Antón ve ark, 2021). Antón ve arkadaşları çalışmasında, yalnızca senkron jeneratörlerdeki sarım kısa devre hatalarına odaklanmışlardır. Ayrıca çalışma, 252 SFRA testiyle sınırlıdır. Büyük veri setlerinin ve farklı test senaryolarının kullanımı, makine öğrenmesinin doğruluğunu artırabilir.

Literatür incelemelerinin ardından bu çalışmada, bir güç trafosunun arızalı mı yoksa sağlam mı olduğunu belirlemeye yönelik bir yapay zekâ uygulaması geliştirilmiştir. Literatürdeki mevcut yöntemler ve yaklaşımlar incelendikten sonra, bu çalışmanın temel amacı olan trafo arızalarının tespiti ve arıza yerinin belirlenmesi konusuna odaklanılmıştır. Eğer trafo arızalı ise, arızanın çekirdekte mi yoksa rotorda mı olduğunu tespit edebilen bir sistem tasarlanmıştır. Bu amaçla, SFRA uygulamasından alınan veriler kullanılarak bir dataset oluşturulmuştur. Bode diyagramı grafiklerinden elde edilen veriler ile oluşturulan bu dataset, yapay zekâ modelinin eğitimi ve test

edilmesi için kullanılmıştır. Çalışma kapsamında, trafo arızalarının tespitinde ve yerinin belirlenmesinde yapay zekanın etkinliğini değerlendiren detaylı analizler gerçekleştirilmiştir. Bu sayede, güç trafolarının bakım ve onarım süreçlerinin daha verimli hale getirilmesi hedeflenmiştir.





2. TRANSFORMATÖRLERİN YAPISI, ÇALIŞMA PRENSİBİ VE TEST YÖNTEMLERİ

2.1. Transformator


Transformator, elektrik enerjisini bir gerilim seviyesinden başka bir gerilim seviyesine dönüştürmek için kullanılan elektromekanik bir cihazdır. IEC 60076 standardına göre, transformator, elektrik enerjisinin taşınması amacıyla bir alternatif gerilim ve akım sistemini, genellikle farklı bir değerde ve aynı frekansta başka bir gerilim ve akım sistemine elektromanyetik indüksiyon yoluyla dönüştüren, iki veya daha fazla sargıya sahip statik bir cihaz olarak tanımlanır (IEC 60076-11,2004). Bu standarda göre, tüm transformatorler, çeşitlerine bakılmaksızın güç transformatorü olarak kabul edilir (ABB,2004). Transformatorler, kullanım ihtiyaçlarına göre çeşitli türlere ayrılmakla birlikte, hepsinin çalışma prensibi aynıdır. Üretici firmalar, üretim süreçlerindeki farklılıklar ve kullanım alanlarına göre transformatorleri güçlerine, tiplerine ve kullanıldıkları yerlere göre sınıflandırmaktadırlar.

Temel olarak alternatif akım (AC) sistemlerinde çalışan transformatorler, elektromanyetik indüksiyon prensibine dayanır ve elektrik enerjisinin verimli ve güvenli bir şekilde iletilmesini ve dağıtılmasını sağlamaktadır. Bu cihazlar, enerjiyi manyetik bir alan üzerinden aktararak gerilim seviyesini değiştirir.

Tek fazlı bir transformatorün analizi, eşdeğer devre kullanılarak detaylı bir şekilde yapılabilir. Bu eşdeğer devre, transformatorün temel özelliklerini ve çalışma prensiplerini daha iyi anlamak ve analiz etmek amacıyla türetilmiştir. Eşdeğer devrenin oluşturulmasında dikkate alınan bazı unsurlar vardır. Öncelikle, transformatorün birincil ve ikincil sargılarının belirli bir dirence sahip olduğu kabul edilir. Bu dirençler, devrede toplu parametreler olarak ele alınır ve sargılarda meydana gelen kayıpları temsil eder. Ayrıca, transformator içinde meydana gelen kaçak akılar, eşdeğer devrede kaçak reaktans olarak modellenir. Bu yaklaşım, kaçak akıların etkisini hesaba katarak daha doğru bir analiz yapılmasını sağlamaktadır.


Transformatorün çekirdek kayıpları da bu devre modellemesinde önemli bir yer tutar. Çekirdek kayıpları, demir kayıpları olarak da bilinen histerezis ve eddy akım

kayıplarını içermektedir. Bu kayıplar, eşdeğer devrede bir şönt direnci ile temsil edilir. Son olarak, transformatör çekirdeğinin manyetizasyonu, bir manyetize edici reaktans aracılığıyla modele dahil edilir. Bu reaktans, çekirdeğin manyetik özelliklerini ve bu özelliklerin devre üzerindeki etkilerini yansıtır.



Şekil 2.1. İdeal Transformatör Eşdeğer Şeması (IEC 60076-11,2004)

Transformatöre ait eşdeğer şeması Şekil 2.1’de verilmektedir. Eşdeğer devre modellemesi, transformatörün farklı çalışma koşulları altında incelenmesini sağlamaktadır. Örneğin, transformatörün yüksüz ve yüklü çalışma modları, bu modelleme yardımıyla analiz edilebilir. Yüksüz çalışma durumunda, ikincil sargı açık bırakılır ve bu nedenle ikincil devrede akım akışı olmaz. Bu durumda, transformatör yalnızca çekirdek kayıplarını ve az miktarda birincil sargı kayıplarını telafi etmek için küçük bir akım çeker.



Şekil 2.2. Yüklü Transformatörün (a) Fiziksel Modeli ve (b) Eşdeğer Devre Diyagramı (Abdulkareem ve ark, 2014)

Şekil 2.2’de verilen devrelerin elemanları Tablo 2.1’de verilmiştir.

Tablo 2.1. Eşdeğer devre büyüklükleri.

SEMBOL	TANIM
R1, R2	Birincil ve ikincil dirençler
X1, X2	Birincil ve ikincil sızıntı reaktansları
R0	Uyarma Direnci
X0	Uyarma Reaktansı
I1	Birincil Taraf Akımı
I0	Yüksüz/Uyarma Akımı Bileşeni
IW (veya IC1)	Yüksüz Akımın Çekirdek Kaybı Bileşeni
I_μ (veya IM1)	Yüksüz Akımın Manyetize Edici Bileşeni
I'2	Birincil Akımın Yük Bileşeni
I2	İkincil Taraf Akımı (Yük Akımı)
V1	Birincil Taraf Terminal Voltajı
V2	İkincil Taraf Terminal Voltajı
E1	Birincil Taraf İndüklenen EMF
E2	İkincil Taraf İndüklenen EMF

Transformatörler, iki ana bileşenden oluşur: manyetik çekirdek ve sargılar. Manyetik çekirdek genellikle ferromanyetik bir malzemeden yapılmış olup manyetik akının yoğunlaşmasını ve yönlendirilmesini sağlar. Sargılar ise bakır veya alüminyum tellerden yapılmış olup elektrik akımının indüklenmesini sağlamaktadır. Primer sargı, transformatörün girişine bağlanır ve alternatif akım uygulandığında manyetik bir akı oluşturur. Bu manyetik akı, çekirdek üzerinden sekonder sargıya iletilir ve sekonder sargıda elektrik akımı indüklenir, böylece çıkış gerilimi elde edilir.

Transformatörlerin çalışma prensibi, Faraday'ın elektromanyetik indüksiyon yasasına dayanmaktadır. Bu yasa, bir devredeki manyetik akının değişiminin, bu devrede bir elektromotor kuvvet (EMK) indükleyeceğini belirtir. Transformatörlerde, primer sargıda oluşan manyetik akı, sekonder sargıda EMK indüklenmesine neden olur. Bu indüksiyon sonucu elde edilen çıkış gerilimi, sargıların sarım sayıları arasındaki orana bağlıdır. Primer sargıdaki sarım sayısı $N1$ ve sekonder sargıdaki sarım sayısı $N2$ olmak üzere, transformatörün giriş ve çıkış gerilimleri $V1$ ve $V2$ arasındaki ilişki (denklem 2.1)'de verilmektedir.

$$\frac{V1}{V2} = \frac{N2}{N1} \quad (2.1)$$

2.2. Faraday Yasası ve Lenz Kanunu

Transformatörlerin temel çalışma prensibi, Faraday Yasası ve Lenz Kanunu ile açıklanmaktadır. Faraday Yasası, bir iletken döngüsünden geçen manyetik akının zamanla değişmesi durumunda bu döngüde bir elektromotor kuvvet (EMK) indükleneceğini belirtir. Michael Faraday, 1831 yılında bu yasaı keşfederek elektromanyetik indüksiyonun temelini atmıştır.

$$\varepsilon = -N d\phi/dt \quad (2.2)$$

Denklem 2.2’de verilen, ε indüklenen EMK’yı, N sargı sayısını ve $d\phi/dt$ manyetik akının zamanla değişimini temsil etmektedir. Faraday’ın bu keşfi, transformatörlerin temel çalışma prensibini oluşturur ve elektrik enerjisinin farklı gerilim seviyelerine dönüştürülmesini mümkün kılar. Faraday Yasası, bir manyetik alanın değişimi ile bir iletkende nasıl gerilim indükleneceğini açıklayarak transformatörlerin çalışma mekanizmasını anlamamıza olanak tanımaktadır (Coltman, 1998).

Lenz Kanunu ise indüklenen akımın, kendisini oluşturan manyetik akı değişikliğine karşı koyacak yönde olacağını belirtmektedir. 1834 yılında Heinrich Lenz tarafından formüle edilen bu yasa, enerjinin korunumu ilkesine dayanır ve transformatörlerde enerji dönüşümünün verimli bir şekilde gerçekleşmesini sağlamaktadır.


$$\varepsilon = -L dI/dt \quad (2.3)$$

Denklem 2.3’te verilen, ε indüklenen EMK’yı, L endüktansı ve dI/dt akımın zamana göre değişimini temsil etmektedir. Lenz Kanunu, indüklenen akımın yönünü belirler ve transformatörlerde manyetik akının korunmasını sağlar. Bu yasa, elektromanyetik indüksiyon sürecinde enerjinin korunmasını ve sistemdeki dengeyi sağlamaktadır (Coltman, 1998) (H.-C. Sun ve ark,2012), 2012).

Faraday Yasası ve Lenz Kanunu, transformatörlerin işleyişini anlamada kritik öneme sahiptir. Faraday Yasası, bir iletkende manyetik akının değişimi sonucu nasıl gerilim indükleneceğini açıklarken, Lenz Kanunu, bu indüklenen akımın yönünü ve enerjinin korunumu prensibini ortaya koymaktadır. Bu iki temel yasa, transformatörlerin tasarımı ve çalışması için vazgeçilmezdir ve modern elektrik sistemlerinin verimli ve güvenli bir şekilde işlemesini sağlar.

2.3. Transformatörlerin Yapısı ve Çeşitleri

Transformatörler, elektrik enerjisinin verimli bir şekilde iletilmesi ve dönüştürülmesi için kullanılan temel cihazlardır. Yapısal olarak, transformatörler iki ana tipe ayrılır: Core tipi ve Shell tipi. Bu tipler arasındaki farklar, üretim sürecindeki farklılıklar, ekonomik faktörler ve yer ihtiyaçlarına göre değişiklik gösterir. Core tip ve Shell tip nüve çeşitlerinin şematik gösterimleri Şekil 2.3'te verilmiştir.



Şekil 2.3. Core Tip Nüve ve (b) Shell Tip Nüve (ABB,2004)

Core tip transformatörlerde, sargılar manyetik çekirdeğin etrafına sarılır. Manyetik akı, çekirdek boyunca bir döngü yaparak akarken, elektrik akımı sargılarda indüklenir. Core tip transformatörler, daha düşük maliyetli üretim süreçleri ve daha kompakt bir tasarım sunar, bu nedenle genellikle daha küçük boyutlu ve ekonomik çözümler gerektiren uygulamalarda tercih edilir. Bu tip transformatörlerde manyetik akı, çekirdek boyunca yatay ve dikey olarak hareket etmektedir.

Shell tip transformatörlerde ise manyetik çekirdek, sargıların etrafını çevreler. Manyetik akı, çekirdek boyunca daha uzun bir yol kat eder ve bu da enerji kayıplarını azaltır. Shell tip transformatörler, genellikle daha büyük boyutlu ve yüksek verimlilik gerektiren uygulamalarda tercih edilir. Bu tipte, manyetik çekirdek, sargıların her iki tarafında da bulunur ve manyetik akı, çekirdek boyunca döngü yapmaktadır.


Transformatörlerin kullanım yerlerine göre sınıflandırıldığında üretim ve dağıtım transformatörleri, güç transformatörleri ve özel transformatörler olmak üzere üç ana kategoriye ayrılmaktadırlar.

2.3.1. Güç transformatörleri

Güç transformatörleri, elektrik enerjisinin iletim ve dağıtımında kritik bir rol oynayan temel cihazlardır. Bu transformatörler, 3 fazlı trafolar olup özellikle enerji santrallerinde üretilen elektrik enerjisinin yüksek voltaj seviyelerine çıkarılarak iletim

hatları üzerinden uzun mesafelere taşınmasını sağlamaktadır. Yüksek voltaj seviyelerinde enerji iletimi, iletim hatlarındaki direnç kayıplarını minimuma indirir, bu da enerji verimliliğinin artmasını sağlar. Güç transformatörleri, genellikle büyük fiziksel boyutları, yüksek güç kapasiteleri ve uzun ömürleri ile bilinirler ve enerji altyapılarında önemli bir yer tutarlar.

Güç transformatörlerinin (Şekil 2.4) iç yapısında çekirdek, sargılar, yağ ve kâğıt gibi temel bileşenler bulunmaktadır. Bu bileşenlerin sağlıklı ve verimli bir şekilde çalışabilmesi için bazı yardımcı elemanlara ihtiyaç duyulmaktadır. Öncelikle, bu bileşenleri barındıran ana tank ve sargıların dışarıya izoleli bir şekilde çıkarılmasını sağlayan buşingler önemli bir rol oynar. Transformatörün aşırı gerilimlerden korunması amacıyla ark boynuzları kullanılır. Ayrıca, transformatör yağı hem soğutma hem de yalıtım işlevi gördüğünden, yağın devir daim yapması ve soğutulması için havalandırma ve fan sistemlerine, aynı zamanda yağın ısındıkça genişmesi için bir rezerv tankına ihtiyaç duyulur. Sargı gerilimini ayarlamak için farklı gerilim seviyelerine sahip yük altında kademe değiştirici tertibatı kullanılır ve transformatörün gerektiğinde taşınabilmesi için ray ve tekerlek sistemleri de yer alır. Tüm bu mekanik elemanlar, transformatörün düzgün bir şekilde çalışmasını sağlarken, transformatörün elektriksel yönden korunması için de çeşitli koruma elemanlarına ihtiyaç vardır.



Şekil 2.4. Güç Transformatörünün Genel Yapısı (Velasco Costa ve ark, 2022)

Güç transformatörlerinin yapısı, verimli ve güvenilir bir şekilde çalışabilmeleri için özenle tasarlanmıştır. Bu transformatörler, üç fazlı elektrik sistemleri için tasarlanmış

olup, her faz için ayrı bir manyetik çekirdeğe sahiptir. Manyetik çekirdek, transformatörün içinden geçen manyetik akıyı yoğunlaştırarak, elektrik enerjisinin sargılar arasında etkin bir şekilde aktarılmasını sağlar. Manyetik çekirdekler, genellikle silisli çelikten imal edilmiştir. Bu malzeme, manyetik akı kayıplarını azaltarak transformatörün enerji verimliliğini artırır. Transformatör sargıları ise genellikle bakır veya alüminyumdan yapılır. Bakır sargılar, yüksek iletkenlikleri sayesinde enerji kayıplarını minimumda tutarken, alüminyum sargılar daha hafif olup maliyet açısından avantaj sunmaktadır (N'cho ve ark,2020).

Güç transformatörlerinin çalışma prensibi, elektromanyetik indüksiyon ilkesine dayanır. Primer sargı, enerji santralinden gelen yüksek akımı alır ve manyetik çekirdek üzerinde bir manyetik akı oluşturur. Bu manyetik akı, çekirdek üzerinden sekonder sargıya iletilir. Sekonder sargıda indüklenen elektromotor kuvvet (EMK), enerji çıkışının daha yüksek bir voltajda olmasını sağlar. Bu şekilde, transformatör, enerjiyi yüksek voltaj seviyelerinde iletim hatlarına aktararak, uzun mesafelere taşınmasını mümkün kılar. Güç transformatörlerinin verimli çalışması için soğutma sistemleri büyük önem taşır. Yağ soğutmalı sistemler, bu transformatörlerde yaygın olarak kullanılır.

2.4. Transformatör Testleri

Güç transformatörleri genellikle 20-35 yıl hizmet verecek şekilde tasarlanmış olsalar da düzenli bakım ve onarımlar sayesinde bu süre 60 yıla kadar uzatılabilir (Wang ve ark,2002). Bir arıza meydana geldiğinde, arızayı sistemden izole etmek ve onarım sürecini başlatmak için programlı bir kesinti süresi gerekebilir. Arızanın niteliğine bağlı olarak teşhis ve onarım süreleri birkaç saatten birkaç güne kadar değişiklik gösterebilir (Dietrich,1983). Bu kesinti sürelerinde oluşacak elektrik maliyetleri, işçilik, servis ve bakım giderleri göz önüne alındığında, testler yoluyla arızaların önceden tespit edilmesinin ne kadar önemli olduğu daha iyi anlaşılmaktadır.

Güç transformatörleri, üretim süreçlerinin tamamlanmasının ardından fabrikada gerçekleştirilen testlerden geçtikten sonra, ihtiyaç duyulan bölgelere kara, hava veya deniz yolu ile nakledilir. Nakliye sırasında transformatörün güvenli bir şekilde varış noktasına ulaşması için gerekli tüm önlemler alınır. Transformatör, kurulum noktasına ulaştığında çalışır duruma getirilir ve ilk saha testlerine tabi tutulur. Şekil 2.5 ve Şekil

2.6’da saha montajı öncesi ve sahada montaj sırasında transformatöre ait şekiller sunulmaktadır.



Şekil 2.5. Saha Montajı Öncesi Transformatör Tankı



Şekil 2.6. Sahada Montaj Sırasında 400/230/34 kV Güç Transformatörü


Transformatörlerin kabul işlemlerinden önce, bir dizi kapsamlı test gerçekleştirilir. Bu testler, yalıtım malzemelerinin durumunun incelenmesi, sargı bağlantılarının uygunluğu, nüvenin pozisyonunun korunup korunmadığı, sargılar ile toprak arasındaki izolasyon mesafesinin değişip değişmediği, sargılarda olası kopuklukların tespit edilmesi, sargı sipirlerinde kısa devre olasılıklarının değerlendirilmesi ve kademe değiştiricisinin durumu gibi hususları içerir. Ayrıca transformatörün izolasyon yağı da detaylı bir şekilde incelenir. Bu testler, rutin olarak gerçekleştirilen saha testleri kapsamında yer alır.

Saha testlerinin amacı, güç transformatörlerinde oluşabilecek arızaların önceden tespit edilmesini ve bu sayede önleyici tedbirlerin alınmasını sağlamaktır. Bu yaklaşım, enerji kesintilerinin önlenmesine ve elektrik şebekesinin güvenilirliğinin artırılmasına yardımcı olur. Saha testleri, aşağıda ayrıntılı olarak açıklanmıştır.

2.4.1. İkaz akım testi


Uyarıcı akım, bir transformatörün manyetik çekirdeğinden geçen manyetik akıyı oluşturmak için gerekli olan akımdır. Transformatörün manyetik çekirdeğinde bir kusur oluştuğunda veya sarımlar arasında kısa devre meydana geldiğinde, uyarıcı akımın büyüklüğü normalden sapar ve bu sapma, bir arızanın varlığına işaret eder. Bu nedenle, uyarıcı akım testleri, transformatörlerin saha testlerinde uygulanarak arızaların belirlenmesinde yaygın olarak kullanılmaktadır.

Bu test, sargı kopukluğu, sargılar arası kısa devre ve manyetik nüveye ilişkin problemleri tanımlamak amacıyla gerçekleştirilen bir ön kontroldür. Ölçümler, her bir faz için ayrı ayrı yapılır ve tüm sargıları kapsayan kademe veya tüm kademelerde gerçekleştirilir. Test sonuçları, önceki ölçüm değerleriyle uyumlu olmalıdır. Eğer farklılıklar tespit edilirse, nüve demanyetize edilmeli ve hala bir farklılık söz konusuysa daha ayrıntılı araştırma testlerine başvurulmalıdır. İkaz akımı testi, transformatör sargılarında meydana gelen deformasyonlar, sargılar arası kısa devreler, sargı kopuklukları ve nüve arızalarının tespitini mümkün kılmaktadır (Brusetti,2016). İkaz akımı ölçümü için temel bağlantı şeması Şekil 2.7'de sunulmuştur.



Şekil 2.7. İkaz Akımı Testi Ölçüm Şeması (Brusetti,2016)

Manyetik devrenin eşdeğer şeması çıkarıldığında, nüve bacakları ve sargılar ohm cinsinden aşağıdaki gibi temsil edilebilir. Şekil 2.8'de nüve için ikaz akımı eşdeğer devresi gösterilmiştir.



Şekil 2.8. Nüve İçin İkaz Akımı Eşdeğer Devresi (Brusetti,2016) (Yıldız,2018)

Bu durumda, sağ ve sol bacaklarda bulunan A ve C fazlarından geçen akımın değeri, eşitlik (2.4)'te hesaplanmıştır (Yıldız,2018).

$$R_{A-C} = (1 + 3 + 1) + \left[\frac{3 \cdot (1 + 3 + 1)}{3 + (1 + 3 + 1)} \right] = 6,875 \quad (2.4)$$

Orta bacakta bulunan B faz sargısından geçen akımın değeri, sağ ve sol bacaklarda bulunan dirençlerin toplamına paralel olur ve bu değer, eşitlik (2.5) yardımıyla hesaplanabilir.

$$R_B = 3 + \left[\frac{(1 + 3 + 1) \cdot (1 + 3 + 1)}{(1 + 3 + 1) + (1 + 3 + 1)} \right] = 5,5 \quad (2.5)$$

$$R_{A-C} \cdot \%80 = R_B \quad (2.6)$$

Bu durum, eşitlik (2.6)'da belirtildiği gibi, B fazından geçen akımın, A ve C fazlarından geçen akımın %80'ine tekabül ettiğini göstermektedir. Ancak, saha koşulları, ölçüm cihazlarının durumu ve personel kaynaklı hatalar ölçüm sonuçlarını etkileyebilir. A ve C fazlarından okunan ve değeri 50 mA'den küçük olan ikaz akımı ölçümlerinde, fazlar arasındaki tolerans %10'u; 50 mA'den büyük olan ölçümlerde ise %5'i geçmemelidir.

2.4.2. AC izolasyon testleri

AC İzolasyon Testleri, transformatörü oluşturan yalıtım malzemelerinin izolasyon durumunu değerlendirmek amacıyla gerçekleştirilen testlerdir. Pratikte, hiçbir malzeme tam izolasyon sağlayamaz. Üretim, işçilik, malzeme kalitesi gibi çeşitli faktörler nedeniyle her malzemede belirli bir izolasyon kaybı meydana gelir. İzolasyonun tarihi, 1836 yılında Michael Faraday'ın kapasitörü keşfetmesiyle başlamıştır. Faraday, kondansatör plakaları arasına farklı malzemeler yerleştirildiğinde kapasitenin değiştiğini gözlemlemiştir. İdeal bir kapasitörde, akım ile gerilim arasındaki faz açısı doksan derece olup, bu durumda izolasyon kaybı yoktur (%PF=0). Pratikte bu ideal durum hiçbir zaman tam olarak sağlanamaz. Kondansatörde kullanılan malzemelerin her birinin belirli bir dielektrik sabiti vardır. Tablo 2.2.'de izolasyon malzemeleri, Tablo 2.3'te ise bazı malzemelerin dielektrik sabitleri listelenmiştir.


Tablo 2.2. İzolasyon malzemeleri (Short,2016).

Katı	Sıvı	Gaz
Porselen	Mineral Yağ	Yüksek Vakum
Polimer	Silikon Yağ	Hava
Selüloz	Distile Edilmiş Su	Kükürt Hekzaflorür (SF6)

Tablo 2.3. İzolasyon malzemelerinin dielektrik sabitleri.


Malzeme	Dielektrik Sabiti
Vakum	1.0
Hava	1.000549
Mika	5.4
Kuru Kâğıt	2
Porselen	7
Yağ	2.2
Silikon Akışkan	2.75
Su (20°C)	80

Transformatörü gerçek çalışma koşullarına daha uygun bir şekilde modelleyebilmek için eşdeğer bir devre oluşturulmaktadır. Şekil 2.9’da transformatöre ait genişletilmiş eşdeğer devre şeması gösterilmiştir (Short,2016).



Şekil 2.9. Transformatörün Genişletilmiş Eşdeğer Devre Şeması (Short,2016)

Elektriksel izolasyonu modellemek amacıyla, bu sistemde kapasitör kullanımı yeterli olacaktır. Normal şartlar altında, kapasite, Şekil 2.10’da gösterilen elektriksel izolasyon modelinden yararlanılarak, eşitlik (2.7) ile hesaplanır.



Şekil 2.10. Elektriksel İzolasyon Modeli (Short,2016)


$$C = \frac{A \cdot \epsilon}{d} \quad (2.7)$$

Plakaların yüklenebilmesi için, iki plaka arasında bir potansiyel fark bulunmalı ve plakalar bağlı iletkenlik içerisinde olmalıdır. Gerilim ve yük arasındaki ilişki, (2.8) eşitliği ile hesaplanır. Akım ile kapasite arasındaki ilişki ise (2.9) eşitliğinden faydalanılarak belirlenir.


$$Q = E \cdot C \quad (2.8)$$

$$I_c = V \cdot \omega \cdot C \quad (2.9)$$

Pratikte dielektrik kayıplar meydana geldiği için, bu kayıplar modellemeye bir direnç ile temsil edilir ve bu durum, akım ile gerilim arasındaki açının doksan dereceden küçük olmasına yol açar. Bu kayıplara "kayıp açısı" denir ve $\tan \delta$ ile gösterilir. Şekil 2.11'de izolasyon kayıp açısının vektörel gösterimi Şekil 2.12'de de izolasyon toplam akımının vektörel gösterimi sunulmuştur.




Şekil 2.11. İzolasyon Kayıp Açısı Vektörel Gösterimi (Yıldız,2018)



Şekil 2.12. İzolasyon Toplam Akımı Vektörel Gösterimi (Yıldız,2018)

Güç faktörü (%PF), IEEE standartlarına göre “Bir dielektrik sisteme uygulanan sinüzoidal gerilim ile dielektrik sistemden geçen akım arasındaki açının kosinüsüdür” şeklinde tanımlanmaktadır. Güç faktörü, bir oran olarak ifade edildiği için, gerilim ve test objesinin büyüklüğünden bağımsızdır. AC İzolasyon Testi, transformatör üzerinde gerçekleştirilen izolasyon testleri, sargılar arasındaki ve sargılar ile tank (toprak) arasındaki izolasyonu değerlendirmek amacıyla yapılır. Transformatörün izolasyon geçmişi, bir veri tabanına kaydedilerek sürekli izleme altında tutulur. İki sargılı bir transformatörün izolasyon durumu, prensip şemasıyla Şekil 2.13'te gösterilmiştir.



Şekil 2.13. İki Sargılı Transformatörün İzolasyon Durumu (Yıldız,2018)

Burada;

- CH: Primer sargı ile tank/toprak arasındaki kapasite,
- CL: Sekonder sargı ile tank/toprak arasındaki kapasite,
- CHL: Primer sargı ile sekonder sargı arasındaki kapasite olarak ifade edilmektedir.


2.4.3. DC izolasyon testleri

DC izolasyon testleri kapsamında, izolasyon direnci IEEE standardında “Kullanılan malzemeler ve uygulama teknikleri bakımından izolasyonun tipinin ve durumunun bir fonksiyonudur” şeklinde tanımlanmıştır. İzolasyon direnci, genellikle izolasyonun yüzey alanının iletkenliği ile doğru orantılı olarak değişmektedir. Ohm Kanunu'na göre direnç, eşitlik (2.10)'da ifade edildiği gibi tanımlandığından, direnç değerinin hesaplanması eşitlik (2.11)'de belirtilen şekilde olacaktır.

$$U = \frac{I}{R} \quad (2.10)$$


$$R = \frac{U_{DC}}{I_T} \quad (2.11)$$

İzolasyon direnci, dielektrik malzemeye uygulanan gerilimin toplam akıma bölünmesiyle elde edilir. Toplam akım, kaçak akımlar IL , polarizasyon akımı IA , iletkenlik akımı IG ve şarj akımları IC gibi akımların toplamından oluşur. Şekil 2.14'te DC izolasyon prensiplerine dayalı elektrik devre şeması gösterilmiştir.



Şekil 2.14. DC İzolasyon Elektrik Devre Şeması (IEEE Std 43-2006)

Polarizasyon akımı, moleküler polarizasyon ve elektron sürtünmelerinden kaynaklanan, başlangıçta yüksek olup zamanla neredeyse sıfıra düşen ve izolasyon sisteminde kullanılan malzeme türüne göre değişen bir akımdır. İletkenlik akımı ise zamanla sabit kalan, izolasyon gövdesinin topraklanmış yüzeyinden yüksek gerilim iletkenine geçen akımlardır. Kapasite akımı, üssel olarak azalan bir akım olup, ölçüm cihazının iç direnci ve sargının geometrik yapısına bağlıdır. Kaçak akımlar ise zamanla sabit kalan ve genellikle sargı uçlarında izolasyon malzemesinin yüzeyinden geçen akımlardır. Kaçak akımların genliği, sıcaklık, nem ve izolasyon malzemesinin türüne göre değişiklik gösterir. Şekil 2.15'de, izolasyon direncini ölçmek için gerekli toplam akımın ve diğer akımların zamanla nasıl değiştiğini gösteren bir grafik sunulmuştur (IEEE Std 43-2006).



Şekil 2.15. DC İzolasyon Akımları Grafiği (IEEE Std 43-2006)

İzolasyon direnci, ilk gerilim uygulandığında hızla yükselir ve zamanla değeri logaritmik olarak azalır. Transformatörlerde kullanılan izolasyon malzemesinin

yapısına bağı olarak bu yükselme süreci bazen birkaç saat sürebilirken, bazı malzemelerde on ila on beş dakika arasında tamamlanır. Epoksi mika, polyester mika gibi bazı izolasyon malzemelerinde bu eğilim yaklaşık dört dakikada gerçekleşmektedir. Polarizasyon endeksi, onuncu dakika direnç değerinin birinci dakika direnç değerine bölünmesiyle elde edilir. Bu endeks, karakteristik direnç eğrisine dayanarak transformatörün izolasyon durumu hakkında karar vermeye yardımcı olur. Dielektrik absorpsiyon oranı ise polarizasyon (absorpsiyon) akımına göre yapılan bir değerlendirmeyi ifade eder. Bu değerlendirme, ilk otuzuncu saniye ve altmışıncı saniyelerdeki direnç değerlerine göre yapılır.

DAR (Dielektrik Absorpsiyon Oranı) ve PI (Polarizasyon Endeksi) değerleri, transformatörlerin izolasyon durumunu değerlendirmek için kullanılan önemli parametrelerdir. PI ve DAR değerlerine göre, standartlarda belirtilen değerlendirme kriterleri dikkate alınır ve elde edilen değerler, Tablo 2.4'te verilen değerlere göre karşılık bulur. Bu değerlendirmeler, çeşitli kaynaklarda farklılık gösterebilmesine rağmen, en çok kabul gören değerlendirme kriterleri Tablo 2.4'te sunulmuştur. Bu tablolardaki veriler, transformatörlerin izolasyon durumunu belirlemede referans olarak kullanılır (Myers ve ark,1981).

Tablo 2.4. DC izolasyon ölçüm değerlendirme tablosu (Myers ve ark,1981).

İzolasyon Durumu	Polarizasyon Endeksi (PI)
Tehlikeli	$PI < 1$
Zayıf	$1 < PI < 1.10$
Şüpheli	$1.10 < PI < 1.25$
Orta	$1.25 < PI < 2$
İyi	$PI > 2$


2.4.4. Sarım oranı testi

Sarım oranı testi, transformatör sargılarının sarım sayılarının projeye uygun olup olmadığını ve transformatör sargılarında iletken kopukluğu veya kısa devre arızası olup olmadığını kolayca tespit edebilir. Temel olarak bu test, primer (YG) sarım sayısının, sekonder (AG) sarım sayısına oranını belirler. Sarım oranı, köprü yöntemi veya dijital cihazlarla ölçülerek tespit edilir ve bu oran, eşitlik (2.12) yardımıyla hesaplanır. Bu test, transformatörün düzgün çalışmasını sağlamak ve herhangi bir iç arızayı erken tespit etmek için kritik öneme sahiptir.

$$\begin{aligned} \text{Teorik Çevirme Oranı} &= \frac{\text{Yüksek Gerilim Sargısı Gerilimi}}{\text{Alçak Gerilim Sargısı Gerilimi}} = \frac{N_1}{N_2} \\ &= \frac{I_2}{I_1} \end{aligned} \quad (2.12)$$

Ölçüm, tek fazlı olarak sargı çiftleri arasında yapılabilir. Ölçüm sırasında, aynı manyetik akının aktığı sargı çiftleri arasındaki çevirme oranı ölçülebilir. Başka bir deyişle, vektör diyagramında birbirine paralel olan sargı çiftleri arasında çevirme oranı belirlenebilir. Köprü yöntemiyle test yapılabilmesi için öncelikle transformatörün bağlantı grubunun bilinmesi ve fazör diyagramlarının incelenmesi gerekmektedir. Boşta çevirme oranındaki sapma $\leq \pm \%0,5$ olmalıdır. Bu sapma sınırları, transformatörün doğru bir şekilde çalıştığını ve sarım oranının beklenen değerler içinde olduğunu doğrulamak için kritik öneme sahiptir (IEEE Std C57.12.90-1987).

Bağlantı grubunun tespit edilmesi için, transformatörün bağlantı yapısının incelenmesi gereklidir. Transformatör bağlantı şekilleri, yıldız, üçgen veya zikzak bağlantı yapısında olabilir. Primer ve sekonder sargılar arasındaki faz açısı, 0° ile 360° arasında değişiklik gösterebilir. Örneğin, saat yönü ve açıları dikkate alındığında, Dyn5 bağlantı grubuna sahip bir transformatörde, primer sargı üçgen, sekonder sargı ise yıldız bağlantı yapısında olacaktır. Bu iki sargı arasında 150° ($5 \times 30^\circ$) faz farkı bulunur (Yıldız,2018). Şekil 2.16'da Dyn5 bağlantı grubuna sahip bir transformatörün vektör diyagramı gösterilmiştir. Bu diyagram, transformatörün doğru bağlantı grubunu belirlemek ve bağlantıların uygunluğunu teyit etmek için kullanılır.



Şekil 2.16. Dyn5 Bağlantılı Transformatör Vektör Diyagramı (Prasetyo ve ark, 2021)

2.4.5. Sargı direnci testi

Sargı direnci testi, transformatör sargılarının direncini (DC direnç) ölçerek, sargı kısa devrelerini, ek yerlerindeki kötü temasları, kademe kontaklarının durumunu ve sargı ile sipir kopukluklarını tespit etmek amacıyla yapılmaktadır.

Bu testlerde, aynı kademede ölçülen DC direnç değerleri, sıcaklık dikkate alınarak fabrika test değerleri veya önceki test sonuçları ile karşılaştırılmaktadır. Her kademe için fazlar kendi aralarında değerlendirilmekte, kademeler arası direnç değerlerinin istikrarlı bir şekilde artma veya azalma göstermesi beklenmektedir. Direnç farklılıkları, yukarıda belirtilen arızalardan bir veya birkaçının göstergesi olabilmektedir. Bu durumda, öncelik sırasına göre detaylı testler ve kontroller yapılarak arıza kaynağı tespit edilmektedir (IEC 60076-1,2011).

Sıcaklık, direncin değişiminde en önemli etken olduğundan, ölçümleri sıcaklıktan bağımsız hale getirmek amacıyla eşitlik (2.13) kullanılmaktadır. Bu yaklaşım, sıcaklığın direnç üzerindeki etkilerini ortadan kaldırarak, daha doğru ve güvenilir test sonuçları elde edilmesini sağlamaktadır.

$$R_2 = R_1 \cdot \frac{235 + t_2}{235 + t_1} \quad (2.13)$$


Burada 235 değeri, IEC standardında bakır için verilen sabit bir değeri ifade etmektedir (IEC 60076-1,2011). Sargı direnci ölçümleri genellikle köprü tekniği, voltmetre-ampermetre yöntemi veya mikro-ohmmetre kullanılarak yapılmaktadır. Ölçülecek direnç değerleri 1 ohm'un üzerinde ise Wheatstone köprüsü, 1 ohm'un altında ise Kelvin köprüsü veya mikro-ohmmetre tercih edilmelidir. Ölçülen sonuçlar, önceki test değerleri ile karşılaştırılmaktadır. Sargılarda herhangi bir gevşeklik veya iç bağlantılarda bir kırıklık olması durumunda, direnç değerleri yüksek çıkacaktır. Bazı standartlara göre, fazlar arası fark veya bir önceki ölçüme göre sıcaklıkla düzeltilmiş direnç değerleri %5'i geçmemelidir. Bu limitlerin aşılması, olası arızaların işareti olabilir ve bu durumda daha detaylı incelemeler yapılması gerekebilmektedir.

2.4.6. Frekans tarama cevabı analizi (Sweep frequency response analysis, SFRA)

Frekans tarama cevabı analizi testi fabrika kabul ve saha çalışmalarında yapılması gereken en önemli testlerden biridir. Test objesinin iki terminaline farklı frekans aralıklarında uygulanan terminal gerilim kaynağı ile uyartıldığında, genlik oranı ve faz açısının ölçülmesi ile elde edilen bir parametredir. SFRA tekniği, hasarın tespiti için

frekans cevabından elde edilen verileri kullanarak değerlendirme yapmaktadır. Bu alandaki ilk zorunlu standart, 1 Haziran 2005 tarihinde DL/T 911/2004 kodu ile Çin'de yayımlanmıştır. Aynı dönemde, uluslararası arenada Cigre ve IEEE gibi önemli kuruluşlar, bu test tekniklerini geliştirmek üzere çalışma grupları oluşturmuşlardır. Bu süreç sonucunda Cigre, 2009 yılında A2 teknik komitesinin 342 numaralı raporunu yayımlamış, bu rapor, SFRA testlerinin uygulanmasına dair önemli bir referans kaynağı olmuştur. Nihayetinde, IEEE tarafından C57.149/2012 standardı yayımlanmış ve bu standart, yağlı tip transformatörler için SFRA testlerinde kılavuz olarak benimsenmiştir (Kraetge ve ark,2009).

SFRA testlerinin temel prensibi, Şekil 2.17'de gösterilen genel prensip şemasında açıklandığı üzere, transformatörün bir terminaline belirli frekanslardaki düşük gerilim sinyalinin uygulanması ve diğer terminalden bu sinyalin genlik ve faz açısı olarak ölçülmesidir. Çıkıştaki sinyalin düşük olması nedeniyle, ölçümler genellikle desibel (dB) cinsinden yapılmaktadır. Bu ölçüm süreci, transformatörün erişilebilir tüm terminalleri için tekrarlanır ve elde edilen veriler, transformatörün mekanik ve elektriksel durumunu değerlendirmek için analiz edilir.




Şekil 2.17. Ses Sinyalinin Osiloskop Üzerinde Gösterimi (Kraetge ve ark,2009)

Bu bağlamda, SFRA testleri, transformatörlerde oluşabilecek hasarların erken tespiti ve izlenmesi açısından kritik bir öneme sahiptir. Geliştirilen bu standartlar ve metodolojiler, SFRA testlerinin güvenilirliğini ve etkinliğini artırarak, güç sistemlerinin daha güvenli ve sürdürülebilir bir şekilde işletilmesine katkıda bulunmaktadır.

2.4.7. Frekans tepkisi basit eşdeğer devresi

Elektriksel empedansın hem aktif hem de reaktif bileşenleri içerdiği bilinen bir gerçektir. Frekans tepkisi analizi (SFRA), bu pasif elemanların kompleks bileşenlerinin analizine dayanmaktadır. Bir elektrik devresi, direnç (R), endüktans (L) ve kapasitans (C) elemanlarından oluşabilir ve bu elemanlar seri veya paralel olarak çok sayıda bağlantı şeklinde bir araya gelebilir. Reaktif bileşenler, frekanstaki değişimlere karşı oldukça hassastır, bu nedenle bir devrenin eşdeğer modeli, frekansın bir fonksiyonu olarak empedans üzerinden ifade edilebilir.

SFRA analizi, özellikle RLC devreleri ile yakından ilişkilidir. Tipik bir transformatörün yüksek gerilim sargısı SFRA analizi yapıldığında, özellikle düşük frekanslarda oldukça belirgin rezonanslar gösterir. Bu rezonanslar, devredeki endüktif ve kapasitif bileşenlerin frekansa bağlı olarak değişen tepkilerinden kaynaklanır. Bu nedenle, SFRA yöntemi, özellikle transformatörlerin frekans yanıtlarını analiz etmek ve bu cihazlarda meydana gelebilecek olası arızaları tespit etmek için kritik bir araçtır.



Şekil 2.18. (a) İkinci Dereceden RLC Devresi ve (b) SFRA Cevabı (Sweetser ve ark,2003)

Şekil 2.18’de ikinci dereceden bir RLC devresi örneği verilmiş ve bu devrenin frekans tepkisi logaritmik ölçekte gösterilmiştir. Bu grafik, devredeki rezonans noktalarını ve bu noktaların frekansa bağlı olarak nasıl değiştiğini görsel olarak temsil etmektedir. SFRA analizinde elde edilen bu tür grafikler, cihazın karakteristik tepkilerini anlamak ve yorumlamak açısından son derece önemlidir. Bu sayede, cihazın performansı hakkında detaylı bilgi edinilebilir ve olası arızalar erken aşamada tespit edilerek önleyici bakım yapılabilir (Sweetser ve ark,2003).

2.4.8. Zaman ve frekans domeni

Sistem tepkisi hem zaman hem de frekans domainlerinde analiz edilebilir ve bu analiz, frekans tepkisi analizi (SFRA) gibi tekniklerle yakından ilişkilidir. Sistem tepkilerini analiz edebilmek için çeşitli matematiksel araçlar ve teknikler geliştirilmiştir. Zaman domaininde, diferansiyel denklemler veya konvolüsyon yöntemleri n. dereceden bir sistemin davranışını modellemek için kullanılırken, frekans domaininde Fourier ve Laplace dönüşümleri yaygın olarak tercih edilmektedir. Bu dönüşümler, sistemin zaman ve frekans domainleri arasında geçiş yapmayı sağlar ve bu sayede sistemin dinamik özellikleri hem zaman hem de frekans perspektifinden incelenebilir.


Frekans tepkisi analizi (SFRA), özellikle bu dönüşümlerin uygulama alanlarından biridir. Zaman domaininde bir sistemin davranışını temsil eden bir fonksiyon, Fourier dönüşümü ile frekans domainine taşınabilir ve burada frekans bileşenleri üzerinden analiz edilebilir. Bu dönüşümde, zaman domainindeki $f(t)$ fonksiyonu, frekans domaininde $F(j\omega)$ olarak ifade edilir. Tam tersi şekilde, $F(j\omega)$ frekans domainindeki bir fonksiyon, ters Fourier dönüşümü ile zaman domainine geri döndürülebilir ve $f(t)$ olarak elde edilir. Bu matematiksel ilişki, sistemin hem zaman hem de frekans domainlerindeki tepkisini anlayabilmek için kritik bir rol oynar (eşitlik 2.14) (Sweetser ve ark,2003).

$$F(j\omega) = \int_{-\infty}^{\infty} e^{-j\omega t} f(t) dt \quad f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-j\omega t} F(j\omega) d\omega \quad (2.14)$$

Sistem cevabını zaman domaininde analiz etmek, özellikle karmaşık elektriksel sistemlerde oldukça zorlayıcı olabilmektedir. Bu zorluk, zaman domaininde ortaya çıkan karmaşık dinamik davranışların doğrudan gözlemlenmesinin güç olmasından kaynaklanmaktadır. Ancak frekans domaininde yapılan analizler, bu zorlukların üstesinden gelmek için daha elverişli bir yaklaşım sunar. Frekans domaininde, farklı frekans bileşenlerinin analiz edilmesi, sistemin genliği ve fazı gibi özelliklerinin daha net bir şekilde anlaşılmasını sağlar. Özellikle, aynı empedans değerine sahip farklı frekans bileşenleri incelenebilir ve sistemde istenmeyen gürültü, harmonikler gibi etkiler daha kolay bir şekilde analiz edilebilir.

Frekans tepkisi analizi (SFRA), bu avantajlardan yararlanarak elektriksel sistemlerin performansını değerlendirir. Örneğin, bir transformatörün eşdeğer devresi, dört uçlu bir empedans devresi olarak modellenir. Bu modelde, iki uç giriş ve iki uç çıkış

olmak üzere, transformatörün bir terminaline uygulanan akım ve gerilim kaynakları, diğer terminalden çıkış olarak alınır. Bu şekilde yapılan modelleme, transformatörün frekans domainindeki davranışını analiz etmek için kullanılır ve sistemin rezonans, empedans ve diğer frekans bağımlı özelliklerini anlamada önemli bir rol oynar.



Şekil 2.19. Transformatörün iki uçlu empedans devre modeli (Sweetser ve ark,2003)

Şekil 2.19’da gösterilen transformatörün iki kapılı empedans devresi modeli, bu tür bir analizin temelini oluşturur. Bu model, transformatörün giriş ve çıkış terminalleri arasındaki ilişkileri inceleyerek, sistemin frekans domainindeki tepkilerini analiz eder. Bu analiz, özellikle transformatörün belirli frekanslarda nasıl bir performans sergilediğini, potansiyel arızaların hangi frekans aralıklarında meydana gelebileceğini ve bu arızaların sistemin genel performansını nasıl etkileyebileceğini anlamak açısından kritiktir (Sweetser ve ark,2003).

2.4.9. Transfer fonksiyonu

Transfer fonksiyonu, bir sistemin başlangıç koşullarında, RLC devre elemanlarının giriş ve çıkışlarındaki frekans tepkisi oranını matematiksel olarak tanımlar. Bu fonksiyon, bir sistemin girişine uygulanan sinyalin, çıkışta nasıl bir değişime uğrayacağını, özellikle genlik ve faz açısından nasıl bir dönüşüm geçireceğini belirler. Eşitlik (2.15)’de bu transfer fonksiyonu genel olarak ifade edilmiştir ve bu ifade, sistemin giriş ve çıkışları arasındaki ilişkiyi frekans domaininde modellemek için kullanılır.

Transfer fonksiyonu, bir sistemin dinamik özelliklerini anlamada kilit bir role sahiptir. Genlik ve faz ilişkisi, transfer fonksiyonu aracılığıyla detaylı bir şekilde incelenebilir. Örneğin, belirli bir frekansta bir devre elemanının çıkışındaki sinyalin genliği, girişteki sinyalin genliği ile kıyaslanarak bulunabilir. Benzer şekilde, faz açısından kayma da

transfer fonksiyonu ile ilişkilendirilerek hesaplanabilir. Bu ilişkiler, özellikle SFRA sistemlerin davranışını anlamak için kritik öneme sahiptir.

$$H(j\omega) = \frac{V_{\text{çıkış}}(j\omega)}{V_{\text{giriş}}(j\omega)} \quad (2.15)$$

Transfer fonksiyonu basit bir forma indirildiğinde, sistemin güç ve rezonans gibi temel karakteristikleri, transfer fonksiyonunun polinomundaki kökler üzerinden tanımlanır. Bu polinomun payının kökleri sistemin sıfırlarını, paydasının kökleri ise kutuplarını oluşturur. Sıfırlar, transfer fonksiyonunun kazancında artışa neden olurken, kutuplar ise bu kazancın düşmesine yol açmaktadır. Bu nedenle, sistemin dinamik davranışlarını anlamak için transfer fonksiyonunun kökleri büyük bir önem taşır. Ancak, yalnızca gerilim oranları kullanılarak transfer fonksiyonu $H(j\omega)$ hesaplandığında, bu fonksiyon doğrudan empedans $Z(j\omega)$ ile ilişkili olmayabilir. Bunun yerine, çıkış gerilimi hesaplanırken Ohm yasasına uygun olarak bir akımın devreye enjekte edilmesi gereklidir. SFRA cihazlarında, 50 Ω empedansın standart olarak kullanılmaya başlanmasıyla birlikte, SFRA ölçümleri, gerilim oranlarını kullanarak $H(j\omega)$ değerini hesaplamaktadır.

Eşitlik (2.16) (2.17), Bode diyagramının nasıl oluşturulacağını matematiksel olarak tanımlar. Bu eşitlik, sistemin transfer fonksiyonunu ($H(j\omega)$) kullanarak, genlik ve fazın frekansın bir fonksiyonu olarak hesaplanmasını sağlar. Ardından, bu hesaplamalar kullanılarak Bode diyagramı çizilir. Bu diyagram, özellikle RLC devrelerinin ve transformatörlerin frekans tepkilerini analiz etmek için önemli bir araçtır (Sweetser ve ark,2003).


$$A(dB) = 20\log_{10}(H(j\omega)) \quad (2.16)$$

$$A(\theta) = \tan^{-1}(H(j\omega)) \quad (2.17)$$


Bode diyagramının en önemli avantajlarından biri, frekans eksenini için logaritmik skala kullanarak sistemin frekans tepkisini daha net ve anlaşılır bir şekilde görselleştirmesidir. Logaritmik skala, geniş bir frekans aralığında asimptotik simetriyi ortaya koyar ve bu sayede sistemin dinamik davranışlarını daha kolay analiz etmeyi sağlar. Özellikle her bir kökteki sıfırlar ve kutuplar, frekansta on katlık bir artışa

karşılık gelen her birim değişiminde 20 dB'lik bir değişim yaratır. Kutuplar -20 dB'lik bir azalmaya neden olurken, sıfırlar +20 dB'lik bir artış sağlar. Bu özellik, sistemin rezonans özelliklerini ve stabilite sınırlarını analiz etmek için kritik önem taşır (Sweetser ve ark,2003).

Bode diyagramında logaritmik skalanın kullanılması, düşük ve yüksek frekanslardaki değişimlerin tek bir grafikte etkin bir şekilde gösterilmesini mümkün kılar. Bu, lineer grafiklerle elde edilemeyen bir avantajdır. Lineer ölçekli grafikler, özellikle yüksek frekanslardaki değişiklikleri yeterince net bir şekilde gösteremezken, logaritmik skala bu değişiklikleri daha görünür hale getirir. Bu durum, Şekil 2.20 ve Şekil 2.21'de açıkça gösterilmiş olup, kazancın frekansla birlikte logaritmik ve lineer olarak nasıl değiştiğini karşılaştıran bir örnek sunmaktadır. Bu şekilde, logaritmik skalanın özellikle yüksek frekanslarda sistemin davranışını daha doğru bir şekilde temsil ettiği açıkça görülmektedir.



Şekil 2.20. Kazancın Frekansla Değişiminin Logaritmik Olarak Gösterimi (Sweetser ve ark,2003)




Şekil 2.21. Kazancın Frekansla Değişiminin Lineer Olarak Gösterimi (Sweetser ve ark,2003)

Frekans domaini karakteristiğinin ölçümünde yaygın olarak kullanılan iki temel yöntem vardır: frekans spektrumunu tarama yöntemi ve Hızlı Fourier Dönüşümü (Fast Fourier Transform, FFT) tekniği. Bu yöntemler, sistemlerin frekans yanıtını analiz etmek ve anlamak için kullanılmaktadır.

2.4.10. Transformatör frekans tepkisi eşdeğer devresi

Transformatöre ait SFRA testine başlamadan önce, transformatörün iç yapısının ve bu yapının hangi parametreleri nasıl etkilediğinin anlaşılması son derece önemlidir. SFRA testi, transformatörün iç yapısındaki mekanik ve elektriksel bileşenlerin durumunu değerlendirerek olası arızaların tespiti için kullanılır. Bu nedenle, testin doğru bir şekilde uygulanabilmesi için transformatörün fiziksel yapısının ve iç devre elemanlarının nasıl bir etkileşim içinde olduğunu anlamak gereklidir.

Şekil 2.22’de, transformatörün iç yapısı ve eşdeğer devresi görselleştirilmiştir. Şekil 2.22 (a) gerçek bir transformatörün iç kısmını göstermekte olup, bu yapıda çekirdek ve sargılar bulunmaktadır. Bu bileşenler, transformatörün frekans tepkisini doğrudan etkileyen kritik unsurlardır. Örneğin, sargılar arasındaki mekanik bozulmalar veya yalıtım malzemelerindeki hasarlar, SFRA testi sırasında belirgin rezonans değişikliklerine neden olabilmektedir. Şekil 2.22 (b)’de ise, transformatörün eşdeğer devresi çizilmiştir. Bu devre, test sırasında elde edilen frekans tepkisi verilerini yorumlamak ve transformatörün durumu hakkında bilgi edinmek için temel bir referans sağlamaktadır (Kraetge ve ark,2009).



Şekil 2.22. (a) Transformatör Nüve ve Sargıları- (b) Transformatör Eşdeğer Devresi (Kraetge ve ark,2009)

Transformatörün frekans tepkisi analizi (SFRA) yalnızca tek bir ölçümle sınırlı olmayıp, farklı bağlantı şekilleri ve ölçüm yöntemlerini içermektedir. Bu çok yönlü yaklaşım, transformatörde meydana gelebilecek çeşitli arıza türlerinin tespit edilmesini ve daha önceki ölçümlerle kıyaslandığında bu arızaların belirlenmesini sağlamaktadır. Bir transformatörde zamanla oluşabilecek arızaların doğru bir şekilde tespit edilebilmesi için, önceden yapılmış ölçümlerin tüm varyasyonları dikkatle kaydedilmeli ve analiz edilmelidir. Bu sayede, sonuçların karşılaştırılması sırasında herhangi bir belirsizlik oluşmasının önüne geçilmiş olur.


Tablo 2.5, frekans tepkisi analizine göre farklı frekans bölgeleri ve bu bölgelerle ilişkili olası hata tipleri arasındaki ilişkiyi göstermektedir. Bu tablo, SFRA sonuçlarını yorumlarken hangi frekans bölgesinde hangi tür hataların olabileceği konusunda rehberlik eder ve transformatördeki potansiyel sorunların doğru bir şekilde tanımlanmasına yardımcı olmaktadır.

Tablo 2.5. SFRA yönteminde, temel dalga ile ölçülen dalganın karşılaştırılması yoluyla hata türleri saptanması (Pandya ve ark,2013).

Temel Dalga ile Analiz Edilen Dalganın Karşılaştırılması	Hata Çıktısı
Ölçülen dalga şeklinin 5 Hz altında oransız biçimde değişmesi	Çekirdek hatası
Ölçülen dalga şeklinin 10 kHz üzerinde oransız biçimde değişmesi	Sargı hatası
Temel dalga ile arasında 3 dB'den az değişiklik olması	Normal ve toleranslar içerisinde
5 Hz ile 2 kHz arası +/- 3 dB veya daha fazla değişiklik olması	Sargı kısa devresi, açık devre rezidüel manyetizma veya çekirdek kayması
50 Hz ile 20 kHz arası +/- 3 dB veya daha fazla değişiklik olması	Sargıların tümüyle kayması
500 Hz ile 2 MHz arası +/- 3 dB veya daha fazla değişiklik olması	Sargılarda deformasyon
25 Hz ile 10 MHz arası +/- 3 dB veya daha fazla değişiklik olması	Sargı ucu ile veya test bağlantı ucu ile alakalı hata

Tablodan da anlaşılacağı üzere bu analiz, bir transformatörün karakteristik frekans yanıtını belirleyerek, adeta transformatörün "parmak izini" çıkarır. Bu benzersiz frekans tepkisi, transformatörün belirli bir zamanda mevcut olan durumunu temsil eder ve bu durum, gelecekte yapılacak rutin kontrol testleri için referans noktası olarak kullanılır. SFRA'nın bu özelliği, transformatörde zaman içinde meydana gelebilecek en küçük değişikliklerin bile hassas bir şekilde tespit edilmesine olanak tanımaktadır.

Bu sayede, transformatörde oluşabilecek mekanik ya da elektriksel arızalar, belirgin hale gelmeden önce erken aşamada fark edilebilir ve bu da hem bakım süreçlerini optimize eder hem de olası arızaların önüne geçilerek transformatörün ömrünü uzatır.



Şekil 2.23. Örnek SFRA Değerlendirme Grafiği (TEİAŞ,2020)


- A- Çekirdek
- B- Sargılar Arası Durum
- C- Sargı Yapısal Durumu
- D- Ölçüm Kurulumu ve Kablo Durumları

TEİAŞ yayımladığı saha testleri kılavuzunda SFRA değerlendirme grafiği olarak Şekil 2.23'te verilen grafiği baz almaktadır (TEİAŞ,2020).

2.4.11. SFRA ölçüm yöntemleri ve bağlantı şekilleri


SFRA, temel olarak dört ana ölçümden oluşsa da çeşitli varyasyonlarla bu ölçümlerin sayısı artırılabilir. Bu ölçümler, transformatörün iç yapısındaki farklı elektriksel ve manyetik özellikleri değerlendirmek için farklı bağlantı senaryolarını içerir. Temel SFRA ölçümleri, sargı sonundan sargı sonuna yapılan ölçümleri kapsar ve bu ölçümler, sekonder sargı açık devre ve sekonder sargı kısa devre olmak üzere her iki durumda da gerçekleştirilir. Bu, transformatörün hem açık devre hem de kısa devre koşullarında nasıl bir frekans tepkisi verdiğini analiz etmeyi sağlar. Diğer iki temel ölçüm ise sargılar arası (primer ve sekonder) kapasitif ölçüm ve sargılar arası endüktif ölçümdür. Kapasitif ölçüm, sargılar arasındaki kapasitans etkilerini değerlendirirken, endüktif ölçüm ise sargılar arasındaki manyetik etkileşimleri analiz eder. Bu iki ölçüm türü, transformatörün frekans domainindeki farklı davranışlarını anlamak için kritik öneme sahiptir.

Sargı sonu-sargı sonu ölçümleri, transformatörün kaynak fazında veya nötr terminaldeyken de yapılabilir. Bu ölçüm varyasyonları, özellikle üç fazlı bir transformatörde farklı faz kombinasyonlarını incelemek için kullanılır. Kısa devre edilen testlerde, her faz sırasıyla kısa devre edilerek ölçüm yapılabileceği gibi, tüm fazlar aynı anda kısa devre edilerek de analiz yapılabilir. Bu, transformatörün farklı çalışma koşulları altındaki tepkilerini daha kapsamlı bir şekilde değerlendirme olanağı sunar.



Şekil 2.24. SFRA Analize Ait Temel Ölçüm Prensi Şeması (Korenciak ve ark, 2020)

Frekans tepkisi analizine ait temel ölçüm prensip şeması, Şekil 2.24'te gösterilmiştir. Sahada yapılan SFRA testine ait bağlantı şeması Şekil 2.25'te verilmiştir.



Şekil 2.25. Sahada SFRA ve Bağlantısı

Bu çalışmada, güç trafolarında arıza durumlarının fiziksel olarak oluşturulması mümkün olmadığından, test trafosu kullanılmıştır. Çekirdek kısa devresi ve sargı kayması gibi arıza durumları, SFRA yöntemiyle simüle edilmiş ve hem normal hem de arıza durumlarında testler yapılarak veriler toplanmıştır. Elektriksel yapıları açısından farklı boyut ve güçlerdeki transformatörler, çekirdek ve sargıdan oluştuğu için SFRA testlerinde benzer sonuçlar elde edilmektedir.



3. MAKİNE ÖĞRENMESİ TEKNİKLERİ

Makine öğrenmesi, bilgisayar sistemlerinin açıkça programlanmadan verilerden öğrenme ve tahminlerde bulunma yeteneğini geliştiren bir yapay zekâ dalıdır. Bu teknoloji, büyük veri setlerinden anlamlı bilgilerin otomatik olarak çıkarılması ve karar verme süreçlerinin optimize edilmesi amacıyla kullanılmaktadır. Makine öğrenmesi, günümüzde birçok alanda devrim yaratmış ve çeşitli uygulamalarda geniş ölçüde benimsenmiştir. Makine öğrenmesinde, verileri analiz eden ve belirli bir görevi yerine getirmek üzere öğrenen algoritmalar kullanılmaktadır. Algoritmalar, verilerden öğrenmek ve model oluşturmak için kullanılır. Modeller, gelecekteki veriler üzerinde tahminler yapmak için bu algoritmalar tarafından eğitilir. Makine öğrenmesi algoritmaları, genellikle denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak üç ana kategoriye ayrılmaktadır.

Denetimli öğrenme, algoritmanın etiketlenmiş verilerle eğitildiği bir öğrenme türüdür. Bu türde, giriş verileri ve bu verilere karşılık gelen doğru çıktılar bilinir. Algoritma, eğitim süreci boyunca doğru tahminler yapmayı öğrenir. Yaygın denetimli öğrenme algoritmaları arasında doğrusal regresyon, lojistik regresyon, karar ağaçları ve destek vektör makineleri bulunmaktadır.

Denetimsiz öğrenme, algoritmanın etiketlenmemiş verilerle çalıştığı ve veri setindeki gizli desenleri veya yapıları keşfetmeye çalıştığı bir öğrenme türüdür. Kümeleme ve boyut indirgeme teknikleri, denetimsiz öğrenmenin örnekleridir. K-Means ve Principal Component Analysis (PCA) bu alanda yaygın olarak kullanılmaktadır.

Pekiştirmeli öğrenme, bir ajan (agent) ile çevresi arasındaki etkileşimlere dayanır. Ajan, çevresindeki durumlara (state) göre eylemler (action) gerçekleştirir ve bu eylemler sonucunda ödüller (reward) alır. Ajan, ödül fonksiyonunu maksimize etmeyi öğrenir. Q-Learning ve Deep Q-Networks (DQN) gibi algoritmalar bu alanda kullanılmaktadır.

Makine öğrenmesi, birçok farklı uygulama alanına sahiptir. Görüntü tanıma, makine öğrenmesinin özellikle derin öğrenme algoritmaları sayesinde büyük başarılar elde ettiği bir alandır. Bu teknoloji, yüz tanıma sistemleri, tıbbi görüntü analizi ve otonom

araçlar gibi birçok alanda kullanılmaktadır. Doğal dil işleme (NLP), metin ve konuşma verilerini anlamak ve işlemek için de makine öğrenmesi tekniklerini kullanır. Çeviri, duygu analizi, sohbet botları ve konuşma tanıma sistemleri gibi birçok uygulamada kullanılmaktadır. Tahmin ve öneri sistemleri, kullanıcıların geçmiş davranışlarına dayanarak gelecekteki davranışları tahmin etmek için kullanılır. Bu, e-ticaret sitelerinde ürün önerileri, içerik platformlarında film veya müzik önerileri gibi alanlarda uygulanmaktadır. Finansal piyasalarda makine öğrenmesi, risk yönetimi, algoritmik ticaret ve dolandırıcılık tespitinde kullanılır. Sağlık sektöründe ise, hasta verilerinden hastalık tahmini, tedavi önerileri ve ilaç keşfi gibi alanlarda büyük ilerlemeler sağlanmıştır. Makine öğrenmesinin önemli bir uygulama alanı da arıza tahminine edilmesine yönelik çalışmalardır. Makine öğrenmesi, arızalarının tahmin edilmesinde çeşitli yöntemlerle kullanılabilir. Özellikle, geçmiş arıza verileri ve çalışma koşullarına dair büyük veri setlerinden yararlanarak, olası arıza durumlarını öngören modeller oluşturulabilmektedir. Makine öğrenmesi, veri odaklı karar verme süreçlerinde devrim yaratma potansiyeline sahip güçlü bir teknolojidir. Doğru veriler ve uygun algoritmalar ile uygulandığında, makine öğrenmesi birçok sektörde verimliliği artırabilir ve yeni çözümler sunabilmektedir.

Makine öğrenmesi Büyük veri setlerinden değerli bilgiler çıkarma ve insan müdahalesi olmadan karmaşık görevleri otomatikleştirme yeteneği ile büyük avantajlar sunar. Ancak, veri kalitesi, algoritma seçimi ve model doğrulama gibi zorluklar da beraberinde gelir. Ayrıca, etik ve gizlilik konuları, makine öğrenmesi uygulamalarında dikkat edilmesi gereken önemli hususlardır (Janiesch ve ark,2021).

3.1. Makine Öğrenmesi Modelleri

3.1.1. Lojistik regresyon (Logistic regression)

Lojistik regresyon, ikili sınıflandırma problemlerinde yaygın olarak kullanılan istatistiksel bir modelleme tekniğidir. Bu yöntem, bağımlı değişkenin iki kategoriden biri olduğu durumlarda, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi modellemek için kullanılmaktadır. Lojistik regresyon modeli, olasılık tahminlerini elde etmek amacıyla lojistik (sigmoid) fonksiyonunu kullanır. Lojistik regresyonun temel amacı, bağımlı değişkenin olasılığını modellemektir. Bu amaçla, bağımlı değişken genellikle iki kategoriye ayrılır: 1 (olayın meydana gelmesi) ve 0 (olayın

meydana gelmemesi). Modelin temel matematiksel denklemi denklem (3.1)'de verilmiştir.

$$\text{logit}(P) = \ln\left(\frac{P}{1-P}\right) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (3.1)$$


Bu denklemde P, olayın meydana gelme olasılığıdır. β_0 , sabit terimdir. $\beta_i (i = 1, 2, 3, \dots, n)$, bağımsız değişkenlerin katsayılarıdır. $X_i (i = 1, 2, 3, \dots, n)$, bağımsız değişkenlerdir. Lojistik fonksiyon, P olasılığını hesaplamak için kullanılır ve denklem (3.2)'de verildiği gibi tanımlanır.

$$P = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}} \quad (3.2)$$

Bu fonksiyon, bağımlı değişkenin iki kategori arasında nasıl dağıldığını açıklar. Lojistik regresyon modeli, maksimum olabilirlik (maximum likelihood) yöntemi kullanılarak kurulmaktadır. Bu yöntem, gözlemlenen verilerin en yüksek olasılıkla ortaya çıkmasını sağlayan parametrelerin bulunmasını amaçlamaktadır. Modelin eğitilmesi sürecinde, eğitim veri seti kullanılarak modelin parametreleri (katsayıları) tahmin edilir. Bu, modelin bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerini öğrenmesini sağlar. Eğitilmiş model kullanılarak yeni veri noktalarının hangi kategoriye ait olacağı tahmin edilir. Tahminler, 0 ile 1 arasında olasılıklar olarak ifade edilir. Olasılıklar belirli bir eşik değerine göre (genellikle 0.5) sınıflandırılır. Eğer tahmin edilen olasılık 0.5'in üzerindeyse, olayın meydana geldiği (1) kabul edilir; aksi takdirde, olayın meydana gelmediği (0) kabul edilmektedir (Hosmer ve ark, 2013).

Lojistik regresyonun birçok avantajı vardır. Modelin parametreleri, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini doğrudan gösterir, bu da modelin yorumlanaabilirliğini artırır. Ayrıca, daha az sayıda veri ile anlamlı sonuçlar elde edilebilir ve diğer karmaşık modellerle karşılaştırıldığında daha hızlı ve daha az hesaplama gücü gerektirir. Ancak, bazı dezavantajları da vardır. Model, bağımsız değişkenler ile log-odds arasındaki ilişkinin doğrusal olduğunu varsayar. Temel haliyle yalnızca iki kategorili sınıflandırma problemleri için uygundur. Multinomial lojistik regresyon gibi uzantıları da bulunmaktadır. Ayrıca, uç değerler modelin performansını olumsuz etkileyebilmektedir.

Lojistik regresyon, ikili sınıflandırma problemleri için güçlü ve etkili bir yöntemdir. Modelin yorumlanabilirliği, çeşitli alanlarda geniş uygulama bulmasını sağlar. Ancak, modelin doğrusal varsayımları ve uç değerlere karşı duyarlılığı, dikkatli bir veri ön işleme ve model değerlendirme gerektirir (Hosmer ve ark,2013). Lojistik regresyona ilişkin grafik Şekil 3.1’de verilmektedir.




Şekil 3.1. Lojistik Regresyon Modeli (Fatima ve ark, 2023)

3.1.2. Rastgele ormanlar algoritması (Random Forest)

Rastgele ormanlar algoritması (Random Forest), sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan güçlü bir makine öğrenmesi algoritmasıdır. Bu algoritma, birden fazla karar ağacını bir araya getirerek bir "orman" oluşturur ve her ağacın çıktısını birleştirerek nihai tahmini yapmaktadır. Bu yaklaşım, modeli daha sağlam ve genellenebilir hale getirmektedir. Random Forest algoritmasının temel prensibi, birden fazla karar ağacı oluşturarak her bir ağacın sınıflandırma veya regresyon yapmasını sağlamaktır. Her ağaç, veri setinin rastgele bir alt kümesi üzerinde eğitilir ve her düğümde rastgele bir alt özellik kümesi kullanılır. Bu yöntem, karar ağaçlarının bireysel zayıflıklarını azaltarak aşırı uyumu (overfitting) önlemektedir (Breiman,2001). Random Forest algoritmasında, her karar ağacı eğitilirken, her düğümde en iyi bölünmeyi bulmak için özelliklerin rastgele bir alt kümesi kullanılmaktadır. Bu, ağaçlar arasında daha fazla çeşitlilik sağlar ve modelin genelleme yeteneğini artırır (Breiman,2001) (Ho,1995).

Random Forest Sınıflandırıcısı, belirli adımlarla oluşturulur. İlk olarak, orijinal veri setinden bootstrap örnekleme yöntemi ile rastgele alt kümeler oluşturulur. Daha sonra, her bir bootstrap örnekleme seti üzerinde bir karar ağacı eğitilir. Ağaçların her düğümünde, en iyi bölünmeyi bulmak için rastgele bir alt özellik kümesi kullanılır. Son olarak, tüm ağaçların tahminleri birleştirilir. Sınıflandırma problemlerinde, çoğunluk oylaması ile nihai tahmin yapılır. Regresyon problemlerinde ise, ağaçların

tahminlerinin ortalaması alınmaktadır (Ho,1995). Şekil 3.2’de rastgele ormanlar algoritmasının şematik gösterimi verilmektedir.



Şekil 3.2. Rastgele Ormanlar Algoritması Şematik Gösterim (Khan ve ark, 2021)

Random Forest Sınıflandırıcısının birçok avantajı vardır. Yüksek doğruluk sağlar ve aşırı uyum riskini azaltmaktadır. Karar ağaçlarının çeşitliliği, modelin genelleme yeteneğini artırır. Ayrıca, model, özelliklerin önemini değerlendirebilir ve bu bilgiler modelin açıklanabilirliğini artırmaktadır. Ancak, bazı dezavantajları da vardır. Çok sayıda karar ağacı oluşturulması, hesaplama maliyetini artırır ve modelin eğitilmesini yavaşlatır. Büyük veri setleri ve çok sayıda ağaç, bellek kullanımını artırır. Karar ağaçlarının birleşiminden oluşan bir modelin yorumlanması, tek bir karar ağacına göre daha zordur (Ho,1995).

3.1.3. En yakın komşu algoritması (K-nearest neighbors (KNN))

En yakın komşu algoritması (K-Nearest Neighbors (K-NN)) algoritması hem sınıflandırma hem de regresyon problemlerinde kullanılan, örnek tabanlı bir makine öğrenmesi yöntemidir. Bu algoritma, bir veri noktasının sınıfını veya değerini belirlemek için, o noktaya en yakın k komşusunun sınıflarına veya değerlerine bakar. K-NN, basit ama güçlü bir yöntemdir ve birçok uygulama alanında etkili sonuçlar vermektedir. K-NN algoritması, eğitim aşamasında herhangi bir model oluşturmaz. Bunun yerine, tüm eğitim verilerini bellekte tutar ve tahmin aşamasında bu verileri kullanır. Algoritma, bir veri noktasının sınıfını veya değerini belirlerken, bu noktaya

en yakın k komşusunu bulur ve bu komşuların sınıflarının çoğunluğuna veya ortalamasına bakarak karar vermektedir (Cover ve ark,1967).

Yeni bir veri noktası için, eğitim veri setindeki her bir nokta ile olan mesafesi hesaplanır. En yaygın kullanılan mesafe ölçüsü Öklidyen mesafedir (Cover ve ark,1967). Öklidyen mesafe, iki nokta arasındaki düz çizgi mesafesini ifade etmektedir (3.3).

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.3)$$

Burada x ve y karşılaştırılan iki veri noktasıdır ve n bu noktaların boyut sayısını ifade etmektedir. Hesaplanan mesafeler kullanılarak, yeni veri noktasına en yakın k komşu belirlenir. Bu komşular, mesafeye göre sıralanır ve en küçük k mesafeye sahip olanlar seçilir.

Sınıflandırma problemlerinde, en yakın k komşunun sınıflarının çoğunluğuna bakılır ve yeni veri noktası bu sınıfa atanır. Bu işlem çoğunluk oylaması ile yapılır. Regresyon problemlerinde ise, en yakın k komşunun değerlerinin ortalaması alınarak yeni veri noktasının değeri tahmin edilir. Öklidyen mesafe en yaygın kullanılan mesafe ölçüsü olsa da bazı durumlarda Manhattan mesafesi gibi diğer mesafe ölçümleri de kullanılabilir (3.4) (Cover ve ark,1967) (Altman,1992).


$$d_{MANHATTAN}(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (3.4)$$

Bazı durumlarda, her bir komşunun katkısı mesafesine göre ağırlıklandırılabilir. Bu durumda, daha yakın komşuların daha büyük bir ağırlığa sahip olması sağlanmaktadır (3.5) (Cover ve ark,1967) (Altman,1992).

$$y' = \frac{\sum_{i=1}^k \frac{y_i}{d(x, x_i)}}{\sum_{i=1}^k \frac{1}{d(x, x_i)}} \quad (3.5)$$

K-NN algoritmasının birçok avantajı bulunmaktadır. Basitliği, kolay anlaşılabilir ve uygulanabilir olmasını sağlar. Herhangi bir parametrelili model kurmaya gerek duymaz

ve her türden veri üzerinde çalışabilmektedir. Yeterli miktarda veri bulunduğunda yüksek doğruluk oranları sağlamaktadır. Ancak, bazı dezavantajları da vardır. Tüm eğitim verilerinin bellekte tutulması ve her tahmin için tüm mesafelerin hesaplanması, büyük veri setlerinde yüksek hesaplama maliyetine yol açmaktadır. Eğitim verilerinin tamamının bellekte tutulması, büyük veri setlerinde bellek kullanımını artırır. Farklı ölçeklerdeki öznitelikler, mesafe hesaplamalarını olumsuz etkileyebilir. Bu nedenle, özniteliklerin normalizasyonu veya standardizasyonu gerekebilir (Cover ve ark,1967) (Altman,1992). Şekil 3.3'te K-NN algoritmasının çalışma prensibi verilmiştir.



Şekil 3.3. K-NN Çalışma Prensibi (Altunkaynak ve ark, 2020)

3.1.4. Destek vektör sınıflandırma algoritması (support vector classifier SVC)

Destek vektör sınıflandırma algoritması (Support Vector Classifier SVC), sınıflandırma problemlerinde yaygın olarak kullanılan güçlü ve esnek bir makine öğrenmesi algoritmasıdır. SVC, verileri yüksek boyutlu bir uzaya yansıtarak bu uzayda en iyi ayrımı yapan hiperdüzlemi bulmayı amaçlamaktadır. Bu ayrım, iki sınıf arasındaki marjini maksimize ederek gerçekleştirilir

Bir veri seti $(x_i + y_i)$, $i=1, 2, \dots, n$ olmak üzere, burada x_i veri noktalarını ve y_i sınıf etiketlerini temsil etmektedir. Buradaki y_i genellikle -1 veya 1 olarak alınmaktadır. SVC, optimizasyon problemini çözerek en iyi ayrımı yapabilen hiper düzlemi bulmaktadır (3.6) (Cortes ve ark,1995) (Scholkopf ve ark,2002).


$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (3.6)$$

Bu koşullar altında:

$$y_i(w \cdot x_i + b) \geq 1 \quad (3.7)$$

Burada w hiper düzlemin normal vektörü ve b sabit bir terimdir. Amaç, w ve b parametrelerini optimize ederek iki sınıf arasındaki marjini maksimize etmektir. Eğer denklem (3.7) ifadesi sağlanıyorsa, bu veri noktası doğru sınıflandırılmış demektir. Yani, veri noktası doğru tarafta ve marjinin dışındadır. Ancak, bu ifadenin -1'den büyük olması, veri noktasının hiper düzlemin doğru tarafında fakat marjin içinde olabileceğini gösterir. Bu durumda, veri noktası doğru sınıflandırılmış olabilir ancak marjin içerisinde yer aldığı için model üzerinde bir etkisi olabilir. Destek vektörleri, marjin sınırında veya marjin içinde yer alan veri noktalarıdır ve bu noktalar modelin karar sınırını belirlemede kritik rol oynar. Bu noktalar, modelin performansını ve genelleme yeteneğini doğrudan etkiler. Eğer veri noktası -1'den büyükse ancak yine de 1'den küçükse, bu noktalar destek vektörleri olarak kabul edilir ve modelin oluşturulmasında kullanılmaktadır (Cortes ve ark,1995) (Scholkopf ve ark,2002).

SVC, doğrusal olarak ayrılabilir olmayan verilerle çalışmak için kernel triklerini kullanır. Kernel trik, verileri daha yüksek boyutlu bir uzaya yansıtarak doğrusal ayrımı mümkün kılar. Yaygın olarak kullanılan kernel fonksiyonları şunlardır: Lineer Kernel, Polinomial Kernel, RBF (Radial Basis Function) Kernel ve Sigmoid Kernel (Scholkopf ve ark,2002). Şekil 3.4'te SVC algoritmasının şematik gösterimi verilmiştir.



Şekil 3.4. SVC Sınıflandırma Algoritmasının Şematik Gösterimi (Hu ve ark,2022)

SVC'nin birçok avantajı vardır. SVC, özellikle yüksek boyutlu veri setlerinde yüksek performans göstermektedir. Farklı kernel fonksiyonları kullanarak doğrusal olmayan ayrımları yapabilir ve marjini maksimize ederek genelleme yeteneğini artırır. Ancak, bazı dezavantajları da bulunmaktadır. Büyük veri setlerinde eğitim süresi uzun olabilir ve kernel fonksiyonları ile hiper parametrelerin seçimi zordur ve çapraz doğrulama gerektirir. Özelliklerin farklı ölçeklerde olması, performansı olumsuz etkileyebilir ve bu nedenle, veri ön işleme adımları gerektirmektedir (Scholkopf ve ark,2002).

3.1.5. Karar ağaçları

Karar ağaçları, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan bir makine öğrenmesi algoritmasıdır. Bu algoritma, verileri sınıflandırmak için bir dizi karar kuralları oluşturarak verileri dallar ve yapraklar şeklinde organize etmektedir. Her bir iç düğüm, belirli bir özelliğe göre veri setini böler, her dal bir karar kuralını temsil eder ve her yaprak düğüm, sınıf etiketini belirtir. Karar ağaçları, veriyi hiyerarşik olarak böler ve her bölen düğümde en iyi ayrımı sağlayan özellik ve eşik değeri seçilir. Bu süreç, veriyi saflaştırmayı amaçlamaktadır. Bir düğüm tamamen saf hale geldiğinde veya daha fazla bölecek veri kalmadığında, yaprak düğümler oluşmaktadır (Hu ve ark,2022) (Suthaharan,2016).

Çalışmalarda veri seti D , Özellikler $X_1, X_2, \dots, X_n$ ve sınıf etiketleri Y ile temsil edilmektedir. Karar ağacı, her bir düğümde veri setini bölen bir karar kuralı belirler. Bu kural, belirli bir özellik X_i ve eşik değeri t kullanarak veri setini iki alt sete bölmektedir (3.8) (Hu ve ark,2022) (Suthaharan,2016).


$$D_{sağ} = \{(X, Y) \in D : X_i \leq t\} \text{ ve } D_{sol} = \{(X, Y) \in D : X_i > t\} \quad (3.8)$$

En iyi bölünmeyi seçmek için kullanılan ölçütler genellikle Gini impüriti, bilgi kazancı veya varyans azaltımıdır. Gini impüriti, bir düğümdeki veri karışıklığını ölçmektedir. Bir düğümdeki Gini impüriti denklem (3.9)' da verildiği şekilde hesaplanır. Burada C sınıf sayısı ve p_i , i -th sınıfının olasılığıdır. Gini impüriti, düğümdeki veri noktalarının ne kadar karışık olduğunu ölçer ve daha saf düğümler için daha düşük değerler almaktadır (Hu ve ark,2022) (Suthaharan,2016).

$$Gini(D) = 1 - \sum_{i=1}^C p_i^2 \quad (3.9)$$

Bilgi kazancı, veri setini böldükten sonra elde edilen bilgi miktarını ölçer ve entropi kavramını kullanır. Bilgi kazancı, düğümlerin saflığını artırarak karar ağacının veriyi daha iyi ayırmasına yardımcı olmaktadır. Regresyon problemlerinde, varyans azaltımı veri setinin bölünmesinin etkisini ölçmektedir. Varyans azaltımı veri noktalarının ne kadar iyi ayrıldığını ölçer ve daha düşük varyans değerleri için daha iyi bölünmeler sağlamaktadır (Hu ve ark,2022) (Suthaharan,2016).

Karar ağaçları, sonuçları kolayca anlaşılabilir ve görselleştirilebilir. Bu, karar ağacı modellerinin sonuçlarını açıklamayı ve yorumlamayı kolaylaştırmaktadır. Normalizasyon veya standardizasyon gibi veri ön işleme adımlarına genellikle ihtiyaç duymaz. Bu, karar ağaçlarını veri hazırlığı açısından daha az zahmetli hale getirmektedir. Hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Bu, karar ağaçlarını çok yönlü bir araç haline getirir. Ancak, bazı dezavantajları da bulunmaktadır. Karar ağaçları, aşırı uyuma meyillidir ve genellikle budama yöntemleri veya maksimum derinlik sınırlandırması ile kontrol edilmesi gerekmektedir. Bu, modelin genelleme yeteneğini artırmak için önemlidir. Büyük veri setlerinde eğitim süresi uzun olabilir. Dengesiz veri setlerinde performans düşebilir ve dengeleyici yöntemler gerekebilmektedir. Bu, karar ağacı modellerinin sınıf dengesizliklerine karşı duyarlı olabileceği anlamına gelmektedir. Şekil 3.5'te karar ağaçları algoritmasının örnek şematik gösterimi verilmiştir.



Şekil 3.5. Karar Ağaçları Örnek Şematik Gösterim (Çamur & Uçar, 2021)

3.1.6. Gradient boosting classifier (GBC)

Gradient Boosting Classifier (GBC), makine öğrenmesi alanında güçlü bir topluluk öğrenme yöntemidir. Bu yöntem, zayıf öğreniciler olarak adlandırılan bir dizi karar ağacını ardışık olarak eğiterek bir güçlü öğrenici oluşturur. Her bir ağaç, bir önceki ağacın hatalarını düzeltmeye çalışır ve her bir etiket için karar ağacı sayısı artmaktadır. Bu süreç, hataların kademeli olarak azaltılması ve modelin performansının artırılmasıyla sonuçlanır. Etiket sayısındaki artış ile karar ağacı sayısının artış durumu bir önceki hatanın düzeltilmesine sebep olmaktadır. Bu sayede GBC algoritması sürekli olarak gelişerek doğruluk değerini arttırmaya çalışır. GBC, temel olarak üç ana bileşenden oluşur: zayıf öğreniciler, kayıp fonksiyonu ve gradyan inişi. Zayıf öğreniciler genellikle karar ağaçlarıdır. Kayıp fonksiyonu, modelin tahminlerinin ne kadar hatalı olduğunu ölçer. Gradyan inişi ise bu hataları en aza indirmek için modelin parametrelerini optimize etmektedir (Friedman,2001).

Model, başlangıçta basit bir modelle başlar ve her yinelemede yeni bir ağaç eklenir. Her yeni ağaç, bir önceki modelin hatalarını öğrenir ve tahmin eder. Bu süreç, hataların azaltılması ve modelin doğruluğunun artırılması amacıyla tekrarlanmaktadır. Her adımda, mevcut modelin tahmin hatalarını hedefleyen bir ağaç eklenir ve bu ağaç, hataların gradyan yönünde düzeltilmesine çalışılır (Suthaharan,2016) (Friedman,2001).


Matematiksel olarak, modelin çıktısı $F_m(x)$ aşağıdaki şekilde ifade edilmektedir (eşitlik 3.10).

$$F_m(x) = F_{m-1}(x) + v * h_m(x) \quad (3.10)$$

Burada $F_{(m-1)}(x)$ önceki modelin tahminlerini, $h_m(x)$ ise m'inci ağacın tahminlerini temsil etmektedir. v öğrenme oranıdır ve modelin daha yavaş ve daha dikkatli öğrenmesini sağlamaktadır.

Kayıp fonksiyonu genellikle ortalama kare hatası veya lojistik kayıp gibi fonksiyonlardan seçilmektedir. Model, her adımda bu kayıp fonksiyonunu minimize etmeye çalışır. Gradyan inişi, kayıp fonksiyonunun türevlerini kullanarak model parametrelerini günceller. Bu, modelin daha doğru tahminler yapmasını sağlamaktadır (Friedman,2001) (Hastie ve ark,2009).

Gradient Boosting Classifier, çeşitli avantajlara sahiptir. Yüksek doğruluk sağlar ve aşırı uyuma karşı dayanıklıdır. Model, karmaşık veri yapılarını öğrenebilir ve çok sayıda özellik ile çalışabilmektedir. Ayrıca, esnek bir modeldir ve farklı kayıp fonksiyonları ve zayıf öğrenicilerle kullanılabilir. Bununla birlikte, bazı dezavantajları da vardır. Eğitim süresi uzundur ve büyük veri setlerinde hesaplama maliyeti yüksektir. Ayrıca, model parametrelerinin dikkatli bir şekilde ayarlanması gerekir, aksi takdirde aşırı uyuma veya düşük performansa neden olabilmektedir. Şekil 3.6’da GBC’nin çalışma prensibini açıklayan şema verilmiştir.



Şekil 3.6. Gradient Boosting Classifier Çalışma Şeması (Zhang ve ark,2021)

Gradient Boosting Classifier, çeşitli alanlarda yaygın olarak kullanılmaktadır. Finans, sağlık, pazarlama ve görüntü işleme gibi alanlarda başarılı sonuçlar verir. Özellikle, kredi riski analizi, hastalık teşhisi, müşteri segmentasyonu, nesne tanıma ve hata analizi gibi uygulamalarda etkilidir.

Gradient Boosting Classifier, güçlü ve esnek bir makine öğrenmesi algoritmasıdır. Zayıf öğrenicilerden güçlü bir model oluşturmak için ardışık olarak eğitilmektedir. Bu süreç, modelin hatalarını kademeli olarak azaltır ve doğruluğunu artırır. Bu çalışmada makine öğrenmesi tekniklerinden Gradient Boosting Classifier algoritması kullanılmıştır. Diğer makine öğrenmesi teknikleri elde edilen veri seti üzerinde denenmiş ancak en başarılı sonuç Gradient Boosting Classifier algoritmasından alınmıştır.


4. MATERYAL VE YÖNTEM

Çalışmanın başlangıcında, çekirdek kısa devresi ve sargı kayması oluşturulan test transformatöründen SFRA ile elde edilen veriler, veri yükleme ve ön işleme aşamaları yer almaktadır. Bu aşamada, ham veriler temizlenmiş ve analiz için uygun hale getirilmiştir. Daha sonra, veriler Excel formatında yüklenmiş ve sınıflara göre ayrılmıştır. Bu işlem, modelin eğitimi için gerekli olan veri setlerinin hazırlanmasını sağlamaktadır. Eğitim ve test verilerinin ayrılması, modelin performansını değerlendirmek açısından kritik bir adım olup overfitting'i önlemeye yönelik bir strateji olarak uygulanmıştır. Model eğitimi sürecinde, Gradient Boosting Classifier algoritması kullanılmıştır. Bu algoritma, karmaşık veri setlerinde yüksek performans elde etmeye yönelik güçlü bir sınıflandırma yöntemidir. Model, eğitim verisi ile eğitilerek veri setindeki örüntüleri öğrenmiştir. Model eğitiminin tamamlanmasının ardından, test verisi üzerinde tahminler yapılmış ve modelin performansı değerlendirilmiştir. Performans değerlendirmesi sırasında, çeşitli metrikler (confusion matrix, accuracy, precision, recall vb.) hesaplanmış ve raporlanmıştır.

Model performansının ayrıntılı analizi için confusion matrix hesaplanmış ve görselleştirilmiştir. Öğrenme eğrisi (learning curve) ve kalibrasyon eğrisi (calibration curve) çizilerek, modelin öğrenme kapasitesi ve kalibrasyonu incelenmiştir. Ayrıca, gain ve lift chart ile KS istatistiği hesaplanarak modelin etkinliği ve ayırım gücü değerlendirilmiştir. Bunun yanı sıra, CAP eğrisi (CAP curve) çizilmiş, MSE ve RMSE değerleri hesaplanarak modelin hataları ölçülmüştür. Yeni veriler üzerinde tahmin yapılarak modelin genelleme yeteneği test edilmiştir. Tahmin sonuçlarının analizi sırasında, en fazla tahmin edilen sınıf belirlenmiş ve raporlanmıştır. Sınıf dağılımı hesaplanarak modelin hangi sınıfa daha fazla eğilim gösterdiği tespit edilmiştir. Analizlerin görselleştirilmesi, elde edilen sonuçların daha anlaşılır hale getirilmesi açısından önem arz etmektedir.

Kullanıcı etkileşimini sağlamak amacıyla, Tkinter kütüphanesi ile grafiksel bir kullanıcı arayüzü (GUI) oluşturulmuştur. Bu arayüz sayesinde, kullanıcı yeni bir Excel dosyası seçerek işlemleri tekrarlayabilmektedir. Sürecin tamamlanmasının ardından

sonular elde edilerek raporlanmıřtır. Bu yapı, veri iřleme, model oluřturma, performans deęerlendirme ve sonuların grselleřtirilmesi gibi kritik adımları kapsamlı bir řekilde ele almaktadır. Bu yaklařım, alıřmanın sistematik ve bilimsel bir řekilde yrtlmesini saęlamaktadır. Bu bilgiler doęrultusunda, alıřmanın tm adımlarını sistematik bir řekilde zetleyen bir akıř diyagramı oluřturulmuř ve řekil 4.1' de paylařılmıřtır.



řekil 4.1. alıřmanın Akıř Diyagramı

4.1. Verilerin Toplanması ve Veri Seti Oluřturulması

4.1.1. SFRA testlerinin yapılması

SFRA testi, trafonun i yapısında meydana gelebilecek olası deformasyonları, sargı kaymalarını, yalıtım problemlerini ve dięer yapısal anormallikleri tespit etmek iin trafonun eřitli frekanslardaki tepki karakteristiklerini lmektedir. SFRA testinin uygulanması, belirli bir prosedr izlenerek gerekleřtirilir. İlk olarak, trafo test iin hazırlanır ve enerjiden izole edilir. Test ekipmanları kurulup, trafoya belirli bir frekans aralığında (genellikle 20 Hz ile 2 MHz arasında) sinyal gnderilir. Bu frekans taraması sırasında trafonun frekans cevabı kaydedilir ve analiz edilir. Elde edilen veriler, referans veriler veya nceki test sonuları ile karřılařtırılarak trafonun mekanik ve elektriksel btnlę deęerlendirilir. Bu sre, trafonun i yapısındaki olası sorunları

belirlemede yüksek hassasiyet ve doğruluk sağlamaktadır (Wang ve ark,2002). Çalışmanın yapılabilmesi için bir test düzeneği oluşturulmuş ve bu düzenek üzerinde SFRA testleri yapılarak veri toplanmıştır (Şekil 4.2 ve Şekil 4.3).




Şekil 4.2. Test Transformatörü Üzerinde Yapılan SFRA Test Düzeneği



Şekil 4.3. SFRA Verilerinin Toplanması İçin Hazırlanan Test Düzeneği

SFRA testi sonuçları genellikle Bode diyagramı olarak sunulmaktadır. Bode diyagramı, bir sistemin frekans cevabını gösteren iki bileşenden oluşur: genlik ve faz grafiği. Genlik grafiğinde frekans yatay ekseninde, genlik ise dikey ekseninde gösterilmektedir. Frekans genellikle logaritmik bir ölçekle, genlik ise desibel (dB) cinsinden ifade edilmektedir. Bu grafik, trafonun belirli frekans aralıklarında sinyali ne kadar ilettiğini veya zayıflattığını gösterir. Genlikteki ani değişiklikler, trafonun iç yapısında meydana gelen olası sorunlara işaret edebilir. Faz grafiğinde ise frekans yine yatay ekseninde, faz dikey ekseninde gösterilir. Frekans logaritmik bir ölçekle, faz ise derece (°) cinsinden ifade edilir. Bu grafik, sinyalin faz kaymasının frekansa bağlı olarak nasıl değiştiğini göstermektedir. Faz kaymasındaki anormallikler, trafonun mekanik yapısındaki potansiyel sorunları belirlemeye yardımcı olabilmektedir. SFRA testi sonuçları Bode diyagramı üzerinde görselleştirilir ve referans veriler veya önceki test sonuçları ile karşılaştırılarak trafonun mekanik ve elektriksel bütünlüğü değerlendirilir. Bu sayede trafonun iç yapısındaki olası problemler erken aşamada tespit edilebilir ve önleyici bakım yapılabilir. Yapılan çalışmada SFRA testlerinin sonuçlarını yorumlayabilmek ve analiz sonuçlarını almak için Omicron programı kullanılmıştır. Omicron programının ara yüzü Şekil 4.4'te verilmiştir.



Şekil 4.4. SFRA İçin Omicron Programı Ara yüzü

4.1.2. Veri ön işleme ve veri setinin oluşturulması

Çalışmada kullanılmış olan veri seti, SFRA testleri sonucunda elde edilmiş verilerden oluşmaktadır. Veri setinde, U1, V1 ve W1 fazlarının her birine ait veriler

bulunmaktadır. Bu veriler, her faz için 1 nötr bağlantısı ile, sargı kayma ve çekirdek hatalarını içermektedir. Aynı zamanda, sağlıklı çalışma durumlarına ait veriler de mevcuttur. Veriler, her faz ve arıza türü için alt ve üst bağlantı noktalarındaki ölçümleri kapsamaktadır. Bu kapsamlı veri seti, her bir fazın farklı arıza türlerine göre nasıl davrandığını analiz etmeye olanak tanırken, sağlıklı durumlarla karşılaştırma yapma imkânı da sunmaktadır. Böylelikle, alt ve üst bağlantı noktalarındaki sargı kayma ve çekirdek hatalarının yanı sıra, sağlıklı bağlantıların frekans yanıtlarını incelemek mümkün hale gelmektedir.

Yazılımda kullanılan veri seti, toplamda 481,000 satır ve 4 sütundan oluşmaktadır. Birinci sütun frekans değerlerini, ikinci sütun genlik ve üçüncü sütun faz değerlerini içermektedir. Dördüncü sütunda ise verilerin etiketlenmiş halleri bulunmaktadır; sağlıklı veriler 0, çekirdek hatası olan veriler 1 ve sargı kayma hatası olan veriler 2 olarak etiketlenmiştir. Yapay zekâ çalışmalarında sınıf etiketleri 0-1-2 şeklinde etiketlenmektedir. Bu işlem, verilerin makine öğrenmesi modelleriyle analiz edilmesini ve sınıflandırma yapılmasını kolaylaştırmaktadır. Harfler ve diğer anlamsız veriler elenmiş, böylece veri seti belirli parametrelere göre işlenip sınıflandırma için uygun hale getirilmiştir. Düzenlenmiş veri setinin bir bölümü örnek olarak Şekil 4.5'te paylaşılmaktadır.

20	-13,19140988	-64,90534704	2
20,6542484	-13,40679406	-65,28220595	2
21,32989884	-13,63252123	-65,67257126	2
22,02765145	-13,85034094	-66,03799568	2
22,74822924	-14,06168523	-66,37562724	2
23,49237886	-14,28400294	-66,73017612	2
24,26087142	-14,49821408	-67,06593114	2
25,05450324	-14,70580709	-67,38010845	2
25,87409667	-14,92522481	-67,70104146	2
26,72050098	-15,13786224	-68,00066894	2
27,59459323	-15,3526881	-68,29596192	2
28,49727915	-15,5692789	-68,57684128	2
29,42949411	-15,78725744	-68,8520183	2
30,39220408	-15,99892159	-69,10787088	2
31,38640662	-16,21907165	-69,36511553	2
32,41313193	-16,43248258	-69,60356147	2
33,47344392	-16,6462943	-69,83361589	2
34,56844127	-16,86795891	-70,0590218	2
35,69925863	-17,08241782	-70,26625695	2
36,86706777	-17,30394092	-70,47161826	2
38,07307877	-17,5178208	-70,66320913	2
39,31854131	-17,73773689	-70,84606466	2
40,60474595	-17,95657501	-71,02404674	2
41,93302545	-18,17392805	-71,18814913	2
43,30475618	-18,39043093	-71,34365989	2
44,72135955	-18,61156907	-71,49414223	2
46,18430344	-18,82463371	-71,62401428	2
47,69510377	-19,04763996	-71,75944542	2
49,25532603	-19,26186481	-71,88278862	2

Şekil 4.5. Düzenlenmiş Veri Setinin Örnek Bir Parçası

Çalışmada veri setinin %43,6'sı test verisi olarak, %56,4'ü eğitim verisi olarak kullanılmıştır.

4.2. Kullanılan Araçlar ve Yazılımlar

4.2.1. Yazılım dili ve çalışmada kullanılan kütüphaneler

Yapılan çalışmada makine öğrenmesi yazılım dili olarak Python kullanılmıştır. Python ve Python kütüphaneleri, makine öğrenmesi ve yapay zekâ çalışmalarında çok kullanışlı ve ergonomiktir. Bunun birkaç temel nedeni vardır. İlk olarak, Python'un sözdizimi basit ve anlaşılırdır. Python'un büyük ve aktif bir kullanıcı topluluğu vardır. Bu topluluk, çok sayıda açık kaynaklı kütüphane ve araç geliştirmiştir. Ayrıca, literatürde ve internette bol miktarda eğitim materyali, dökümantasyon ve forum

bulunmaktadır, bu da karşılaşılan sorunların çözülmesini kolaylaştırmaktadır. Python'un zengin kütüphane ekosistemi de büyük bir avantajdır. Python ayrıca, diğer diller ve platformlarla iyi uyum sağlar ve farklı ortamlarda (masaüstü, web, sunucu vb.) çalışabilir, bu da projelerin ölçeklenebilirliğini arttırmaktadır. Bu nedenlerle, Python ve kütüphaneleri, makine öğrenmesi ve yapay zekâ projelerinde güçlü, esnek ve kullanıcı dostu bir araç seti sunmaktadır.

Çalışmada pandas, matplotlib- seaborn, scikit-learn (Sklearn), tkinter, numpy, time, sklearn.calibration olmak üzere çeşitli Python kütüphaneleri kullanılmış olup her birinin belirli rolü ve işlevi bulunmaktadır (Şekil 4.6). Çalışmada pandas kütüphanesi kullanılmıştır. Çünkü pandas, veri analizi ve veri manipülasyonu için güçlü araçlar sunmaktadır. Pandas, verilerin okunması, yazılması, temizlenmesi ve dönüştürülmesi gibi işlemler için etkili yöntemler sağlamaktadır. Özellikle veri çerçeveleri (dataframes) ile çalışmak, veri setlerini filtrelemek, gruplandırmak ve özetlemek için idealdir. Pandas ile verilerin hızlı ve kolay bir şekilde işlenmesi, büyük veri kümeleriyle çalışırken oldukça yararlıdır ve veri hazırlama sürecini hızlandırır. Ayrıca, pandas ile verilerin eksik değerlerinin doldurulması, yeniden şekillendirilmesi ve dönüştürülmesi gibi işlemler de gerçekleştirilebilir.

```
1
2 import pandas as pd
3 import matplotlib.pyplot as plt
4 import seaborn as sns
5 from sklearn.ensemble import GradientBoostingClassifier
6 from sklearn.metrics import (accuracy_score, precision_score, recall_score, f1_score, confusion_matrix,
7                             roc_curve, auc, precision_recall_curve, average_precision_score)
8 from sklearn.model_selection import learning_curve
9 import tkinter as tk
10 from tkinter import filedialog
11 import time
12 import numpy as np
13 from sklearn.calibration import calibration_curve
14 from sklearn.metrics import roc_curve, auc
15 import matplotlib.pyplot as plt
```

Şekil 4.6. Çalışmada Kullanılan Python Kütüphaneleri

Matplotlib ve seaborn kütüphaneleri, verilerin görselleştirilmesi için kullanılmıştır. Matplotlib.pyplot, verilerin görselleştirilmesi için temel grafikler oluşturmayı sağlamaktadır. Histogramlar, çizgi grafikler, dağılım grafikleri gibi çeşitli grafik türlerini destekler. Bu kütüphane, verilerin görsel olarak incelenmesine ve analiz edilmesine olanak tanımaktadır. Seaborn ise, matplotlib üzerine kurulmuş olup daha gelişmiş ve estetik görselleştirmeler sunar. Seaborn, kategorik verilerin

görselleştirilmesi, dağılım matrisleri ve ısı haritaları gibi ileri düzey grafikler oluşturmak için kullanışlıdır. Bu görselleştirme araçları, veri setlerinin anlaşılması, trendlerin ve desenlerin belirlenmesi ve model sonuçlarının yorumlanması açısından kritik öneme sahiptir.

Scikit-learn (sklearn) kütüphanesi, makine öğrenmesi modellerinin oluşturulması, eğitilmesi ve değerlendirilmesi için kapsamlı araçlar sunar. Bu çalışmada, Gradient Boosting Classifier kullanılmıştır. Bu algoritma, gradyan artırmalı karar ağaçları prensibine dayanarak çalışır ve özellikle karmaşık veri kümelerinde yüksek doğruluk oranları elde etmek için etkilidir. Scikit-learn, ayrıca diğer makine öğrenmesi algoritmalarını ve araçlarını da içerir, bu da model seçimi ve karşılaştırması yapmayı kolaylaştırır. Scikit-learn.metrics modülü, model performansını değerlendirmek için çeşitli metrikler sunar. Bu metrikler arasında doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1 skoru ve ROC eğrisi gibi önemli performans göstergeleri bulunmaktadır. Bu metrikler, modelin başarımını detaylı bir şekilde analiz etmek ve farklı metrikler üzerinden değerlendirmek için kullanılmıştır. Ayrıca, sklearn.model_selection.learning_curve fonksiyonu, modelin farklı eğitim seti boyutları üzerindeki performansını analiz etmeye yardımcı olur, bu da modelin öğrenme sürecini ve aşırı öğrenme (overfitting) veya yetersiz öğrenme (underfitting) durumlarını tespit etmeye yarar.

Tkinter kütüphanesi, kullanıcı arayüzü (GUI) oluşturmak için kullanılmıştır. Bu çalışmada, veri girişi ve model sonuçlarının kullanıcıya sunulması gibi işlemler için basit ve kullanışlı arayüzler oluşturulmuştur. Tkinter, Python ile entegre çalışarak hızlı ve etkili bir şekilde GUI uygulamaları geliştirmeye olanak tanır. Bu sayede, kullanıcıların modeli kolayca kullanabilmesi ve sonuçları anlaması sağlanmıştır. Kullanıcı dostu arayüzler, modelin kullanılabilirliğini artırır ve kullanıcı deneyimini iyileştirir.

Numpy kütüphanesi, sayısal işlemler ve hesaplamalar için kullanılmıştır. Numpy, büyük ve çok boyutlu diziler (arrays) ile çalışma, lineer cebir, Fourier dönüşümleri ve rastgele sayı üretimi gibi matematiksel işlemleri etkin bir şekilde gerçekleştirmeyi sağlar. Özellikle veri manipülasyonu ve bilimsel hesaplamalar sırasında numpy kütüphanesi önemli avantajlar sunmaktadır. Makine öğrenmesi modellerinin eğitiminde ve değerlendirilmesinde numpy dizileri yaygın olarak kullanılmıştır.

Numpy, ayrıca verilerin hızlı bir şekilde işlenmesi ve performansın artırılması için düşük seviyeli optimizasyonlar sunar.

Time kütüphanesi, zamanla ilgili işlemler için kullanılmıştır. Bu çalışmada, kodun çalışma süresinin ölçülmesi, bekleme sürelerinin yönetilmesi ve zaman damgalarının elde edilmesi gibi işlemler için time kütüphanesinden yararlanılmıştır. Performans analizi ve zamanlama gerektiren işlemler için oldukça faydalıdır. Time kütüphanesi ile kodun farklı bölümlerinin ne kadar sürede çalıştığını ölçmek ve performans optimizasyonları yapmak mümkündür.

Sklearn.calibration kütüphanesi, model kalibrasyonu için kullanılmıştır. Kalibrasyon eğrileri, modelin tahmin olasılıklarının ne kadar iyi kalibre edildiğini gösterir. Özellikle ROC (Receiver Operating Characteristic) ve PRC (Precision-Recall Curve) eğrilerinin analiz edilmesi, modelin doğruluk ve güvenilirlik değerlendirilmesinde kritik rol oynamıştır. Kalibrasyon eğrileri, modelin gerçek dünya performansını daha doğru bir şekilde yansıtmalarını sağlar. Bu kütüphane, modelin olasılık tahminlerinin iyileştirilmesi ve daha güvenilir tahminler elde edilmesi için kullanılmıştır. Bu kütüphaneler, makine öğrenmesi sürecinin her aşamasında çeşitli görevleri yerine getirerek çalışmanın başarısını ve doğruluğunu artırmada büyük önem taşımaktadır. Verilerin hazırlanması, modellenmesi, değerlendirilmesi ve görselleştirilmesi gibi adımlar, bu kütüphanelerin sağladığı araçlar sayesinde daha etkili ve verimli bir şekilde gerçekleştirilmiştir. Bu sayede, makine öğrenmesi projelerinde daha sağlam ve güvenilir sonuçlar elde edilmiştir. Bütün bu kullanılan kütüphaneler ile çalışma en verimli, en ergonomik haline getirilmeye çalışılmıştır.

4.2.2. Entegre geliştirme ortamı (IDE)

Çalışmada IDE olarak PyCharm 2023.1.3 versiyon kullanılmıştır. PyCharm, JetBrains tarafından geliştirilen ve Python programlama dili için optimize edilmiş bir entegre geliştirme ortamıdır (IDE). PyCharm, kullanıcı dostu arayüzü, güçlü özellikleri ve geniş eklenti desteği ile Python geliştiricileri arasında oldukça popülerdir. Yapay zekâ ve makine öğrenimi projeleri için PyCharm oldukça uygun bir geliştirme ortamıdır. Python desteği sayesinde, yapay zekâ ve makine öğrenimi alanında en çok kullanılan dillerden biri olan Python'u desteklemektedir. TensorFlow, PyTorch, scikit-learn gibi popüler yapay zekâ kütüphaneleri ile uyumlu çalışır. NumPy, Pandas ve Matplotlib gibi veri analizi ve görselleştirme araçları ile entegre edilebilir. Jupyter Notebook desteği ile interaktif veri analizi ve model geliştirme imkânı sunar. Ayrıca, sanal ortam

yönetimi ile projeler arasında bağımlılık çatışmalarını önler ve temiz bir geliştirme ortamı sağlar (PyCharm).

4.3. Makine Öğrenme Algoritmalarının Değerlendirilmesi

Çalışmada lojistik regresyon (logistic regression), random forest, K-Nearest Neighbors (K-NN), destek vektör sınıflandırma algoritması (Support Vector Classifier SVC), karar ağaçları ve gradient boosting classifier (GBC) olmak üzere 6 tane makine öğrenmesi algoritması üzerine çalışılmış ve elde edilen performans çıktılarına göre “Gradient Boosting Classifier” algoritmasına karar verilmiştir.

Lojistik regresyon, ikili sınıflandırma problemlerinde sıklıkla kullanılan istatistiksel bir modelleme tekniğidir. Bu yöntem, bağımlı değişkenin iki kategoriden biri olduğu durumlarda, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi modellemek amacıyla lojistik (sigmoid) fonksiyonunu kullanmaktadır. Lojistik regresyonun temel amacı, bağımlı değişkenin olasılığını modellemektir; bu bağlamda bağımlı değişken genellikle iki kategoriye ayrılır: 1 (olayın meydana gelmesi) ve 0 (olayın meydana gelmemesi). Model, maksimum olabilirlik yöntemi ile kurulmakta olup, bu yöntem gözlemlenen verilerin en yüksek olasılıkla ortaya çıkmasını sağlayan parametrelerin belirlenmesini hedefler. Eğitim sürecinde, modelin parametreleri (katsayıları) eğitim veri seti kullanılarak tahmin edilmekte ve bu sayede model, bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerini öğrenmektedir. Eğitilmiş model aracılığıyla yeni veri noktalarının hangi kategoriye ait olduğu tahmin edilmekte; bu tahminler 0 ile 1 arasında olasılıklar olarak ifade edilmekte ve genellikle 0.5 eşik değeri kullanılarak sınıflandırılmaktadır. Eğer tahmin edilen olasılık 0.5'in üzerindeyse, olayın meydana geldiği (1) kabul edilmekte; aksi takdirde, olayın meydana gelmediği (0) kabul edilmektedir (Hosmer ve ark,2013). Random Forest Sınıflandırıcısı, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan güçlü bir makine öğrenmesi algoritmasıdır. Bu algoritma, birden fazla karar ağacını bir araya getirerek bir "orman" oluşturur ve her ağacın çıktısını birleştirerek nihai tahmini yapar. Bu yaklaşım, modeli daha sağlam ve genellenebilir hale getirmektedir. Bu yöntem, karar ağaçlarının bireysel zayıflıklarını azaltarak aşırı uyumu (overfitting) önlemektedir. Random Forest, Bagging (Bootstrap Aggregating) adı verilen bir toplu öğrenme (ensemble learning) yöntemine dayanmaktadır. Bagging, birden fazla modelin (bu durumda karar ağaçları) birleştirilerek performansın artırılmasını sağlamaktadır. Her model, orijinal

veri setinden rastgele örnekler alınarak oluşturulan bir alt küme üzerinde eğitilir. Random Forest algoritmasında, her karar ağacı eğitilirken, her düğümde en iyi bölünmeyi bulmak için özelliklerin rastgele bir alt kümesi kullanılmaktadır. Bu, ağaçlar arasında daha fazla çeşitlilik sağlar ve modelin genelleme yeteneğini artırır (Ho,1995). Sınıflandırma problemlerinde, çoğunluk oylaması ile nihai tahmin yapılır. Regresyon problemlerinde ise, ağaçların tahminlerinin ortalaması alınmaktadır (Ho,1995) (Cover ve ark,1967). K-Nearest Neighbors (K-NN) algoritması hem sınıflandırma hem de regresyon problemlerinde kullanılan örnek tabanlı bir makine öğrenmesi yöntemidir. Bir veri noktasının sınıfını veya değerini belirlemek için, o noktaya en yakın k komşusunun sınıflarına veya değerlerine bakar. Eğitim aşamasında herhangi bir model oluşturmaz; bunun yerine tüm eğitim verilerini bellekte tutar ve tahmin aşamasında bu verileri kullanır. Büyük veri setlerinde yüksek bellek kullanımı ve yavaş tahmin süresi gibi dezavantajları bulunmaktadır. Görüntü tanıma, metin sınıflandırma ve tavsiye sistemleri gibi birçok alanda yaygın olarak kullanılan bu yöntem, basitliği ve esnekliği ile makine öğrenmesi uygulamalarında önemli bir rol oynamaktadır (Cortes ve ark,1995). Destek Vektör Sınıflandırma (Support Vector Classifier - SVC), sınıflandırma problemlerinde yaygın olarak kullanılan güçlü ve esnek bir makine öğrenmesi algoritmasıdır. Veri ön işleme adımları gerektiren özelliklerin farklı ölçeklerde olması performansı olumsuz etkileyebilmektedir (Scholkopf ve ark,2002) (Suthaharan,2016). Karar ağaçları, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan güçlü bir makine öğrenmesi algoritmasıdır. Bu algoritma, verileri sınıflandırmak için bir dizi karar kuralı oluşturur ve bu kurallar çerçevesinde verileri dallar ve yapraklar şeklinde yapılandırır. Karar ağaçlarının sonuçları kolaylıkla anlaşılabilir ve görselleştirilebilir, bu da modelin açıklanmasını ve yorumlanmasını kolaylaştırmaktadır. Bu algoritma, normalizasyon veya standardizasyon gibi veri ön işleme adımlarına genellikle ihtiyaç duymaz, bu da veri hazırlık sürecini daha az zahmetli hale getirir. Karar ağaçları hem sınıflandırma hem de regresyon problemlerinde kullanılabilir, bu da onları çok yönlü bir araç yapmaktadır (Suthaharan,2016). Gradient Boosting Classifier (GBC), makine öğrenmesi alanında güçlü bir topluluk öğrenme (ensemble learning) yöntemidir. Bu yöntem, zayıf öğreniciler olarak adlandırılan bir dizi karar ağacını ardışık olarak eğiterek, hataları kademeli olarak azaltmak suretiyle güçlü bir öğrenici oluşturur. Her adımda mevcut modelin tahmin hatalarını hedefleyen bir ağaç eklenir ve bu ağaç, hataları gradyan yönünde düzeltilir. Gradient Boosting Classifier, yüksek doğruluk

sağlar ve aşırı uyuma karşı dirençlidir. Model, karmaşık veri yapılarını öğrenebilir ve çok sayıda özellik ile çalışabilir. Ayrıca, farklı kayıp fonksiyonları ve zayıf öğrenicilerle kullanılabilecek esnek bir modeldir (Friedman,2001).

Yapılan çalışmada, Gradient Boosting Classifier algoritması, veri seti üzerinde test edilen diğer makine öğrenmesi teknikleri arasında en başarılı sonuçları vermiştir. Gradient Boosting Classifier (GBC) yönteminin bir diğer önemli özelliği, yalnızca ikili değil, aynı zamanda üçlü metriklerde üstün performans göstermesidir. Bu çalışmada üç farklı etiket değeri bulunduğundan, Gradient Boosting Classifier (GBC) yöntemi daha başarılı bir sonuç elde etmektedir Algoritmaların performans sonuçları Tablo 4.1’de verildiği gibidir.

Tablo 4.1. Farklı algoritmaların performans sonuçları.

Performans Sonuçları Tablosu	Genel Doğruluk (Accuracy)	Genel Hassasiyet (Precision)	Genel Duyarlılık (Recall)	Genel F-1 Ölçümü (F1-Score)
Logistic Regression	0.7768	0.7996	0.7927	0.7924
Random Forest Classifier	0.8868	0.8928	0.8815	0.8522
K-Nearest Neighbors	0.6941	0.6635	0.6814	0.6855
Support Vector Classifier	0.8569	0.8535	0.8911	0.8552
Decision Tree Classifier	0.7961	0.7954	0.7740	0.7813
Gradient Boosting Classifier	0.9142	0.9205	0.9142	0.9141

Makine öğrenmesi çalışmalarında, bir modelin başarısını değerlendirmek için çeşitli performans metrikleri kullanılmaktadır. Bu çalışmada, SFRA testlerinden elde edilen trafo verilerini kullanarak arıza tespiti yapmak amacıyla altı farklı sınıflandırma algoritması denenmiş ve her bir modelin performansını değerlendirmek için genel doğruluk (Accuracy), genel hassasiyet (Precision), genel duyarlılık (Recall) ve genel F1 ölçümü (F1-Score) parametreleri kullanılmıştır. Bu metrikler, makine öğrenmesi çalışmalarında yaygın olarak kullanılan ve modelin doğruluğunu, yanlış pozitif ve yanlış negatif oranlarını ve genel denge performansını değerlendirmemizi sağlayan kritik göstergelerdir. Genel doğruluk (accuracy), makine öğrenmesi ve sınıflandırma problemlerinde model performansını değerlendirmek için yaygın olarak kullanılan bir metriktir. Bu metrik, modelin doğru tahmin ettiği örneklerin toplam örnek sayısına oranını ifade eder ve modelin hem pozitif hem de negatif sınıflar için doğru

tahminlerde bulunma kapasitesini göstermektedir. Doğruluk metriği, modelin genel performansını hızlı ve basit bir şekilde değerlendirmeye olanak tanımaktadır. Doğruluk değerinin 1'e yakın olması istenilen çıktıdır. Doğruluk metriği akademik literatürde makine öğrenmesi modellerinin karşılaştırılmasında temel bir metrik olarak sıkça yer almaktadır (Sarker,2021). Çalışmada; bu performans metriği, 6 farklı makine öğrenmesi algoritması arasından en yüksek GBC algoritmasında bulunmaktadır. Gradient boosting classifier algoritmasında doğruluk değeri 0.9142'dir.

Genel hassasiyet (precision), makine öğrenmesi ve sınıflandırma problemlerinde model performansını değerlendirmek için kullanılan önemli bir metriktir. Bu metrik, modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu göstermektedir. Yani, modelin pozitif sınıf tahminlerinin doğruluk oranını ölçer. Precision, yanlış pozitiflerin (false positives) oranını azaltmayı hedefler ve özellikle yanlış pozitiflerin maliyetli olduğu durumlarda önemlidir. Hassasiyet metriği, modelin pozitif tahminlerinin ne kadar doğru olduğunu ölçerek, yanlış pozitiflerin düşük olmasını sağlamaktadır (Ting,2011). Hassasiyet değerinin 1'e yakın olması beklenmektedir. Çalışmada; bu performans metriği, 6 farklı makine öğrenmesi algoritması arasından en yüksek GBC algoritmasında bulunmaktadır. Gradient boosting classifier algoritmasında hassasiyet değeri 0.9205'tir.

Genel duyarlılık (recall), makine öğrenmesi ve sınıflandırma problemlerinde model performansını değerlendirmek için kullanılan önemli bir metriktir. Recall, modelin gerçek pozitif örneklerin ne kadarını doğru bir şekilde pozitif olarak tahmin ettiğini göstermektedir. Yani, yüksek duyarlılık, modelin gerçek pozitifleri kaçırmamasını sağlamaktadır. Bu metrik, özellikle yanlış negatiflerin (false negatives) oranını azaltmayı hedefler. Akademik çalışmalarda, duyarlılık metriği, makine öğrenmesi modellerinin performansını değerlendirirken sıklıkla kullanılır ve diğer metriklerle (örneğin, hassasiyet) birlikte değerlendirildiğinde, modelin genel performansı hakkında daha dengeli ve kapsamlı bir analiz yapılmasına olanak tanımaktadır (Ting,2011). Duyarlılık değerinin 1'e yakın olması beklenmektedir. Çalışmada; bu performans metriği, 6 farklı makine öğrenmesi algoritması arasından en yüksek GBC algoritmasında bulunmaktadır. Gradient boosting classifier algoritmasında hassasiyet değeri 0.9142'tir.

Genel F-1 Ölçümü (F1-Score), makine öğrenmesi ve sınıflandırma problemlerinde model performansını değerlendirmek için kullanılan önemli bir metriktir. F1-Score,

hassasiyet (precision) ve duyarlılık (recall) metriklerinin harmonik ortalamasıdır ve modelin bu iki metriği dengeli bir şekilde değerlendirmesini sağlamaktadır. Bu metrik, özellikle sınıflar arasında dengesizlik olduğunda kullanışlıdır çünkü modelin hem pozitif örnekleri doğru yakalama kapasitesini (recall) hem de yanlış pozitif tahminlerden kaçınma kapasitesini (precision) dikkate almaktadır. F1-Score, 0 ile 1 arasında bir değer alır ve 1'e yakın olması, modelin hem yüksek hassasiyet hem de yüksek duyarlılık gösterdiği anlamına gelir. F1-Score, özellikle sınıf dengesizliği olan veri setlerinde doğruluğa (accuracy) göre daha güvenilir bir performans ölçütü sağlar çünkü modelin hem pozitif tahminlerinin doğruluğunu hem de pozitif örnekleri yakalama yeteneğini dengeler (Ting,2011). Çalışmada; bu performans metriği, 6 farklı makine öğrenmesi algoritması arasından en yüksek GBC algoritmasında bulunmaktadır. Gradient boosting classifier algoritmasında hassasiyet değeri 0.9141'tir.

```
# Gradient Boosting sınıflandırıcısını oluştur ve e it
gb_classifier = GradientBoostingClassifier(n_estimators=100, learning_rate=0.6, max_depth=8, random_state=5)
gb_classifier.fit(X_train, y_train)
print("A  e itimi tamamlandı..")
# Test seti  zerinde modelin performansını de erlendir
tahminler_test = gb_classifier.predict(X_test)
prob_test = gb_classifier.predict_proba(X_test)[: , 1]
```


 ekil 4.7. Gradient Boosting Sınıflandırıcısının Oluşturulması ve E itimi

T m bu sonu lar de erlendirildi inde  alı ma i in en uygun ve en iyi modelin GBC oldu u uygun g r lm  t r.  alı mada kullanılan GBC modeli i in yazılan yazılım  ekil 4.7'de verilmektedir.

4.4. Model Performansının De erlendirilmesi

4.4.1. Hata matrisi (confusion matrix) analizi

Hata matrisi (confusion matrix), makine   renimi ve istatistik alanlarında sınıflandırma modellerinin performansını de erlendirmek i in kullanılan temel ve kritik bir ara tır. Bu matris, modelin tahmin etti i sınıflarla ger ek sınıflar arasındaki ili kiyi g rsel olarak sunarak, sınıflandırma performansını detaylı bir  ekilde analiz etmemize olanak tanımaktadır (Alsallakh,2020). Hata matrisinin  rnek yapısı  ekil 4.8'de verilmektedir.



Şekil 4.8. Hata Matrisinin Yapısı (Yalman ve ark,2022)

Özellikle dengesiz veri kümelerinde, modelin nerelerde hata yaptığını belirlemek ve bu hataların doğasını anlamak için hayati öneme sahiptir. İkili sınıflandırma problemlerinde confusion matrisi dört ana bileşenden oluşur: doğru pozitifler (True Positives, TP), doğru negatifler (True Negatives, TN), yanlış pozitifler (False Positives, FP) ve yanlış negatifler (False Negatives, FN). Bu bileşenler, doğruluk (4.1), hassasiyet (4.2), duyarlılık (4.3) gibi çeşitli performans metriklerinin hesaplanmasına olanak tanımaktadır.

$$\frac{TP+TN}{TP+TN+FP+FN} \quad (4.2)$$

$$\frac{TP}{TP + FP} \quad (4.2)$$


$$\frac{TP}{TP + FN} \quad (4.3)$$

Hata matrisi, çok sınıflı ve çok etiketli sınıflandırma problemlerinde de yaygın olarak kullanılabilir. Çok sınıflı problemler için matrisin boyutu $n \times n$ olur, burada n sınıf sayısını temsil etmektedir (Alsallakh,2020). Bu tür matrislerde her hücre, belirli bir sınıfın gerçek örneklerinin başka bir sınıf olarak tahmin edilme sayısını göstermektedir. Örneğin, üç sınıflı bir problemde, matrisin 3×3 boyutunda olması ve

her bir hücrenin yanlış veya doğru sınıflandırma sayısını göstermesi beklenir. Çok etiketli sınıflandırmalarda ise her bir örneğin birden fazla etiketi olabilir ve confusion matrisi bu durumu da göz önünde bulunduracak şekilde genelleştirilebilir. Bu tür matrisler, her bir etiketin doğru veya yanlış sınıflandırılma sayısını gösterebilir ve model performansını daha iyi anlamak için önemlidir. Günümüzde, confusion matrisinin daha karmaşık sınıflandırma senaryolarına uyarlanması üzerine çeşitli araştırmalar yapılmaktadır. Örneğin, hiyerarşik sınıflandırmalarda, hiyerarşik yapıda olan veri setlerinde sınıflar arasında bir hiyerarşi bulunur ve confusion matrisi bu hiyerarşiyi dikkate alacak şekilde uyarlanabilir. Bu, daha detaylı ve anlamlı performans değerlendirmeleri yapılmasını sağlamaktadır. Probabilistik yaklaşımlarla ise confusion matrisleri, sınıflandırıcı değişkenliğini ve belirsizliğini değerlendirmek için probabilistik yaklaşımlar kullanılarak genişletilebilir (Krstinić,2020). Bu, tahminlerin her zaman ikili veya kategorik olmadığı, belirsizlik derecelerini içerdiği durumlarda özellikle önemlidir. Bu yaklaşımlar, modelin performansını daha esnek ve kapsamlı bir şekilde değerlendirmeye olanak tanır.

Gerçekleştirilen çalışmada confusion matrisi kullanılmasının birkaç temel nedeni bulunmaktadır. Öncelikle, confusion matrisi modelimin performansını sadece genel doğrulukla sınırlı kalmadan, yanlış pozitifler ve yanlış negatifler gibi hataları detaylı bir şekilde incelemeye olanak tanımaktadır. Bu, modelin güçlü ve zayıf yönlerini daha iyi anlamamızı sağlamaktadır. Çalışmada kullanılan veri kümeleri dengesiz olabilir ve bu durum, doğru performans değerlendirmesi yapabilmek için confusion matrisinin kullanılmasını gerektirir. Dengesiz veri kümelerinde genel doğruluk yanıltıcı olabilir, ancak confusion matrisi her bir sınıf için ayrı ayrı performans ölçümleri sağlamaktadır. Ayrıca, hangi tür hataların (yanlış pozitifler veya yanlış negatifler) daha fazla olduğunu görmek, modeli nasıl iyileştirebileceğime dair önemli ipuçları sağlamaktadır. Örneğin, hassasiyeti artırmak için yanlış pozitifleri azaltmak veya duyarlılığı artırmak için yanlış negatifleri azaltmak üzere model üzerinde ayarlamalar yapılabilmektedir.

Çalışmada trafolarla yapılan SFRA test verileri kullanılarak trafo arızaları tespit edilmeye çalışılmaktadır. Çalışma kapsamında sağlıklı veriler, sargı kayma hataları ve çekirdek hataları olmak üzere üç sınıf bulunmaktadır. En yüksek doğruluğa sahip algoritmanın (GBC) performansı confusion matrisi ile değerlendirilmiştir. Çalışmanın çıktısına ilişkin confusion matrisi Şekil 4.9’da verilmiştir.



Şekil 4.9. Çalışmaya Ait Hata Matrisi


Hata matrisinin her bir hücresinde modelin doğru veya yanlış sınıflandırma sayıları belirtilmiştir. Sağlıklı veriler için (Sınıf 0), 70 veri noktasının 69'u doğru sınıflandırılmış ve sadece 1'i yanlış sargı kayma hatası olarak sınıflandırılmıştır. Sargı kayma hataları için (Sınıf 1), 70 veri noktasının 58'i doğru sınıflandırılmış, 11'i yanlış sağlıklı veri ve 1'i çekirdek hatası olarak sınıflandırılmıştır. Çekirdek hataları için (Sınıf 2), 70 veri noktasının 65'i doğru sınıflandırılmış, 2'si sağlıklı veri ve 3'ü sargı kayma hatası olarak sınıflandırılmıştır.

Modelin genel doğruluğu, tüm doğru sınıflandırmaların toplam sınıflandırma sayısına oranı olarak hesaplanmıştır ve yaklaşık %91,4 olarak bulunmuştur. Sınıf bazında hassasiyet ve duyarlılık oranları da değerlendirilmiştir. Sağlıklı veriler için hassasiyet %85 ve duyarlılık %98,6, sargı kayma hataları için hassasiyet %93,6 ve duyarlılık %82,9, çekirdek hataları için ise hassasiyet %92,9 ve duyarlılık %92,8 olarak hesaplanmıştır.

4.4.2. Çalışma sonucunda elde edilen performans değerlendirme grafikleri

Öğrenme eğrisi grafiği, bir makine öğrenimi modelinin performansını değerlendirmek için önemli bir araçtır. Bu grafik, eğitim setinin boyutuna bağlı olarak modelin eğitim ve doğrulama doğruluğunu gösterir. Öğrenme eğrisi, modelin genelleme yeteneğini ve aşırı öğrenme (overfitting) veya eksik öğrenme (underfitting) durumlarını belirlemede

kullanılmaktadır. Özellikle, eğitim doğruluğu ve çapraz doğrulama doğruluğu arasındaki farklar, modelin genelleme kabiliyetini göstermektedir. Eğitim seti boyutunun artırılmasıyla doğrulama doğruluğunun nasıl değiştiğini gözlemleyerek, modelin daha fazla veriye ihtiyaç duyup duymadığını veya hiperparametrelerin yeniden ayarlanması gerekip gerekmediğini belirlemek mümkündür (Perlich ve ark,2003).



Şekil 4.10. Öğrenme Eğrisi Grafiği (Learning Curve)


Grafikte görülen (Şekil 4.10) X eksenini, eğitim verisi sayısını temsil ederken, Y eksenini modelin doğruluk oranını (accuracy) göstermektedir. Kırmızı çizgi, modelin eğitim setindeki doğruluk oranını, yeşil çizgi ise çapraz doğrulama setindeki doğruluk oranını temsil etmektedir.

Eğitim skoru neredeyse 1.0'a yakındır, bu durum modelin eğitim setinde oldukça yüksek bir performans sergilediğini ve hatta aşırı öğrenme (overfitting) problemi yaşadığını göstermektedir. Eğitim setindeki doğruluk oranının 1.0'a yakın olması, modelin eğitim verisinde aşırı öğrenme yapabileceğini gösterebilir, ancak bu her zaman böyle değildir. Overfitting'i doğrulamak için doğrulama hatasının yüksek olup olmadığına da bakmak gerekmektedir. Eğitim hatası yok denecek kadar azdır. Diğer yandan, çapraz doğrulama skoru eğitim örneklerinin sayısı arttıkça yükselmektedir. Bu, modelin genelleme kabiliyetinin eğitim veri seti arttıkça arttığını ve modelin başlangıçta yetersiz veri nedeniyle düşük performans sergilediğini, ancak daha fazla

veri ile performansının iyileştiğini göstermektedir. Eğitim skoru ile doğrulama skoru arasında belirgin bir fark bulunmaktadır. Eğitim skoru yüksek kalırken doğrulama skoru belirgin şekilde daha düşüktür ki bu durum overfitting göstergesidir. Model, eğitim verisine çok iyi uyum sağlarken, yeni verilere yeterince iyi genelleymemektedir. Eğitim verisi arttıkça doğrulama skoru iyileşmekte ancak hala eğitim skoruna ulaşamamaktadır. Bu, overfitting'in devam ettiğini ancak daha fazla veri ile bu durumun azalabileceğini göstermektedir.

Kalibrasyon eğrisi, makine öğrenimi modellerinin tahmin ettiği olasılıkların gerçek olasılıklarla ne kadar uyumlu olduğunu değerlendiren önemli bir grafiksel analiz yöntemidir. Bu grafik, özellikle sınıflandırma problemlerinde modelin tahminlerinin ne kadar güvenilir olduğunu belirlemek için kullanılmaktadır (Perlich ve ark,2003).

Kalibrasyon eğrisi, modelin tahmin ettiği olasılıkları gerçek sonuçlarla karşılaştırarak, modelin kalibre edilip edilmediğini anlamamıza yardımcı olur. İdeal bir durumda, kalibrasyon eğrisi $y = x$ doğrusunu takip etmektedir. Bu doğru, modelin tahmin ettiği olasılıkların tam olarak gerçek olasılıklarla örtüştüğü anlamına gelmektedir. Örneğin, bir model belirli bir sınıf için %70 olasılık veriyorsa, bu durumda kalibrasyon eğrisinde bu nokta, gerçekten %70 doğruluğa sahip olmalıdır. Kalibrasyon eğrisinin $y = x$ doğrusunu takip etmesi, modelin verdiği tahminlerin gerçek dünyadaki sonuçlarla uyumlu olduğunu gösterir. Bu durum, modelin güvenilirliğini ve doğruluğunu artırır, çünkü modelin tahminlerine güven duyulabileceğini gösterir. Kalibrasyon eğrisinin bu doğruyu takip etmemesi durumunda ise modelin tahminlerinde bir yanlışlık veya hata olduğu anlaşılır ve bu durumda modelin kalibre edilmesi veya yeniden eğitilmesi gerekebilir. Bu bağlamda, kalibrasyon eğrileri modelin hem doğru tahminlerde bulunma kabiliyetini hem de bu tahminlerin gerçek dünyada nasıl performans gösterdiğini analiz etmede hayati bir rol oynamaktadır. Doğru kalibre edilmiş bir model, karar destek sistemlerinde daha güvenilir ve etkili sonuçlar üretir, bu da uygulama alanında büyük bir avantaj sağlamaktadır (Perlich ve ark,2003).



Şekil 4.11. Kalibrasyon Eğrisi Grafiği (Calibration Curve)

İdeal bir kalibrasyon eğrisi, tahmin edilen olasılıklar ile gerçek olasılıklar arasında doğrusal bir ilişki gösterir ve bu doğrusal ilişki "Perfectly Calibrated" etiketiyle gösterilen kesikli çizgi üzerinde yer almaktadır. Bu doğrusal ilişki, modelin kalibrasyonunun mükemmel olduğunu ve tahmin edilen olasılıkların gerçek olasılıklarla uyumlu olduğunu gösterir. Çalışma için oluşturulan grafikte, üç sınıf (Class 0, Class 1 ve Class 2) için ayrı ayrı kalibrasyon eğrileri çizilmiştir (Şekil 4.11).


Class 0 için kalibrasyon eğrisi (mavi çizgi), düşük olasılık değerlerinde (0.0- 0.4 aralığında) gerçek olasılıkları önemli ölçüde küçümsemektedir. Bu durum, modelin düşük olasılıklar için aşırı güvenli olduğunu ve birçok pozitif örneği kaçırdığını gösterir. 0.5 olasılık değerinden itibaren ise modelin tahminleri daha iyi uyum göstermekte, ancak yine de mükemmel kalibrasyondan sapmalar bulunmaktadır.

Class 1 için kalibrasyon eğrisi (turuncu çizgi) genel olarak daha iyi kalibre edilmiştir. Bununla birlikte, 0.2- 0.4 aralığında modelin tahminleri gerçek olasılıkları küçümsemekte ve 0.6 civarında ise modelin tahminleri gerçek olasılıkları olduğundan fazla tahmin etmektedir. Bu durum, modelin bu aralıkta aşırı güvenli olduğunu ve yüksek olasılıklar atayarak hataya yol açabileceğini göstermektedir. Yüksek olasılık değerlerinde ise modelin kalibrasyonu daha iyi bir uyum göstermektedir, bu da modelin yüksek güvenilirlikteki tahminlerinin daha doğru olduğunu işaret etmektedir.

Class 2 için kalibrasyon eğrisi (yeşil çizgi), başlangıçta düşük olasılık değerlerinde mükemmel bir kalibrasyon sergilemektedir. Bu, modelin düşük olasılık değerlerinde gerçek olasılıkları doğru tahmin ettiğini gösterir. Ancak, 0.4- 0.6 aralığında modelin

tahminleri gerçek olasılıkları büyük ölçüde küçümsemekte ve 0.8'den sonra ise modelin tahminleri gerçek olasılıklarla daha iyi uyum göstermektedir. Bu durum, modelin belirli bir aralıktaki olasılıkları küçümsediğini ve bu nedenle hatalı düşük olasılıklar atayarak pozitif örnekleri kaçırabileceğini göstermektedir.


Kazanım grafiği, bir modelin belirli bir hedefe yönelik kümülatif başarı oranını gösterir. Bu grafik, veri kümesinin belirli bir yüzdesine karşılık gelen kümülatif doğru pozitiflerin yüzdesini temsil etmektedir. Kazanım grafiği, modelin hedef kitlenin doğru belirlenmesindeki etkinliğini ve performansını ölçmek için kullanılmaktadır. Grafik, modelin kümülatif doğru pozitif oranını rastgele seçimlerle karşılaştırarak, modelin üstünlüğünü görselleştirir (Anzanello ve ark,2011).




Şekil 4.12. Kazanım Grafiği (Gain Chart)

Grafikteki (Şekil 4.12) yatay eksen, kümülatif veri yüzdesini (cumulative data fraction) temsil ederken, dikey eksen, kümülatif doğru tahminlerin yüzdesini (cumulative response) göstermektedir. Mavi çizgi, modelin tahminlerine dayalı olarak elde edilen kazanımı gösterirken, kesikli siyah çizgi, rastgele bir modelin performansını temsil etmektedir. Grafikte görüldüğü gibi, modelin çizgisi (mavi çizgi), rastgele model çizgisinden (kesikli siyah çizgi) yukarıda kaldığı sürece, modelin rastgele bir seçimden daha iyi performans gösterdiği anlaşılmaktadır. Bu, modelin hedeflenen doğru pozitifleri daha yüksek bir doğruluk oranıyla yakaladığını göstermektedir.


KS istatistiği, bir modelin ayırt etme gücünü ölçmek için kullanılan bir metottur. Bu istatistik, modelin doğru pozitif oranı (TPR) ile yanlış pozitif oranı (FPR) arasındaki maksimum farkı temsil etmektedir. KS istatistiği grafiği, eşik değerlerine karşılık gelen TPR ve FPR eğrilerini gösterir. KS değeri ne kadar yüksekse, modelin performansı o kadar iyidir (Berger ve ark,2014).



Şekil 4.13. Sınıf 0 İçin KS İstatistiği (Kolmogorov-Smirnov) Grafiği



Şekil 4.14. Sınıf 1 İçin KS İstatistiği (Kolmogorov-Smirnov) Grafiği




Şekil 4.15. Sınıf 2 İçin KS İstatistiği (Kolmogorov-Smirnov) Grafiği

Class 0 (Şekil 4.13), Class 1 (Şekil 4.14) ve Class 2 (Şekil 4.15) için ayrı ayrı KS eğrisi grafikleri çizilmiştir. Class 0 (Şekil 4.13) için KS eğrisi, modelin eşik değerine bağlı olarak TPR ve FPR oranlarını göstermektedir. Grafikte, TPR'nin (mavi çizgi) yüksek seviyelerde kaldığı, ancak eşik değeri arttıkça azaldığı gözlemlenmektedir. Aynı zamanda, FPR (kırmızı çizgi) eşik değeri düşükken yüksektir ve eşik değeri arttıkça sıfıra yaklaşmaktadır. Bu durum, modelin düşük eşik değerlerinde yanlış pozitif oranının yüksek olduğunu ancak doğru pozitif oranının da yüksek olduğunu gösterir. Eşik değeri arttıkça, model daha seçici hale gelir ve yanlış pozitif oranı düşerken doğru pozitif oranı da düşer. Class 0 için KS istatistiği, TPR ve FPR arasındaki en büyük farkı temsil eder ve bu fark modelin ayırtırma gücünü göstermektedir.


Class 1 (Şekil 4.14) için KS eğrisi de benzer bir yapı sergilemektedir. Yine, TPR (mavi çizgi) başlangıçta yüksekken, eşik değeri arttıkça azalmaktadır. FPR (kırmızı çizgi) ise düşük eşik değerlerinde yüksek olup, eşik değeri arttıkça düşmektedir. Bu eğri, modelin düşük eşik değerlerinde yanlış pozitif oranının yüksek olduğunu, ancak doğru pozitif oranının da yüksek olduğunu göstermektedir. Class 1 için KS istatistiği, TPR ve FPR arasındaki maksimum farkı temsil eder ve modelin bu sınıf için ayırt edici yeteneğini gösterir.

Class 2 (Şekil 4.15) için KS eğrisi, diğer sınıflara benzer bir desen izlemektedir. TPR (mavi çizgi) başlangıçta yüksek olup, eşik değeri arttıkça azalmaktadır. FPR (kırmızı çizgi) ise düşük eşik değerlerinde yüksek olup, eşik değeri arttıkça düşmektedir. Bu eğri, modelin düşük eşik değerlerinde yanlış pozitif oranının yüksek olduğunu, ancak doğru pozitif oranının da yüksek olduğunu göstermektedir. Class 2 için KS istatistiği, TPR ve FPR arasındaki maksimum farkı temsil eder ve modelin bu sınıf için ayırt edici yeteneğini gösterir.


Kümülatif doğruluk eğrisi (Cumulative Accuracy Profile, CAP), bir makine öğrenimi modelinin doğruluk profilini değerlendirmek için kullanılan önemli bir araçtır. Bu grafik, veri setinin belirli bir yüzdesiyle elde edilen doğru pozitiflerin kümülatif yüzdesini gösterir ve bu sayede modelin belirli bir veri yüzdesi ile ne kadar doğru tahminler yapabileceği anlaşılmaktadır. Grafikteki eğrinin rastgele modelden ne kadar uzaklaştığı, modelin doğruluk oranını yansıtır. Rastgele model çizgisi genellikle bir referans çizgisi olarak kullanılır ve modelin performansının bu referans çizgisine göre ne kadar üstün olduğunu göstermeyi amaçlar. Eğrinin referans çizgisinden uzaklaşması, modelin daha yüksek bir doğrulukla tahminlerde bulunduğunu ve daha etkili bir performans sergilediğini göstermektedir. CAP eğrisi, modelin kümülatif doğruluk profilini görselleştirerek, model performansının anlaşılmasını ve değerlendirilmesini kolaylaştırmaktadır. Bu grafik, özellikle modelin karar destek sistemlerindeki güvenilirliğini artırmak için kullanılır ve modelin genel başarısı hakkında derinlemesine bilgi sağlamaktadır.



Şekil 4.16. Sınıf 0 İçin Kümülatif Doğruluk Eğrisi CAP (Cumulative Accuracy Profile)



Şekil 4.17. Sınıf 1 İçin Kümülatif Doğruluk Eğrisi CAP (Cumulative Accuracy Profile)



Şekil 4.18. Sınıf 2 İçin Kümülatif Doğruluk Eğrisi CAP (Cumulative Accuracy Profile)

Class 0 (Şekil 4.16), Class 1 (Şekil 4.17) ve Class 2 (Şekil 4.18) için ayrı ayrı CAP eğrisi grafikleri çizilmiştir. Class 0 (Şekil 4.16) için CAP eğrisi grafiği, modelin eşik değerine bağlı olarak kümülatif veri fraksiyonu ve kümülatif yanıt oranını göstermektedir. Grafikte, mavi çizgi modelin performansını temsil ederken, kesikli siyah çizgi rastgele bir modelin performansını göstermektedir. Mavi çizgi, başlangıçta hızlı bir artış göstermekte ve veri fraksiyonunun yaklaşık %40'ında kümülatif yanıt oranının %100'e ulaştığı görülmektedir. Bu, modelin Class 0 için yüksek doğrulukla pozitif örnekleri tespit edebildiğini ve rastgele bir modele göre çok daha iyi performans gösterdiğini göstermektedir. Grafikteki dik artış, modelin bu sınıfta güçlü bir ayırtırma yeteneğine sahip olduğunu göstermektedir.


Class 1 (Şekil 4.17) için CAP eğrisi de benzer bir yapı sergilemektedir. Mavi çizgi, veri fraksiyonunun yaklaşık %40'ında kümülatif yanıt oranının %100'e ulaştığını göstermektedir. Bu durum, modelin Class 1 için de yüksek doğrulukla pozitif örnekleri tespit edebildiğini ve rastgele bir modele göre çok daha iyi performans gösterdiğini ortaya koymaktadır. Modelin kümülatif yanıt oranı, veri fraksiyonunun başlangıcında hızlı bir artış göstermekte ve bu da modelin pozitif örnekleri etkin bir şekilde ayırt edebildiğini göstermektedir. Ancak, dikkat edilmesi gereken önemli bir nokta, başlangıçta dik bir artış olmasına rağmen, Class 0'a kıyasla daha yumuşak bir eğilim

izleniyor olmasıdır. Bu, Class 1 için ayırıştırma gücünün Class 0'a göre biraz daha düşük olabileceğini gösterebilir.

Class 2 (Şekil 4.18) için CAP eğrisi grafiği de benzer bir eğilim göstermektedir. Mavi çizgi, veri fraksiyonunun yaklaşık %40'ında kümülatif yanıt oranının %100'e ulaştığını göstermektedir. Bu, modelin Class 2 için de yüksek doğrulukla pozitif örnekleri tespit edebildiğini ve rastgele bir modele göre çok daha iyi performans gösterdiğini işaret etmektedir. Sonuç olarak, her üç sınıf için de CAP eğrileri modelin pozitif örnekleri yüksek doğrulukla tespit edebildiğini ve rastgele bir modele kıyasla önemli ölçüde daha iyi performans gösterdiğini ortaya koymaktadır.

4.5. Çalışma Sonucunda Elde Edilen Karşılaştırma Grafikleri

Çalışmada sağlıklı bir trafonun frekans-genlik grafiği ile durumu değerlendirilmek üzere seçilen bir trafonun frekans-genlik grafiği karşılaştırılmıştır. Grafik, iki veri setini aynı eksenler üzerinde göstererek farklılıkların ve benzerliklerin görsel olarak analiz edilmesini sağlar. Siyah çizgi, sağlıklı trafoya ait frekans-genlik ilişkisini temsil ederken, kırmızı kesik çizgi seçilen trafonun verilerini göstermektedir. Bu tür karşılaştırmalar, trafoların sağlık durumunun değerlendirilmesinde ve potansiyel arızaların erken tespitinde kritik öneme sahiptir. Analiz sonucunda, seçilen trafonun sağlıklı olup olmadığına dair daha kesin bir yargıya varılabilir. Bu yöntem, trafoların güvenilirlik ve performanslarının sürekli izlenmesi açısından büyük bir fayda sağlamaktadır.



Şekil 4.19. 1U-1N Test Verisine Ait Karşılaştırma Grafiği


Yapılan 1u-1n-test verisi analizine göre toplam 1000 veri incelenmiş ve bu verilerin 968 tanesi sınıf 0, 26 tanesi sınıf 1 ve 6 tanesi sınıf 2 olarak sınıflandırılmıştır. Karşılaştırma grafiği incelendiğinde her iki trafonun frekans-genlik davranışları genel olarak benzer eğilimler göstermekte, belirgin zirve ve düşüş noktaları barındırmaktadır.

Grafik başlangıcında (Şekil 4.19), yani 0.00- 0.25 aralığında, kırmızı kesik çizginin daha belirgin dalgalanmalar göstermesi dikkat çekmektedir. Bu durum, seçilen trafoda bu frekans aralığında daha fazla varyasyon olduğunu işaret ederken, siyah çizginin daha stabil bir seyir izlemesi sağlıklı trafonun bu aralıktaki tutarlılığını göstermektedir. Yüksek genlik bölgelerinde, özellikle 1.50- 2.00 aralığında, kırmızı kesik çizginin genlik değerlerinin biraz daha düşük olması, seçilen trafonun bu frekans-genlik aralığında sağlıklı trafodan farklı davranış sergilediğine işaret etmektedir.

```
Toplam 1000 veriden 968 tanesi sınıf 0.  
Toplam 1000 veriden 26 tanesi sınıf 1.  
Toplam 1000 veriden 6 tanesi sınıf 2.  
Çıktı olarak: Trafo Sağlıklı
```

Şekil 4.20. 1U-1N Test Verisine Ait Konsol Çıktısı

Yazılım çalıştırıldığında konsol çıktısı olarak Şekil 4.20’de verildiği gibi sonuç alınmaktadır. Bu test verisine göre karşılaştırma grafiği (Şekil 4.19) incelendiğinde optimum sonuç alındığı yorumu yapılabilmektedir.



Şekil 4.21. 1V-1M-Test Verisine Ait Karşılaştırma Grafiği


Yapılan 1v-1m-test verisi analizine göre toplam 1000 veri incelenmiş ve bu verilerin 965 tanesi sınıf 0, 29 tanesi sınıf 1 ve 6 tanesi sınıf 2 olarak sınıflandırılmıştır. Grafikte siyah çizgi, sağlıklı trafonun verilerini, kırmızı kesik çizgi ise seçilen trafonun verilerini temsil etmektedir. Her iki trafonun frekans-genlik davranışları genel olarak benzer eğilimler göstermekte, belirgin zirve ve düşüş noktaları barındırmaktadır.

Grafik başlangıcında (Şekil 4.21), yani 0.00- 0.25 aralığında, kırmızı kesik çizginin daha belirgin dalgalanmalar göstermesi dikkat çekmektedir. Bu durum, seçilen trafoda bu frekans aralığında daha fazla varyasyon olduğunu işaret ederken, siyah çizginin daha stabil bir seyir izlemesi sağlıklı trafonun bu aralıktaki tutarlılığını göstermektedir. Yüksek genlik bölgelerinde, özellikle 1.50- 2.00 aralığında, kırmızı kesik çizginin genlik değerlerinin biraz daha düşük olması, seçilen trafonun bu frekans-genlik aralığında sağlıklı trafodan farklı davranış sergilediğine işaret etmektedir. Kırmızı kesik çizginin sağlıklı trafodan farklılaştığı bölgelerde potansiyel anormallikler veya arızalar olabileceği gözlemlenmektedir. Bu farklılıklar, seçilen trafonun sağlık durumunu olumsuz etkileyebilir ve daha detaylı incelenmesi gereken alanlar olduğunu işaret etmektedir. Bu sınıflandırma sonucunda, seçilen trafonun genel olarak sağlıklı olduğu değerlendirilmiştir. Ancak belirli frekans aralıkları için daha detaylı bir inceleme yapılmasının yararlı olacağı sonucuna varılabilmektedir.

```
Toplam 1000 veriden 965 tanesi sınıf 0.  
Toplam 1000 veriden 29 tanesi sınıf 1.  
Toplam 1000 veriden 6 tanesi sınıf 2.  
Çıktı olarak: Trafo Sağlıklı
```

Şekil 4.22. 1V-1M-Test Verisine Ait Konsol Çıktısı

Bu test verisine göre karşılaştırma grafiği (Şekil 4.21) incelendiğinde optimum sonuç alındığı yorumu yapılabilmektedir. Yazılım çalıştırıldığında konsol çıktısı olarak Şekil 4.22’de verildiği gibi sonuç alınmaktadır.



Şekil 4.23. 1V-1N-1W ÇKD Alt Test Verisine Ait Karşılaştırma Grafiği


Grafikte (Şekil 4.23), sağlıklı bir trafonun frekans-genlik ilişkisi ile arızalı olduğu belirlenen bir trafonun frekans-genlik ilişkisi karşılaştırılmıştır. Yapılan 1v1n1w ckd alt test verisi analizine göre, toplam 1000 veri incelenmiş ve bu verilerin 72 tanesi sınıf 0, 117 tanesi sınıf 1 ve 811 tanesi sınıf 2 olarak sınıflandırılmıştır. Siyah çizgi, sağlıklı trafonun verilerini, kırmızı kesik çizgi ise arızalı trafonun verilerini temsil etmektedir.

Grafik incelendiğinde, her iki trafonun frekans-genlik davranışlarının genel olarak benzer eğilimler gösterdiği, ancak belirgin farklılıkların bulunduğu görülmektedir. Özellikle belirli frekans aralıklarında, kırmızı kesik çizginin (arızalı trafo) siyah çizgiden (sağlıklı trafo) farklı bir eğilim sergilediği dikkat çekmektedir. Başlangıçtan itibaren, yani 0.00-0.25 aralığında her iki çizgi de benzer bir seyir izlemektedir. Ancak grafik genelinde bazı belirgin farklılıklar bulunmaktadır. 0.25- 0.50 aralığında, arızalı trafonun frekans-genlik ilişkisinde belirgin dalgalanmalar ve sapmalar gözlemlenmektedir. Kırmızı kesik çizginin daha keskin iniş ve çıkışlar göstermesi, arızalı trafonun bu frekans aralığında stabil bir performans sergilemediğini göstermektedir. 1.00- 1.25 aralığında ise, sağlıklı trafoya kıyasla arızalı trafonun genlik değerlerinde farklılıklar gözlenmektedir. Kırmızı kesik çizginin daha düşük genlik değerlerine sahip olması, arızalı trafonun bu aralıkta performans düşüklüğü yaşadığını işaret etmektedir. 1.50- 2.00 aralığında, özellikle bu yüksek genlik bölgelerinde, kırmızı kesik çizginin genlik değerlerinin sağlıklı trafodan daha düşük olması dikkat çekicidir.

```
Toplam 1000 veriden 72 tanesi sınıf 0.  
Toplam 1000 veriden 117 tanesi sınıf 1.  
Toplam 1000 veriden 811 tanesi sınıf 2.  
Çıktı olarak: Çekirdek Arızalı Trafo
```

Şekil 4.24. 1V1N1W ÇKD Alt Test Verisine Ait Konsol Çıktısı

Grafikte gözlemlenen bu farklılıklar, arızalı trafonun sağlıklı trafodan farklı bir frekans-genlik eğrisi ortaya koyduğunu ve bu farklılıkların trafonun çekirdek arızası olduğunu işaret ettiğini göstermektedir. Sonuç olarak, yapılan analiz sonucunda seçilen trafonun çekirdek arızalı olduğu belirlenmiştir. Bu değerlendirme, frekans-genlik eğrilerindeki sapmalar ve anormalliklerle desteklenmektedir. Bu sonuca ilişkin konsol çıktısı Şekil 4.24'te verilmiştir.



Şekil 4.25. 1W-1N Test Verisine Ait Karşılaştırma Grafiği


Grafikte, sağlıklı bir trafonun frekans-genlik ilişkisi ile değerlendirilmek üzere seçilen bir trafonun frekans-genlik ilişkisi karşılaştırılmıştır. Yapılan 1w-1n test verisi analizine göre, toplam 1000 veri incelenmiş ve bu verilerin 906 tanesi sınıf 0, 41 tanesi sınıf 1 ve 53 tanesi sınıf 2 olarak sınıflandırılmıştır. Siyah çizgi, sağlıklı trafonun verilerini, kırmızı kesik çizgi ise seçilen trafonun verilerini temsil etmektedir. Her iki trafonun frekans-genlik davranışları genel olarak benzer eğilimler göstermekte olup, belirgin zirve ve düşüş noktaları barındırmaktadır. Grafik başlangıcında (Şekil 4.25), yani 0.00-0.25 aralığında, kırmızı kesik çizginin daha belirgin dalgalanmalar göstermesi dikkat çekmektedir. Bu durum, seçilen trafoda bu frekans aralığında daha fazla varyasyon olduğunu işaret ederken, siyah çizginin daha stabil bir seyir izlemesi

sağlıklı trafonun bu aralıktaki tutarlılığını göstermektedir. Yüksek genlik bölgelerinde, özellikle 1.50-2.00 aralığında, kırmızı kesik çizginin genlik değerlerinin biraz daha düşük olması, seçilen trafonun bu frekans-genlik aralığında sağlıklı trafodan farklı davranış sergilediğine işaret etmektedir. Kırmızı kesik çizginin sağlıklı trafodan farklılaştığı bölgelerde potansiyel anormallikler veya arızalar olabileceği gözlemlenmektedir.

```
Toplam 1000 veriden 906 tanesi sınıf 0.  
Toplam 1000 veriden 41 tanesi sınıf 1.  
Toplam 1000 veriden 53 tanesi sınıf 2.  
Çıktı olarak: Trafo Sağlıklı
```

Şekil 4.26. 1W-1N Test Verisine Ait Konsol Çıktısı

Bu sınıflandırma sonucunda, seçilen trafonun genel olarak sağlıklı olduğu değerlendirilmiştir (Şekil 4.26). Karşılaştırma grafiği ve diğer sonuçlar değerlendirildiğinde optimum sonuç alındığına karar verilmiştir.



Şekil 4.27. 1W-1N-1V Sargı Kayma Arızalı Test Verisine Ait Karşılaştırma Grafiği

Grafikte (Şekil 4.27), sağlıklı bir trafonun frekans-genlik ilişkisi ile sargı kayma arızalı olduğu belirlenen bir trafonun frekans-genlik ilişkisi karşılaştırılmıştır. Yapılan 1w1n1v dk test verisi analizine göre, toplam 1000 veri incelenmiş ve bu verilerin 328 tanesi sınıf 0, 590 tanesi sınıf 1 ve 82 tanesi sınıf 2 olarak sınıflandırılmıştır. Siyah çizgi, sağlıklı trafonun verilerini, kırmızı kesik çizgi ise sargı kayma hatalı trafonun verilerini temsil etmektedir.

Grafik incelendiğinde, her iki trafonun frekans-genlik davranışlarının genel olarak benzer eğilimler gösterdiği, ancak belirgin farklılıkların bulunduğu görülmektedir. Bu farklılıklar, arızalı trafonun sağlıklı trafodan farklı eğilimler sergilediği bazı bölgelerde ortaya çıkmaktadır.

Başlangıçtan itibaren, yani 0.00-0.25 aralığında her iki çizgi de benzer bir seyir izlemektedir. Ancak grafiğin belirli noktalarında bazı belirgin farklılıklar bulunmaktadır. 1.75- 2.00 aralığında, özellikle bu yüksek genlik bölgelerinde, kırmızı kesik çizginin genlik değerlerinin sağlıklı trafodan daha düşük olması dikkat çekicidir. Bu durum, arızalı trafonun yüksek frekans-genlik aralıklarında sağlıklı trafodan farklı davranış sergilediğini ve potansiyel bir arıza belirtileri taşıdığını göstermektedir.

```
Toplam 1000 veriden 328 tanesi sınıf 0.  
Toplam 1000 veriden 590 tanesi sınıf 1.  
Toplam 1000 veriden 82 tanesi sınıf 2.  
Çıktı olarak: Sargı Kayma Arızalı Trafonsformatör
```

Şekil 4.28. 1W-1N-1V Sargı Kayma Arızalı Test Verisine Ait Konsol Çıktısı

Grafikte gözlemlenen bu farklılıklar, arızalı trafonun sağlıklı trafodan farklı bir frekans-genlik eğrisi ortaya koyduğunu ve bu farklılıkların trafonun sargı kayma arızası olduğunu işaret ettiğini göstermektedir. Sonuç olarak, yapılan analiz sonucunda seçilen trafonun sargı kayma arızası olduğu belirlenmiştir. Bu değerlendirme, frekans-genlik eğrilerindeki sapmalar ve anormalliklerle desteklenmektedir. Bu sonuca ilişkin konsol çıktısı Şekil 4.28’de verilmektedir.



5. SONUÇLAR

Yapılan çalışmanın matematiksel olarak sonuçlarının değerlendirilmesi için bazı performans testleri yapılmıştır. Kolmogorov-Smirnov (KS) istatistiği, bir modelin sınıflandırma performansını değerlendirmek için kullanılan önemli bir metriktir. KS testi, doğru pozitif oranı (TPR) ile yanlış pozitif oranı (FPR) arasındaki maksimum farkı ölçmektedir. Bu fark ne kadar büyükse, modelin sınıflandırma performansı o kadar iyidir. KS istatistiği değer 1'e ne kadar yakınsa, modelin performansı o kadar iyi kabul edilmektedir (Berger ve ark,2014). Bu çalışmada kullanılan modelde KS istatistikleri sınıf 0 için 0.9286, sınıf 1 için 0.9071 ve sınıf 2 için 0.9857 olarak belirlenmiştir (Tablo 5.1.) Bu yüksek değerler, modelin sınıfları doğru tahmin etme oranlarının oldukça yüksek olduğunu göstermektedir. KS istatistiği, modelin doğruluğunu ve etkinliğini değerlendirmek için güçlü bir metriktir ve bu çalışmada modelin performansının oldukça iyi olduğunu göstermiştir.

Tablo 5.1. Çalışmadaki sınıflara ait ks istatistikleri sonuçları.

KS İstatistikleri	
Sınıf 0- Sağlıklı Trafo	0.9286
Sınıf 1- Çekirdek Hatalı Trafo	0.9071
Sınıf 2- Sargı Kayma Hatalı Trafo	0.9857

Makine öğrenmesi çalışmalarında, modellerin başarısını değerlendirmek amacıyla çeşitli performans metrikleri kullanılmaktadır. Bu çalışmada, SFRA testlerinden elde edilen trafo verileri ile arıza tespiti gerçekleştirilmiş ve modelin performansı genel doğruluk (Accuracy), genel hassasiyet (Precision), genel duyarlılık (Recall) ve genel F1 skoru (F1-Score) metrikleri ile ölçülmüştür. Bu metrikler, makine öğrenmesi modellerinin doğruluğunu, yanlış pozitif ve yanlış negatif oranlarını ve genel denge performansını değerlendiren temel göstergelerdir. Çalışma sonucunda elde edilen performans sonuçları Tablo 5.2 'de verilmiştir.

Tablo 5.2. Genel model performansı.

Performans Değerlendirme Kriterleri	Performans Değeri
Genel Doğruluk (Accuracy)	0.9142
Genel Hassasiyet (Precision)	0.9205
Genel Duyarlılık (Recall)	0.9142
Genel F1-Ölçümü (F1-Score)	0.9141

Genel doğruluk (Accuracy), makine öğrenmesi ve sınıflandırma problemlerinde model performansını ölçmek için sıklıkla kullanılan bir metriktir. Bu değer 1'e yakın olması, modelin yüksek performans gösterdiğini belirtir. Akademik çalışmalarda doğruluk metriği, makine öğrenmesi modellerinin karşılaştırılmasında temel bir metrik olarak sıkça yer alır (Sarker,2021). Bu çalışmada, GBC algoritması için doğruluk değeri 0.9142 olarak hesaplanmıştır. Genel hassasiyet (Precision), modelin pozitif sınıf tahminlerinin doğruluk oranını ölçer. Hassasiyet, yanlış pozitiflerin (false positives) oranını azaltmayı hedefler. Hassasiyet değerinin 1'e yakın olması beklenir. Bu çalışmada, GBC algoritması için hassasiyet değeri 0.9206 olarak belirlenmiştir. Genel duyarlılık (Recall), makine öğrenmesi ve sınıflandırma problemlerinde model performansını ölçmek için kullanılan bir diğer önemli metriktir. Yüksek duyarlılık, modelin gerçek pozitifleri kaçırmamasını sağlar. Bu metrik, özellikle yanlış negatiflerin (false negatives) oranını azaltmayı hedefler. Duyarlılık değerinin 1'e yakın olması istenir. Bu çalışmada, duyarlılık değeri 0.9142 olarak bulunmuştur. Genel F1 Skoru (F1-Score), makine öğrenmesi ve sınıflandırma problemlerinde model performansını ölçmek için kullanılan önemli bir metriktir. F1-Score, hassasiyet (precision) ve duyarlılık (recall) metriklerinin harmonik ortalamasıdır ve modelin bu iki metriği dengeli bir şekilde değerlendirmesini sağlar. Bu metrik, özellikle sınıflar arasında dengesizlik olduğunda kullanışlıdır çünkü modelin hem pozitif örnekleri doğru yakalama kapasitesini (recall) hem de yanlış pozitif tahminlerden kaçınma kapasitesini (precision) dikkate alır. F1-Score, 0 ile 1 arasında bir değer alır ve 1'e yakın olması, modelin hem yüksek hassasiyet hem de yüksek duyarlılık gösterdiği anlamına gelir. Bu çalışmada F1-Score değeri 0.9142 olarak hesaplanmıştır. Çalışmanın sonucunu değerlendirmek için aynı zamanda ortalama kare hatası (MSE) ve kök ortalama kare hatası (RMSE) değerleri de hesaplanmıştır. Ortalama Kare Hata (MSE), tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını hesaplamaktadır. Kök Ortalama Kare Hata (RMSE) ise MSE'nin

karekökünün alınmasıyla elde edilmektedir. Her iki metrik de modelin doğruluğunu ve tahmin performansını değerlendirmede tamamlayıcı bir rol oynamaktadır (Braatz,2014). Çalışma sonucunda elde edilen MSE ve RMSE değerleri Tablo 5.3’te verilmiştir.

Tablo 5.3. MSE ve RMSE sonuçları.

PERFORMANS PARAMETRESİ	SONUÇLAR
RMSE	0.3381
MSE	0.1143

Bu çalışmada elde edilen MSE, RMSE ve diğer performans metriklerinin değerleri GBC algoritmasının tahmin doğruluğunun yüksek olduğunu ve modelin trafo arıza tespitinde etkili bir performans sergilediğini göstermektedir. Tüm bu sonuçlar, Gradient Boosting Classifier algoritmasının trafo arıza tespiti için hem yüksek doğruluk hem de genel denge sağladığını ortaya koymaktadır. Model, özellikle pozitif tahminlerin doğruluğu ve gerçek pozitiflerin tespiti konularında güçlü bir performans sergileyerek, tahminlerinin güvenilirliğini ve etkinliğini kanıtlamıştır.



6. TARTIŞMA VE SONUÇ

Bu çalışmada, transformatörlerin elektrik güç sistemlerindeki kritik rolünü ve teknolojik ilerlemelerle bu cihazların nasıl daha verimli ve güvenilir hale getirilebileceğini kapsamlı bir şekilde ele alınmıştır. Transformatörler, elektrik enerjisinin üretiminden dağıtımına kadar olan süreçte hayati bir işlev üstlenir. Ancak, transformatörlerin uzun ömürlü ve güvenilir bir şekilde çalışabilmesi için, arıza türlerinin doğru bir şekilde sınıflandırılması ve teşhis edilmesi şarttır. Bu çalışmada, elektriksel, mekanik ve termik arıza türleri, transformatörlerin performansını ve ömrünü doğrudan etkileyen önemli faktörler olarak ele alınmıştır. Arızaların erken tespiti için geliştirilen test yöntemleri, transformatörlerin güvenliğini ve verimliliğini artırmada büyük önem taşımaktadır. Özellikle Frekans Tarama Cevabı Analizi (SFRA) gibi modern test teknikleri, transformatörlerin frekans cevabını analiz ederek potansiyel hasarları tespit etmeye yönelik önemli bir yenilik olarak öne çıkmıştır. Bu çalışmanın literatüre katkısı; makine öğrenmesi teknikleri ve yapay zekâ kullanılarak SFRA test sonuçlarının değerlendirilmesi ile arızalı-sağlıklı trafo teşhisi yapılmasıdır. Bu değerlendirme yapılırken transformatör durumuna ilişkin 3 adet etiket değerinin oluşturulması literatüre katkı açısından ele alınması gereken en önemli hususlardan biridir.

Makine öğrenmesi algoritmaları, özellikle Gradient Boosting Classifier (GBC) gibi güçlü yöntemler, transformatör arızalarının öngörülmesi ve önlenmesi sürecinde büyük katkılar sunmaktadır. Makine öğrenmesi teknolojisi, büyük veri setlerinden öğrenerek arıza tahminlerini yüksek doğrulukla yapabilmektedir. Bu tezde, GBC algoritması üçlü sınıflandırma problemlerinde üstün performans göstermiştir. Genel doğruluk, hassasiyet, duyarlılık ve F1 skoru gibi performans metriklerinde diğer sınıflandırma algoritmalarına kıyasla daha başarılı olduğu gözlemlenmiştir. GBC algoritması için doğruluk oranı %91,42 olarak hesaplanmıştır. Bu, modelin oldukça yüksek bir doğrulukla çalıştığını gösterir. Genel hassasiyet değeri ise 0.9205 olarak bulunmuştur, bu da modelin pozitif tahminlerinde güvenilir olduğunu ortaya koymaktadır. Genel duyarlılık metriği 0.9142, F1 skoru ise 0.9141 olarak

hesaplanmıştır, bu da modelin yüksek hassasiyet ve duyarlılık gösterdiğini ifade eder. Bu metrikler, GBC algoritmasının yüksek doğruluk ve güvenilirlik sağladığını kanıtlamaktadır. Çalışmada, performans grafikleri analiz ederek frekans ve genlik arasındaki ilişkilerin görsel olarak incelenmesi sağlanmış ve sağlıklı ile arızalı trafolar arasındaki farklar belirginleştirilmiştir.

Bu çalışmada, veri seti üzerinde kullanılan sınıflandırma algoritmasından elde edilen sonuçlar, literatürde yapılan çalışmalarla karşılaştırıldığında, SFRA analizi verilerini kullanarak makine öğrenmesi ve yapay zekâ ile transformatör arızalarından aynı anda 3 adet etiket değerini teşhis eden bir sistemin mevcut olmadığı görülmektedir. Literatürdeki çalışmaların sahada uygulamaya uygunluğu da genellikle sınırlıdır. Bu çalışmanın literatüre katkılarından biri, kolay anlaşılır ve yorumlanabilir sonuçlar sunmasıdır. Bununla birlikte, her akademik çalışmada olduğu gibi, bu çalışma da geliştirilmeye ve kullanılabilirliğinin artırılmasına açıktır. Günümüzde SFRA ve diğer transformatör testlerinin yapılabilmesi için transformatörün enerjisinin kesilmesi ve fider ile bara bağlantı iletkenlerinin ayrılması gerekmektedir. Gelecekte, bu konuda yapılacak çalışmaların artmasıyla birlikte, iletim hattı ve baralara farklı frekanslarda gerilim uygulanarak SFRA testleri gerçekleştirilebilir. Eğer bu testlerin sonuçları yapay zekâ ile anlık olarak karşılaştırılabilir hale getirilirse, enerji kesintisi yapılmadan veya iletkenler ayrılmadan testlerin gerçek zamanlı olarak yapılabilmesi mümkün olacaktır. Bu çalışma, transformatörlerin gelecekteki enerji sistemlerinde vazgeçilmez bir bileşen olarak kalmasını sağlamaya yönelik önemli bir adımdır.

KAYNAKLAR

- ABB. (2004). Transformer handbook. Switzerland, 163–164.
- Abdulkareem, A., Awosope, C. O. A., Orovwode, H. E., & Adelakun, A. A. (2014). Power flow analysis of Abule-Egba 33-kV distribution grid system with real network simulations. *IOSR Journal of Electrical and Electronics Engineering*, 9(2, Ver. III), 67–80. <https://doi.org/10.9790/1676-09236780>
- Alsallakh, B., et al. (2020). Neo: Generalizing confusion matrix visualization to hierarchical and multi-output labels. *arXiv preprint*. <https://arxiv.org/abs/2110.12536>
- Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175–185. <https://doi.org/10.2307/2685209>
- Altunkaynak, A., Başakın, E. E., & Kartal, E. (2020). Dalgacık K-En Yakın Komşuluk yöntemi ile hava kirliliği tahmini. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 25(3), 1547–1562. <https://doi.org/10.17482/uumfd.809938>
- Atalar, F., & Kuntman, A. (2024). Bulanık mantık yöntemi kullanılarak güç transformatörleri arızalarının belirlenmesi. *Dicle University Journal of Engineering (DUJE)*, 15(2), 387–396.
- Berger, V. W., & Zhou, Y. (2014). Kolmogorov–Smirnov test: Overview. In *Encyclopedia of statistics in behavioral science*, republished in Wiley StatsRef: Statistics Reference Online. <https://doi.org/10.1002/9781118445112.stat06558>
- Bjelić, M., Brković, B., Žarković, M., & Miljković, T. (2024). Machine learning for power transformer SFRA based fault detection. *International Journal of Electrical Power & Energy Systems*, 156, 109779. <https://doi.org/10.1016/j.ijepes.2023.109779>
- Braatz, R. D. (n.d.). Parameter estimation. Unpublished. Available at <https://math.mit.edu/~rmd/650/estimation.pdf>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Çamur, S. N. ve Uçar, M. K. (2021). Erken diyabet teşhisi için kural tabanlı yapay zeka algoritması. 2021 Tıp Teknolojileri Kongresi (TIPTEKNO). IEEE. <https://doi.org/10.1109/TIPTEKNO53239.2021.9632855>
- Chakravorti, S., Dey, D., & Chatterjee, B. (2013). Recent trends in the condition monitoring of transformers: Theory, implementation and analysis. Springer.
- Coltman, J. W. (1988). The transformer. *Scientific American*, 258(1), 86–95. <https://doi.org/10.1038/scientificamerican0188-86>
- Coltman, J. W. (1988). Transformatör. Çeviren: F. L. Değertekin. *Elektrik Mühendisliği*, 361(362), 395–399.

- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- Demirçalı, A., & Köroğlu, S. (2015). Güç transformatörü arızalarının destek vektör makineleriyle belirlenmesi. *Pamukkale Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü, Denizli, Türkiye*.
- Demirci, M., Saka, M., Gözde, H., & Taplamacıoğlu, M. C. (2022). Güç transformatörleri arıza teşhisinde veri ön işleme yöntemlerinin sınıflandırıcı performansına etkisinin incelenmesi. In *Proceedings of the ELECO 2022* (pp. 1-6).
- Dietrich, M. (1983). Transformer failures and their diagnosis. *IEEE Transactions on Power Apparatus and Systems*, PAS-102(3), 676–685. <https://doi.org/10.1109/TPAS.1983.317079>
- Durusel Elektrik. (t.y.). Güç transformatörleri. Erişim adresi: <https://www.duruselektrik.com/urun/guc-transformatorleri/>
- El-Faraskoury, A. (2015). Experiences of sweep frequency response analyser for the diagnosis of transformer winding damage. In *IEEE-MEPCON 2015* (pp. 1-6). Mansoura University. <https://doi.org/10.13140/RG.2.1.2787.0805>
- Fatima, R., Sadiq, M., Ullah, S., Ahmed, G., & Mahmood, S. (2023). An optimized approach for detection and classification of spam emails using ensemble methods [Preprint]. *Research Square*. <https://doi.org/10.21203/rs.3.rs-2051142/v1>
- Fofana, I., & Hadjadj, Y. (2016). Electrical-based diagnostic techniques for assessing insulation condition in aged transformers. *Energies*, 9(6), 431. <https://doi.org/10.3390/en9060431>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer.
- Hayt, W. H., & Buck, J. A. (2011). *Engineering electromagnetics* (8th ed.). McGraw Hill.
- Ho, T. K. (1995). Random decision forests. In *Proceedings of the 3rd International Conference on Document Analysis and Recognition* (pp. 278–282).
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression*. Wiley.
- Hu, J., Zhou, T., Ma, S., Yang, D., Guo, M., & Huang, P. (2022). Rock mass classification prediction using heuristic algorithms and support vector machines: A case study of Chambishi copper. *Scientific Reports*, 12(1), 1–12. <https://doi.org/10.1038/s41598-022-05027-y>
- IEEE Region 5. (n.d.). Power transformer factory test using IEEE standards. *IEEE Region 5*.

- IEEE. (n.d.). IEEE C57.12.90: IEEE standard test code for liquid-immersed distribution, power, and regulating transformers. IEEE.
- IEEE. (n.d.). IEEE C57.149: Guide for the application and interpretation of frequency response analysis for oil-immersed transformers. IEEE.
- IEEE. (n.d.). IEEE guide for on-site acceptance tests of electrical equipment. IEEE Xplore.
- Institute of Electrical and Electronics Engineers. (1995). IEEE guide for diagnostic field testing of electric power apparatus (IEEE Std 62-1995).
- International Electrotechnical Commission. (2004). IEC 60076-11: Power transformers - Part 11: Dry-type transformers. IEC.
- International Electrotechnical Commission. (2006). IEC 60076-1: Power transformers - Part 1: General. IEC.
- International Electrotechnical Commission. (2006). IEC 60076-3: Power transformers - Part 3: Insulation levels, dielectric tests and external clearances in air. IEC.
- International Electrotechnical Commission. (2012). Power transformers - Part 18: Measurement of frequency response (IEC 60076-18). Geneva, Switzerland.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning fundamentals. *Open Access*, 31, 685–695. <https://doi.org/10.1007/s10209-021-00763-x>
- Jose E. Antón, Jose M. Guerrero, Carlos A. Platero (2021). "A Frequency Response Analysis and Machine Learning Combined Method for Interturn Faults Identification in Synchronous Generators." 2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe). DOI: 10.1109/EEEIC/ICPSEurope51590.2021.9584617.
- Karaisas, P., & Kaminaris, D. (2023). Power transformer fault diagnosis using neural network optimization techniques. *Mathematics*, 11(22), 4693. <https://doi.org/10.3390/math11224693>
- Khan, M. Y., Qayoom, A., Nizami, M. S., Siddiqui, M. S., Wasi, S., & Raazi, S. M. K.-u.-R. (2021). Automated prediction of good dictionary examples (GDEX): A comprehensive experiment with distant supervision, machine learning, and word embedding-based deep learning techniques. *Complexity*, 2021, Article ID 2553199, 18 pages. <https://doi.org/10.1155/2021/2553199>
- Korenciak, D., & Gutten, M. (2020). Fault diagnostics of transformer winding in time and frequency domain. *Diagnostyka*, 21(3), 49–54. <https://doi.org/10.29354/diag/125310>
- Kraetge, A., Krüger, M., Velasquez, J. L., Viljoen, H., & Dierks, A. (2009). Aspects of the practical application of sweep frequency response analysis (SFRA) on power transformers. In *Cigre 6th Southern Africa Regional Conference* (pp. 1–10). Paris.
- Krstinić, D., et al. (2020). Generalizing confusion matrix to multi-label classification problems. *Journal of Machine Learning Research*.

- Lynch, B. E., & Missouri, A. (2011). Ameren and Doble engineers prevent transformer failure, Viaduct substation 115-34 kV 46.7 MVA Auto Transformer 1. In 78th Annual International Conference of Doble Clients (pp. 1–6).
- Mlakić, D., Nikolovski, S., & Majdandžić, L. (2018). Deep learning method and infrared imaging as a tool for transformer faults detection. *Journal of Electrical Engineering*, 6(2), 98–106. <https://doi.org/10.17265/2328-2223/2018.02.006>
- Mohan, N. (2011). *Electric machines and drives* (1st ed.). Wiley.
- N'cho, J. S., & Fofana, I. (2020). Review of fiber optic diagnostic techniques for power transformers. *Energies*, 13(17), 1789. <https://doi.org/10.3390/en13071789>
- Nihat Pamuk (2014). "Tarama Frekans Cevap Metodu Kullanılarak Güç Transformatörlerindeki Çekirdek ve Sargı Yapısının Mekanik Bütünlüğünün Tespiti." *BEÜ Fen Bilimleri Dergisi*, 3(2), 117-125. *TEİAŞ*, 5. İletim Tesis ve İşletme Grup Müdürlüğü, Sakarya, Türkiye.
- Özgönenel, O., & Kılıç, E. (2024). Transformatör iç arızalarının çözülmesinde BBA ve TBA yöntemlerinin karşılaştırılması. *Ondokuz Mayıs Üniversitesi, Elektrik – Elektronik Mühendisliği Bölümü ve Bilgisayar Mühendisliği Bölümü*.
- Pandya, A. A., & Parekh, B. R. (2013). Sweep frequency response analysis (SFRA) an approach to detect hidden transformer faults. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 2(4), 1893–1896.
- Perlich, C., Provost, F., & Simonoff, J. (2003). Tree induction vs. logistic regression: A learning-curve analysis. *Journal of Machine Learning Research*, 4(2), 211–255.
- Prasetyo, A., & Supriyanto, E. (2021). Failure analysis of power transformer based on transformer turn ratio test and SFRA. *Journal of Physics: Conference Series*, 1817(1), 012021. <https://doi.org/10.1088/1742-6596/1817/1/012021>
- Rawlins, J. C. (2000). Ideal transformer. In *Basic AC circuits* (2nd ed.). Elsevier. Retrieved May 23, 2021, from <https://www.sciencedirect.com/topics/engineering/ideal-transformer>
- Ryder, S. A. (2002). Transformer diagnosis using frequency response analysis: Results from fault simulations. In *Proceedings of the 2002 IEEE Power Engineering Society Summer Meeting* (Vol. 3, pp. 399–404). <https://doi.org/10.1109/PESS.2002.1043423>
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2, 160. <https://doi.org/10.1007/s42979-021-00592-x>
- Scholkopf, B., & Smola, A. J. (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. MIT Press.
- SCOTECH. (t.y.). 80 MVA 220 kV büyük güç transformatörü. Erişim adresi: <https://tr.scotech-electrical.com/transformer/power-transformer/80-mva-220kv-large-power-transformer.html>

- Shahriar, S., Al-Ali, A. R., Osman, A., & Shaaban, M. F. (2022). Machine learning approach for smart distribution transformers load monitoring and management system. *Energies*, 15(21), 7981. <https://doi.org/10.3390/en15217981>
- Sun, H.-C., Huang, Y.-C., & Huang, C.-M. (2012). A review of dissolved gas analysis in power transformers. *Energy Procedia*, 14, 1220–1225.
- Suthaharan, S. (2016). Decision tree learning. In *Machine learning models and algorithms for big data classification* (Vol. 36, pp. 237–269). Springer. https://doi.org/10.1007/978-1-4899-7641-3_10
- Sweetser, C., & McGrail, T. (2003). Sweep frequency response analysis transformer applications. A Technical Paper from Doble Engineering. USA, 27–31.
- Ting, K. M. (2008). Mean squared error. In *The concise encyclopedia of statistics* (pp. 337–339). Springer. https://doi.org/10.1007/978-0-387-32833-1_251
- Ting, K. M. (2011). Precision and recall. In C. Sammut & G. I. Webb (Eds.), *Encyclopedia of machine learning* (p. 781). Springer. https://doi.org/10.1007/978-0-387-30164-8_652
- Turan, A., & Çalışkan, A. (2024). Bulanık mantık tabanlı Rogers ve IEC metotlar kullanarak güç transformatör arızalarının belirlenmesi. *Dicle University Journal of Engineering (DUJE)*, 15(2), 387–396.
- Türkiye Elektrik İletim A.Ş. (2020). Saha test felsefesi (Rev. 00). Test Müdürlüğü.
- Velasco Costa, J., da Silva, D. F. F., & da Costa Branco, P. J. (2022, Mart). Large power transformers: Time now for addressing their monitoring and failure investigation techniques [Preprint]. Preprints. <https://doi.org/10.20944/preprints202203.0285.v1>
- Wang, M., Vandermaar, A. J., & Srivastava, K. D. (2002). Review of condition assessment of power transformers in service. *IEEE Electrical Insulation Magazine*, 18(6), 12–25. <https://doi.org/10.1109/MEI.2002.1166115>
- Wikipedia. (n.d.). Transformatör. Retrieved August 23, 2024, from <https://tr.wikipedia.org/wiki/Transformat%C3%B6r>
- Yalman, Y., Uyanık, T., Atlı, İ., Tan, A., Bayındır, K. Ç., Karal, Ö., Golestan, S., & Guerrero, J. M. (2022). Prediction of voltage sag relative location with data-driven algorithms in distribution grid. *Energies*, 15(18), 6641. <https://doi.org/10.3390/en15186641>
- Yıldız, M. (2018). Güç transformatörlerinde meydana gelen arızaların gelişmiş test yöntemleri ile belirlenmesi (Yüksek lisans tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı). Pamukkale Üniversitesi, Denizli, Türkiye.
- Zhang, T., Lin, W., Vogelmann, A. M., Zhang, M., Xie, S., Qin, Y., & Golaz, J.-C. (2021). Improving convection trigger functions in deep convective parameterization schemes using machine learning. *Journal of Advances in Modeling Earth Systems*, 13(5). <https://doi.org/10.1029/2020MS002365>



ÖZGEÇMİŞ

Ad-Soyad : Hakan ÇUHADAROĞLU

ÖĞRENİM DURUMU:

- **Lisans** : 2003,Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü
- **Yükseklisans** : 2005,Sakarya Üniversitesi, Elektrik-Elektronik A.B.D
- **Doktora** : 2025 Sakarya Üniversitesi Elektrik-Elektronik A.B.D

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2003-2004 Santral Elektrik, Saha Mühendisi
- 2004-2006 Atilla Otomasyon, Elektronik Lab. Şefi
- 2007-2010 Aven Enerji, Saha Test Mühendisi
- 2011- Alternans Elektrik Güç Sistemleri, Kurucu Ortak
- 2017- Alfa Yenilenebilir Enerji A.Ş, Kurucu Ortak

TEZDEN TÜRETİLEN ESERLER:

Çuhadaroğlu, H.; Uyaroğlu,Y. Detection of Transformer Faults: AI-Supported Machine Learning Application in Sweep Frequency Response Analysis. Energies 2025, 18,2481. <https://doi.org/10.3390/en18102481>

DİĞER ESERLER: