

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

**TRANSFORMATÖR İÇ ARKLARININ GEÇİCİ
REJİM SİNYAL İŞLEME VE MAKİNE ÖĞRENME
YÖNTEMLERİYLE ERKEN TESPİTİ**

DOKTORA TEZİ

Feyyaz ALPSALAZ

Elektrik Tesisleri Anabilim Dalı

Tez Danışmanı: Prof. Dr. Mehmet Salih MAMİŞ

ARALIK 2024

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

**TRANSFORMATÖR İÇ ARKLARININ GEÇİCİ
REJİM SİNYAL İŞLEME VE MAKİNE ÖĞRENME
YÖNTEMLERİYLE ERKEN TESPİTİ**

DOKTORA TEZİ

**Feyyaz ALPSALAZ
(36203615005)**

Elektrik Tesisleri Anabilim Dalı

Tez Danışmanı: Prof. Dr. Mehmet Salih MAMİŞ

ARALIK 2024

**İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ**

**TRANSFORMATÖR İÇ ARKLARININ GEÇİCİ
REJİM SİNYAL İŞLEME VE MAKİNE ÖĞRENME
YÖNTEMLERİYLE ERKEN TESPİTİ**

**Tezi Hazırlayan: Feyyaz ALPSALAZ
Doktora Tezi**

TEŞEKKÜR VE ÖNSÖZ

Bu tez çalışmasının her aşamasında yardım, öneri, bilgi, tecrübe ve desteklerini esirgemedi beni her konuda yönlendiren danışman hocam Sayın Prof. Dr. Mehmet Salih MAMİŞ'e teşekkür ederim.

Tez ve TİK süreçlerimde desteklerini ve bilgilerini esirgemeyen Sayın Prof. Dr. Müslüm ARKAN ve Sayın Dr. Öğr. Üyesi Cemal KELEŞ'e teşekkür ederim.

Çalışmalarımnda ayrıca tüm hayatım boyunca olduğu gibi bu çalışmalarım süresince de benden her türlü desteklerini aileme teşekkür ederim.

Doktora ve Tez sürecimin tamamında her türlü fedakarlığı ve sabrı gösteren Eşim Süheyla DEMİRTAŞ ALPSALAZ'a teşekkür ederim.

Tez sürecimde vakitlerinden feragat ettiğim Kızlarım Hatice Asya ve Azra İnci'ye teşekkür ederim.

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından **123E658** Numaralı proje ile desteklenmiştir. Projeye verdiği destekten ötürü TÜBİTAK'a teşekkürlerimiz sunarız.

ONUR SÖZÜ

Doktora tezi olarak sunduğum “Transformatör İç Arklarının Geçici Rejim Sinyal İşleme ve Makine Öğrenme Yöntemleriyle Erken Tespiti” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığına ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Feyyaz ALPSALAZ



İÇİNDEKİLER

TEŞEKKÜR VE ÖNSÖZ	i
ONUR SÖZÜ	ii
İÇİNDEKİLER.....	iii
ÇİZELGELER DİZİNİ.....	v
ŞEKİLLER DİZİNİ.....	vi
SEMBOLLER VE KISALTMALAR	viii
ÖZET.....	ix
ABSTRACT	x
1. GİRİŞ.....	1
2. TRANSFORMATÖR TEORİSİ VE MODELLENMESİ.....	12
2.1 Transformatörün Tarihçesi	12
2.2 Transformatörler	13
2.2.1 Transformatör elektriksel modeli	13
2.2.2 Transformatör manyetik modeli	15
2.2.3 Transformatör kayıpları	16
2.3 Transformatör ANSYS@Maxwell Modeli.....	18
2.3.1 Gecici (Transient) transformatör modelinin oluşturulması	18
2.3.2 Nüve yapısının oluşturulması	19
2.3.3 YG ve AG sargılarının oluşturulması	20
2.3.4 Malzeme seçimi.....	21
2.3.5 Elektromekanik analiz için kuvvet analizlerinin oluşturulması	24
2.4 Sonlu Elemanlar Yöntemi (SEY)	24
3. ARK TEORİSİ VE MODELLENMESİ	27
3.1 Transformatör Yağının Özellikleri ve Arkın Oluşumu	27
3.2 Yağ İçinde Arkın Dinamikleri	28
3.3 Elektrik Arklarının Fiziksel Temelleri.....	28
3.4 Arkın Elektriksel Davranışı	29
3.4.1 Arkların statik modeli.....	29
3.4.2 Arkların dinamik modelleri	29
3.5 MATLAB'ta Arkın Modellenmesi	31
3.6 Ark Modelinin Seçilmesi.....	33
3.7 Ark yapısının ANSYS@Simplorer Modeli	35
4. FOURİER DÖNÜŞÜMÜ	37
4.1 Ayırık Fourier Dönüşümü (DFT)	38
4.2 Hızlı Fourier Dönüşümü (FFT)	39
5. MAKİNA ÖĞRENME ALGORİTMALARI	42
5.1 Denetimli Öğrenme Algoritmaları.....	43
5.1.1 Regresyon Algoritmaları	43
5.1.2 Sınıflandırma Algoritmaları	44
5.2 Denetimsiz öğrenme algoritmaları.....	44
5.2.1 Kümeleme (Clustering)	44
5.2.2 Boyut İndirgeme (Dimensionality Reduction)	45
5.2.3 Özyinelemeli Sinir Ağları (Autoencoders).....	45
5.2.4 Bağlantı kurma ve kurallar (Association Rule Learning).....	45
5.3 Pekiştirmeli Öğrenme Algoritmaları	45
5.3.1 Q-Öğrenme (Q-Learning).....	46
5.3.2 Sonsuz Küçük Gradyan İnişi (Deep Q-Network, DQN)	46
5.4 Transformatör Arızalarıyla İlgili MÖ Çalışmaları	46
5.5 Algoritmaların Belirlenmesi	47

5.5.1 Karar ağaçları algoritması (DT)	48
5.5.2 k-En yakın komşu (k-NN)	49
5.5.3 Destek vektör makineleri (SVM)	50
5.5.4 Yapay sinir ağları (YSA)	50
5.5.5 Ansamble öğrenme (ESM)	52
5.6 Performans Parametreleri	52
6. BENZETİM ORTAMLARININ BİRLEŞTİRİLEREK ANALİZLERİN	
ÇERÇEKLEŞTİRİLMESİ	56
6.1 Önerilen Metodoloji	56
6.2 Transformatör performans parametrelerinin elde edilmesi	58
6.2.1 Normal Koşullarda Çalışması	60
6.2.2 Kısa Devre Çalışması	61
6.2.3 Harmonikli Çalışma	63
6.3 Modellerin ANSYS@Simplorer Ortamında Birleştirilmesi	64
6.4 Ark Arızasının Akım ve Gerilim Sinyallerinin Elde Edilmesi	66
6.5 Transformatör Girişlerinden Alınan Akım/Gerilim Sinyallerinin İşlenmesi	70
6.6 Arıza Fazı ve Arıza Diskinin MÖ Yöntemiyle Tespiti ve Metrik Parametrelerin karşılaştırılması	77
7. SONUÇ VE ÖNERİLER	86
KAYNAKLAR	90
EKLER	101
ÖZGEÇMİŞ	112

ÇİZELGELER DİZİNİ

Çizelge 1.1 : Literatürde transformatör arızalarının belirlenmesi için kullanılan yöntemler.	3
Çizelge 5.1 : İki sınıflı bir karışıklık matrisi	53
Çizelge 6.1 : Transformatör parametreleri	59
Çizelge 6.2 : Fabrika verileri ile modelleme sonuçlarının karşılaştırılması.....	60
Çizelge 6.3 : Harmonik seviyelerine ait THD değerleri	64
Çizelge 6.4 : THD=0 ile THD=4.97 kayıpların karşılaştırmaları	64
Çizelge 6.5 : MÖ modellerinin hiper parametre değerleri	78
Çizelge 6.6 : Arızalı sargıya ait MÖ parametreleri	83
Çizelge 6.7 : Arızalı diske ait MÖ parametreleri	84

ŞEKİLLER DİZİNİ

Şekil 1.1 : CIGRE raporlarına göre transformatörlerdeki arıza kaynağı oranları.....	1
Şekil 2.1 : Bir fazlı ideal transformatör.....	13
Şekil 2.2 : Bir fazlı transformatörün düşük frekans eşdeğer modeli.....	14
Şekil 2.3 : Nüve ve sargıları olan manyetik devre.	15
Şekil 2.4 : Maxwell çözümleme modelleri	19
Şekil 2.5 : Nüve modelinin oluşturulması.....	19
Şekil 2.6 : Sargı modelinin oluşturulması (YG sargıları)	20
Şekil 2.7 : AG ve YG sargılarının (üstten görünüm)	20
Şekil 2.8 : M125_027S nüve malzemesinin seçilmesi.....	21
Şekil 2.9 : M125_027S malzemesi bilgisi	22
Şekil 2.10 : M125_027S malzemesi B-H karakteristiği.....	23
Şekil 2.11 : M125_027S malzemesine ait B-P kayıp karakteristiği ve materyal bilgileri. .	23
Şekil 2.12 : Bakır materyal bilgileri.....	24
Şekil 2.13 : Elektromekanik örgü yapısı.....	24
Şekil 2.14 : Mesh örgü parametreleri.....	26
Şekil 3.1 : MATLAB@Simulink'e kuplajlanan ark modeli.	32
Şekil 3.2 : MATLAB@Simulink modeli.....	33
Şekil 3.3 : Ark'ın doğrusal olmayan model gösterimi.	35
Şekil 3.4 : Doğrusal olmayan ark modelinin Simplorer ortamındaki davranışı.....	36
Şekil 4.1 : Dikdörtgen bir darbenin zaman uzayındaki gösterimi.....	38
Şekil 4.2 : Dikdörtgen bir darbenin zaman uzayındaki gösterimi.....	38
Şekil 5.1 : Karar ağaçları algoritma yapısı.....	48
Şekil 5.2 : K-NN sınıflandırıcısı için iki farklı sınıfa ait örnek bir veri dağılımı	49
Şekil 5.3 : İki sınıflı örnek bir veri grubu için hiperdüzlem ve destek vektörlerinin gösterimi.....	50
Şekil 5.4 : YSA'nın kendi yapısında giriş, çıkış ve gizli katmanları	51
Şekil 5.5 : K-katlı çapraz doğrulama gösterimi	53
Şekil 6.1 : Önerilen Ark Arızası Tespiti (AFD) tahmin metodolojisi.....	57
Şekil 6.2 : Transformatör ANSYS@Maxwell tasarımı	59
Şekil 6.3 : Transformatör modeli çekirdek kayıpları değişimi	60
Şekil 6.4 : Kısa devre çalışma diyagramı.....	61
Şekil 6.5 : A faz-Toprak arızası manyetik akım yoğunluğu	62
Şekil 6.6 : A faz-Toprak arızası sonucu transformatör sargılarına etki eden elektromanyetik radyal kuvvetler.....	63
Şekil 6.7 : Ark analizi için geliştirilen MATLAB@Simulink uyumlu ANSYS@Simplorer modeli.....	65
Şekil 6.8 : Transformatör sargılarındaki farklı noktalardaki ark rızası için oluşturulan sargı yapıları.....	66
Şekil 6.9 : Ark Arızası oluşmuş transformatör çekirdeğindeki manyetik akı yoğunluğu dağılımı ($t=0,35$ ms'deki)	67
Şekil 6.10 : Ark akımı ve geriliminin zamana bağlı değişimi.....	68
Şekil 6.11 : Ark'ın Gerilim-Akım değişimi	68
Şekil 6.12 : ANSYS@Simplorer ortamındaki ark arızası sonucu oluşan terminal geriliminin değişimi	69
Şekil 6.13 : MATLAB ortamına aktarılan ark arızası sonucu oluşan terminal akım/gerilim değişimi	69
Şekil 6.14 : YG meydana gelen ark arızasına ait gerilim spektrumları a)Disk1 b)Disk3 ...	71
Şekil 6.15 : YG meydana gelen ark arızasına ait akım spektrumları a)Disk1 b)Disk3	72

Şekil 6.16 :	AG meydana gelen ark arızasına ait gerilim spektrumları <i>a)Disk1 b)Disk3 ...</i>	73
Şekil 6.17 :	AG meydana gelen ark arızasına ait akım spektrumları <i>a)Disk1 b)Disk3.....</i>	74
Şekil 6.18 :	YG Sargısında meydana gelen ark arızasına ait filtre uygulanmış akım spektrumları <i>a)Disk1, b)Disk3, c)Disk5, d) Disk9, e)Disk11</i>	77
Şekil 6.19 :	Arızalı sargı eğitim verisine ait AUC-ROC eğrisi (DT).....	79
Şekil 6.20 :	Arızalı sargı test verisine ait AUC-ROC eğrisi (DT)	79
Şekil 6.21 :	Arızalı sargı eğitim verisine ait konfüzyon matrisi (SVM)	80
Şekil 6.22 :	Arızalı sargı eğitim verisine ait konfüzyon matrisi (SVM)	80
Şekil 6.23 :	Arızalı Disk eğitim verisine ait AUC-ROC eğrisi (K-NN)	81
Şekil 6.24 :	Arızalı Disk eğitim verisine ait AUC-ROC eğrisi (K-NN)	81
Şekil 6.25 :	Arızalı diskin eğitim verisine ait konfüzyon matrisi (ESM).....	82
Şekil 6.26 :	Arızalı diskin test verisine ait konfüzyon matrisi (ESM)	82



SEMBOLLER VE KISALTMALAR

AG	: Alçak gerilim
AGA	: Alçak gerilim A sargısı
AGB	: Alçak gerilim B sargısı
AGC	: Alçak gerilim C sargısı
B	: Manyetik akı yoğunluğu
B_r, B_φ ve B_z	: Silindirik koordinattaki Akı yoğunluğunun bileşenleri
D	: Elektrik akı yoğunluğu
DGA	: Çözünmüş gaz analizi
E	: Elektrik alan şiddeti
F	: Kuvvet
FFT	: Hızlı Fourier dönüşümü
f	: Frekans
c	: Spesifik ısı kapasitesi
f₀	: Kayıp eğrisi test frekansı
k	: Malzemenin termal iletkenliği
a_c	: Girdap akım katsayısı
H	: Manyetik alan şiddeti
H_c	: Koersitive
J	: Elektrik akım yoğunluğu
L	: Endüktans
P	: Güç
P_h	: Histerezis kaybı
P_c	: Nüve kaybı
P_e	: Girdap akım kaybı
P_{exc}	: Hesaplanmayan kayıplar
ρ	: Hacimsel elektrik yükü yoğunluğu
λ	: Termal iletkenlik sabiti
σ	: İletkenlik
μ	: Manyetik geçirgenlik
μ₀	: Hava aralığının manyetik geçirgenliği
μ_r	: Bağıl geçirgenlik
ρ	: Spesifik materyal yoğunluğu
SEY,FEM	: Sonlu elemanlar yöntemi
T, t, time	: Zamana ve ortama bağlı sıcaklık dağılımının fonksiyonu
V	: Gerilim
w	: Uygulanan manyetik-alanın frekansı
ω	: Açısal frekansı
YG	: Yüksek gerilim
YGA	: Yüksek gerilim A sargısı
YGC	: Yüksek gerilim B sargısı
YGD	: Yüksek gerilim B sargısı
YSA, ANN	: Yapay sinir ağlar

ÖZET

Doktora

TRANSFORMATÖR İÇ ARKLARININ GEÇİCİ REJİM SİNYAL İŞLEME VE MAKİNE ÖĞRENME YÖNTEMLERİYLE ERKEN TESPİTİ

Feyyaz ALPSALAZ

İnönü Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Tesisleri Anabilim Dalı

113+X sayfa

2024

Danışman: Prof. Dr. Mehmet Salih MAMİŞ

Güç transformatörlerinde yıldırım düşmesi, anahtarlama olayları ve kısa devre arızaları gibi nedenler, sargı yalıtımında deformasyona yol açarak sargılar arasında elektrik arkı oluşumuna neden olmaktadır. Ark oluşumu zamanla rijit bir kısa devreye yol açarak trafoların aşırı ısınmasına ve basınç nedeniyle transformatörün patlamasına sebep olabilmektedir. Bu tez çalışmada, transformatör sargılarındaki ark oluşumu transformatörün terminallerindeki akım ve gerilim sinyallerindeki geçici rejim değişimleri incelenerek tespit edilmiştir. Çalışmada, 15 MVA gücünde bir güç transformatörü ANSYS@Maxwell ortamında üç boyutlu olarak modellenmiş ve MATLAB@Simulink'te oluşturulan ark modeli ANSYS@Maxwell manyetik modeline adapte edilerek yapılan senkronize çalışma ile transformatör sargılarındaki ark analizi gerçekleştirilmiştir. Tasarımların çözümlemesinde Sonlu Elemanlar Yöntemi (SEY) kullanılmıştır. Transformatör modelinin doğruluğunu sağlaması için normal, kısa devre ve harmonik analizleri gerçekleştirilmiş ve elde edilen sonuçlar fabrika ve tasarım verileriyle karşılaştırılarak sonuçların uyumlu olduğu belirlenmiştir. Transformatör girişinden elde edilen veriler, Hızlı Fourier Dönüşümü (FFT) kullanılarak frekans spektrumuna dönüştürülmüş ve bu sinyallerden transformatördeki ark arızası durumlarında oluşan yüksek frekanslı harmonikler tespit edilmiştir. Frekans spektrumlarından elde edilen 361 ayrı noktadaki harmonik veriler kullanılarak K-NN, DT, SVM, YSA ve ESM gibi Makine Öğrenmesi (MÖ) algoritmaları ile modeller eğitilmiştir. Arızalı sargı ve arızalı diske ait arıza tespit modellerinde yüksek doğruluk ve performans değerleri sağlanmıştır. Böylece, geliştirilen yöntem sayesinde transformatör sargılarında ark arızası oluşumunun sensör kullanmadan kısa sürede tespit edilmesine imkân sağlanmıştır.

Anahtar Kelimeler: Transformatör, Sargı arızası, Geçici rejim analizi, Ark tespiti, FFT, Makine Öğrenmesi,

ABSTRACT

Phd. Thesis

EARLY DETECTION OF TRANSFORMER INTERNAL ARCS USING TRANSIENT SIGNAL PROCESSING AND MACHINE LEARNING

Feyyaz ALPSALAZ

Inonu University
Graduate School of Nature and Applied Sciences
Department of Electrical Installations

113+X page

2024


Supervisor: Prof. Dr. Mehmet Salih MAMİŞ

In power transformers, phenomena such as lightning strikes, switching operations, and short-circuit faults can lead to deformation of the winding insulation, causing electrical arc formation between windings. Over time, arc formation may result in a rigid short circuit, leading to excessive heating and, under pressure, transformer explosions. This thesis investigates the detection of arc formation in transformer windings by analyzing transient in the current and voltage signals at the transformer terminals. In this study, a 15 MVA power transformer is modelled in three dimensions in ANSYS@Maxwell environment and the arc model created in MATLAB@Simulink is adapted to the ANSYS@Maxwell magnetic model by performing the arc analysis in the transformer windings via synchronised operation. Finite Element Method (FEM) is used to analyse the designs. In order to ensure the accuracy of the transformer model, normal, short circuit and harmonic analyses are performed and the results obtained are compared with the factory and design data and it is determined that the results are compatible. The data obtained from the transformer terminals are transformed into frequency spectrum using Fast Fourier Transform (FFT) and high frequency harmonics generated during arc fault conditions in the transformer are detected from these signals. The models are trained with Machine Learning (ML) algorithms such as K-NN, DT, SVM, ANN and ESM using harmonic data at 361 different points obtained from frequency spectra. High accuracy and performance values are achieved in fault detection models of faulty winding and faulty disc. Thus, with the developed method, it is possible to detect arc fault formation in transformer windings in a short time without need of any sensor.

Keywords: Transformer, Winding fault, Transient analysis, Arc detection, FFT, Machine Learning.

1. GİRİŞ

Enerji üretim, iletim ve dağıtımının vazgeçilmez ve en önemli elemanı olan transformatörde meydana gelebilecek arızalar beklenmedik enerji kesintilerine yol açmakta, bu kesintiler önemli oranda iş gücü kayıplarına ve çeşitli ekonomik zararlara neden olmaktadır. Enerji sürekliliğinin daha da önem teşkil ettiği günümüzde transformatör arızalarının olabilecek en erken safhada tahmin edilmesi büyük önem taşımaktadır. CIGRE raporlarına göre transformatör arızalarının büyük oranda sargı arızalarından oluştuğu Şekil 1.1’de görülmektedir (Abbasi, 2022). Transformatörlerdeki ikinci düzeydeki arıza nedeni yükte kademe değiştirici arızaları olsa da yükte kademe değiştirici kullanılan transformatör sayısı oranının maliyetten dolayı oldukça düşük düzeyde olması nedeniyle arızaların yarısından fazlasının sargı arızası şeklinde olduğu söylenebilir.



Şekil 1.1 : CIGRE raporlarına göre transformatörlerdeki arıza kaynağı oranları (Abbasi, 2022).

Mevcut durumda yağ soğutmalı güç grubu transformatörlerinin korunması için güvenlik donanımı olarak Buchholz rölesi kullanılmaktadır. İlk olarak Alman mühendis Max Buchholz tarafından tasarlanan bu röleler 1940'lı yıllardan bu yana yaygın olarak kullanılmaktadır. Yağla soğutulan bir transformatörde sargılarda arıza meydana geldiğinde yağ, gaz şeklinde buharlaşmakta ve trafo yağında hızlı bir şekilde gaz birikimi meydana gelmektedir. Yağlı tip trafolarla bir elektrik arka oluştuğunda, transformatör ısınır ve yağ, genleşme kazanına hızla akarak, hareket eden yağın yolu üzerinde bulunan bir kanatçıya bağlı elektrik anahtarını çalıştırır. Bu süreçte, gazın yağdan daha hafif olması sebebiyle

oluşan gaz Buchholz rölesinin gaz haznesinde toplanır. Gazın birikmesi ve basınç artışı, röledeki şamandıranın yükselmesine yol açar; bu sırada alarm kontakları kapanır ve alarm devreye girer. Aynı zamanda, cihazı izole etmek amacıyla devre kesicisinin açılmasını sağlayarak, arıza daha fazla hasara yol açmadan önlenir. Transformator, bakım için ana güç kaynağından ayrılarak koruma altına alınır. Buchholz röleleri ayrıca, biriken gazın test için çekilmesine olanak tanıyan bir test portuna sahiptir. Rölede bulunan yanıcı gaz, aşırı ısınma veya ark gibi bazı dahili arızaları gösterirken, rölede bulunan hava yalnızca düşük yağ seviyesini veya sızıntıyı göstermektedir (Christopoulos ve Wright, 1999). Gazın üretilmesi, transformatorün içinde meydana gelen arızanın büyüklüğüne ve çeşidine bağlıdır. Ancak, transformatorde sargı veya sargı arasındaki yalıtımın bozulmasından dolayı meydana gelen iç arıza başlangıçta ark şeklinde ortaya çıkmaktadır. Bu nedenle Buchholz rölesi ark başlangıç (arc initiation) arızalarında yetersiz kalarak geç cevap verebilmektedir. Diğer bir husus ise, yüksek maliyetinden dolayı Buchholz rölesinin ekonomik açıdan küçük trafolarda kullanımının uygun olmaması ve 500 kVA'dan yüksek bir değere sahip trafolarda kullanıma uygun olmasıdır. Daha da önemlisi, röle ancak rijit bir ark arızası meydana geldiğinde arıza bilgisi üretmektedir ki, bu durum çoğu zaman kuvvetli bir arıza durumu veya hızlıca sargıların tamamen yanmış olması ile sonuçlanmaktadır. Bu röle ile ilgili diğer bir kısıt ise, rölenin çalışma prensibi gereği yalnızca yağlı transformatorlerde kullanılmaya uygun olmasıdır. Bu sebeplerden dolayı transformatorlerde iç arızaların sayısal ve dijital yöntemlerle tespitine yönelik çalışmalar son yıllarda büyük önem kazanmıştır.

Ark enerjisi, özellikle ark gerilimine ve arkı oluşturan elektrotlar arası mesafeye bağlıdır. Ark gerilimi düşük ve ark mesafesi yüksek olduğunda, ark enerjisi de düşük olmaktadır (Terzija vd., 2011; Terzija ve Koglin, 2004). Bu tip ark oluşumları, geçici rejim durumunda transformator akım ve gerilim rms değerlerinde önemli bir değişiklik meydana getirmediğinden ve kısmi boşalmaya neden olabilecek düzeyde yeterli gaz oluşumuna neden olmadığından, bu tip arkların diferansiyel röle veya çözünmüş gaz analizi (Dissolved Gas Analysis-DGA) gibi klasik yöntemlerle belirlenmesi nispeten daha zor olmaktadır.

Geçmişten günümüze transformator arızaları incelendiğinde, ark arızası konusundaki çalışmaların çok az olduğu ve genellikle doğrudan iletken teması şeklindeki rijit kısa devre arızaları üzerinde durulduğu görülmektedir. Halbuki, rijit kısa devre arızası oluşmadan önce ark arızası meydana gelmekte olup, özellikle düşük enerji düzeyinde olması durumunda bu tür ark arızasıyla ilgili hiçbir belirti görülmeyebilir. Buchholz rölesi ve diferansiyel koruma bu aşamada yetersiz kalmaktadır. Literatürde transformator arızalarının belirlenmesi için

kullanılan, ancak büyük çoğunlukla rijit ark arızasının belirlenmesine yönelik olan yöntemlerin özellikleri Tablo 1’de genel hatlarıyla verilmiştir. Konuyla ilgili yöntemler daha önce yapılan çalışmalarda ele alınmıştır (Abbasi, 2022; Hajiaghasi vd., 2021).

Çizelge 1.1 : Literatürde transformatör arızalarının belirlenmesi için kullanılan yöntemler.

Tespit Yöntemi	Avantajları	Kısıtlılıkları	Referanslar
DGA	- Başlangıç düzeyinde herhangi bir anormalliğin tespiti kolaydır. - Hem çevrimiçi hem de çevrimdışı DGA ile mümkündür.	- Yüksek maliyetli bir yöntemdir. - Analiz sonuçlarının güvenilirlik düzeyi düşüktür. - Kuru tip trafo için kullanışlı değildir.	(Bandaru vd., 2022; Gémez vd., 2014; Li vd., 2011; Martin vd., 2014; Mutha ve Saratkar, 2020; Tighiz vd., 2020)
FRA	Kapasitif etki analize dahil edilebilmektedir.	-İnceleme altındaki transformatörün sağlıklı durumundaki FRA bilgilerine ihtiyaç duyar. - Genel olarak çevrimdışı bir yöntemdir. Transformatörün test için devre dışına alınması gereklidir. - Analiz için uzman görüşüne ve gelişmiş araçlara ihtiyaç duyar. -Yüksek maliyetli yöntemdir.	(Akhmetov vd., 2021; Bandaru vd., 2022; Holdyk vd., 2014; Khalili Senobari vd., 2018; Kumar vd., 2022; Moradzadeh vd., 2021, 2022; Moradzadeh ve Pourhossein, 2019; Yoon vd., 2021; X. Zhao vd., 2020; Z. Zhao vd., 2018)
Negatif Bileşen Akımı	-Arıza tespiti için sinyal kullanışlıdır	- Arızanın yerinin tespitinde yetersiz kalmaktadır.	(Farzin vd., 2019; Zacharias ve Gokaraju, 2016)
Kısmi Deşarj	- Elektrik arızası tespitinde köklü bir yöntemdir.	- Bu yöntemde tank ve sargıların sonuçlar üzerindeki etkisi fazladır.	(Mirzaei vd., 2013; Z. Zhang vd., 2023)
Akı Tabanlı Yöntem	- Hassasiyeti ve doğruluğu yüksektir.	- Doğrulama amacıyla geliştirilen modellerdir. - Transformatör yapısının ve sensörlerin detaylı bilgilerini gerektirir.	(Athikessavan vd., 2019; Haghjoo ve Mostafaei, 2016; Liu vd., 2007; Muraleedharan vd., 2019)
Gerilim ve Akım Ölçümü	- Doğrulama amacıyla geliştirilen modellerdir.	- Arıza tespitinde yetersizdir.	(P. Li ve Guo, 2022; Xian vd., 2024)

Çizelge 1.1 (devamı): Literatürde transformatör arızalarının belirlenmesi için kullanılan yöntemler.

Tespit Yöntemi	Avantajları	Kısıtlılıkları	Referanslar
Diferansiyel koruma	- Klasik ve güvenilir bir yöntemdir. - Çevrimiçi izleme mümkündür.	- Sargılar arasında oluşan ark arızası gibi başlangıç aşamasındaki arklar tespit edilememektedir. - Akım trafosunun hassasiyetine aşırı duyarlı bir yöntemdir. - Sargı yalıtımlarının bozulmasına karşı hassastır. - Transformatörün yapısına ve parametrelerine duyarlıdır.	(Medeiros vd., 2020; Oliveira vd., 2011; Oliveira ve Cardoso, 2010, 2012; Sheryar vd., 2022)
Mevcut Yapay Zekâ Yaklaşımları	- Az sayıda sargı arası arıza belirlenebilmektedir. - Eksik verilere karşı güvenilirdir.	- Ark arızaları yeterince incelenmemiştir. - Değişik tür transformatörler için henüz geliştirilmiş bir çalışma bulunmamaktadır.	(Duan vd., 2019; Obulareddy ve Munagala, 2021; Tripathy vd., 2007)
Titreşim Analizi	- Bu yöntem mekanik ve elektriksel arızaları tespit edebilir.	- Titreşim modeli karmaşıktır ve sensör gerektirir. - Sargı üzerine sensör monte edilmesini gerektirir.	(Hajiaghahi vd., 2021; Wang ve Sharma, 2021)
Diğer Yöntemler (Park vektör dönüşümü, Simetrik bileşenler)	- Faz akımı ölçülerek arızalar tespit edilir.	- Çevrimiçi algılama mümkündür. - Belirli arıza tespiti durumlarında hesaplamalar ve tepki süresi uzamaktadır.	(Ivanchenko ve Aleksey, 2018; Leal vd., 2020; C. Zhang vd., 2020)

Behjat ve Vahedi (2011), transformatör sargı kısa devre arıza koşulları altında çalışırken, gerçek bir güç transformatörünün geçici rejim davranışını karakterize etmek için, güç transformatörünün devre-kuplajlı zaman adımlı sonlu eleman modeli (SEY) geliştirmiştir. Arızalı transformatörün SEY modelini doğrulamak için, SEY transformatör simülasyonunda kullanılan transformatörle aynı özelliklere sahip bir transformatör kullanarak bir deney düzeneği kurulmuştur. Sonuçlar, modelin, sargılar arası oluşan arızaların analizi için başarılı olduğunu göstermektedir. Çalışmada, yük, besleme gerilimi,

arızanın şiddeti ve büyüklüğü gibi değişken koşullarda transformatör arızaları karakterize edilmiştir (Behjat ve Vahedi, 2011).

Fan vd. (2016) sargılar arası arızaları tespit etmek için dinamik durum tahmini (DSE) tabanlı koruma düzeni kullanmıştır. Bu yöntemde, transformatör terminal ölçümleri dikkate alınarak ölçüm verileri ve transformatör modeli dinamik durum tahmincisine aktarılır. Transformatör modelinin, ölçüm verileriyle eşleşme olasılığını (güvenirlilik düzeyi) değerlendirmek için chi-square testi kullanılmıştır. Model ile ölçüm verileri arasındaki herhangi bir uyumsuzluk, transformatörün içinde bir sorun olduğunu ve koruma önlemi alınması gerektiğini göstermektedir (Fan vd., 2016).

Frimpong vd. (2020), güç trafolarında sargılar arası kısa devre arızalarını tespit etmek için hem primer hem de sekonder hat akımlarından uyarma akımlarını ve negatif akım bileşeni örneklerini çıkararak, negatif akım bileşeni örneklerinin genliğini ve fazını 3 seviyeli dalgacık ayrıştırması yöntemi ile ayrı ayrı bulmuştur. Daha sonra bu veriler, analiz edilerek belirli işlemlere tabi tutulduktan sonra, uyarlanabilir nöro-bulanık çıkarım sistemine (Adaptive Neuro-Fuzzy Inference System-ANFIS) aktarılmıştır. Bu sistemin herhangi bir sargı arızası olup olmadığını belirleyen çevrimiçi bir yapı olarak kullanılabileceği belirtilmiştir. Ancak, bu yöntem sadece iletken teması şeklindeki rijit kısa devre durumu için uygulanmış ve deneysel doğrulama gerçekleştirilmemiştir (Frimpong vd., 2020).

Hammond vd. (2020) tarafından yapılan çalışmada, giriş parametresi olarak üç fazlı trafoya ait gerilim ve akım sinyalleri kullanılmış ve bu sinyaller, sürekli dalgacık dönüşümü (CWT) kullanılarak altılı skalogram görüntüsüne (akımlar ve gerilimler) dönüştürülmüştür. Elde edilen altılı skalogram görüntüsü normalize edilerek tek bir görüntüde birleştirilmiş ve birleştirilmiş görüntü daha sonra eğitilmiş bir evrimsel sinir ağına (CNN) aktararak, sargılar arası bir arızanın oluşup oluşmadığı incelenmiştir. Sargılar arası bir arıza tespit edildiğinde, arızanın büyüklüğü/şiddeti ve etkilenen faz belirlenebilmektedir. Ancak, ark arızası durumları için bir inceleme yapılmamıştır (Hammond vd., 2020).

Ehsanifar vd. (2021), trafonun yüksüz aktif güç kaybı (NLAPL) ve yüksüz reaktif gücünü (NLRP) inceleyerek arıza tespiti yapmıştır. NLAPL'nin ve NLRP'nin tek harmonik bileşenleri kullanılarak bulunan iki indeks olan aktif gücün toplam harmonik bozulmasını (THDAP) ve reaktif gücün toplam harmonik bozulmasını (THDRP), tek fazlı bir transformatör için incelemişler, elde edilen sonuçları doğrulamak için, fiziksel bir transformatör üzerindeki test sonuçlarını, ANSYS analizinin sonuçlarıyla karşılaştırmıştır.

Ancak bu yöntemde transformatörün yüksüz durumda bulunması gerekmektedir (Ehsanifar vd., 2021).

Granados-Lieberman vd. (2021), sargılar arası arıza durumunu diferansiyel akım spektrumu ve bir bulanık mantık (FL) sistemi aracılığıyla belirlemiştir. Spektrum tahmini için fazör ölçüm birimi (PMU) tabanlı bir şema kullanılmış, bulanık mantık sistemiyle de sürekli ve çevrimiçi arıza tespiti yapılmıştır. Yöntemin performansı, yüksüz, doğrusal yükler ve doğrusal olmayan yükler dahil olmak üzere farklı çalışma koşulları altında, 120/240 V'de çalışan 1.5 kVA tek fazlı transformatör kullanılarak test edilmiştir. Ancak, yöntem, 3 fazlı transformatöre ve ark arızalarına uygulanmamış olup, yöntemin primer ve sekonderden alınan bilgilerin senkronize olması durumuna çok duyarlı olması önemli bir kısıt oluşturmaktadır (Granados-Lieberman vd., 2021).

Hajiaghasi vd. (2021), transformatör sargıları arasında meydana gelen arızaların kaçak akı analizi yöntemi ile tespiti üzerine bir çalışma yapmış ve bu çalışmada yöntemin uygulanabilirliği ve hassasiyeti üzerine analizler sunmuştur. Çalışmada, kaçak akı ve titreşim analizine dayalı iki yeni çevrimiçi yöntem önerilmiştir. Birinci yöntemde arıza tespiti için arama bobinleri gerilim analizi kullanılmıştır. İkincisinde ise Dijital İvme Ölçer (ADXL) sensörü vasıtasıyla transformatörün titreşimi ölçülerek ve bu ölçüm, normal şartlardaki titreşim miktarıyla karşılaştırılarak, titreşim miktarındaki farklılığa göre arıza tespiti yapılmıştır. Ancak bu tip yöntemlerde, transformatörde belirgin düzeyde titreşim yapabilecek kuvvetli bir arıza gerçekleşmesi durumunda, arıza tespit yapılması mümkündür (Hajiaghasi vd., 2021).

Munagala (2021), yaptığı çalışmada, zaman-frekans bölgesinde sürekli dalgacık dönüşümü kullanarak transformatörün darbe test yanıtlarının önemli özelliklerini elde etmek için bir yaklaşım ortaya koymuş ve bu yaklaşımda elde edilen veriler rastgele örnekleme ile dengelenmiştir. Bu çalışmada, arıza akımı verilerini sınıflandırmak için üç tip sınıflandırma algoritmasının performansı karşılaştırılmış, eğitim doğruluğuna dair kapsamlı sonuçlar, topluluk algoritmasının diğer sınıflandırıcılar arasında en iyi performansı gösterdiğini, topluluk sınıflandırıcının tahmin oranının olasılık eğrisi ile temsil edildiğini ve sınıflandırıcı algoritmaların tahmin doğruluğunun, gerçek pozitif orana dayalı olarak sunulduğunu ortaya koymaktadır (Obulareddy ve Munagala, 2021).

Behkam vd. (2022) tarafından yapılan çalışmada, dağıtım trafosu sargılarında arıza tipi tespiti için FRA ile elde edilen frekans cevabı bileşenleri kullanılmış, her bir arıza tipi,

arıza konumu ve sargılar boyunca arıza kapsamıyla ilgili frekans yanıtlarındaki değişikliklerin gösterilmesi için uygun istatistiksel endekslere dayalı ısı haritaları oluşturulmuştur. Bu veriler yardımıyla, YSA kullanılarak elde edilen sonuçlara göre, genelleştirilmiş regresyon sinir ağı yönteminin trafo sargı arızalarının sınıflandırılmasında en etkili çözüm olduğu ifade edilmiştir. Ancak, bu yöntemde FRA analizi için transformatörün şebekeden ayrılması gerekmektedir (Behkam vd., 2022).

Transformatör sargılarında gelişen arklarla ilgili sınırlı çalışmalardan biri olan ve Yan vd. (2022) tarafından yapılan çalışmada, transformatör sargıları arasında meydana gelen ark arızalarına yönelik olarak, SEY devre kuplajlı ve zamanla değişen ark iletkenliğini hesaplamak için Schavemaker modelinin doğrudan entegrasyonunu mümkün kılan bir model oluşturulmuştur. Bir güç transformatörünün simülasyon modeli kullanılarak akı dağılımı, kısa devre dolaşım akımı ve uç akımları tespit edilmiş olup, terminal akımının özelliğini çıkarmak için Ayırık Zamanlı Wavelet analizi (Discrete Wavelet Transforms, DWT) kullanılmıştır. Sonuçlar, önemli akım bozulmalarının dalgacık katsayısı değişimlerine yansıdığını göstermiş, arkın özelliklerinden dolayı, detay katsayılarındaki birkaç periyodik keskin artışın, kısa devre akımının sıfır geçiş noktalarına tam olarak karşılık geldiği gösterilmiştir. Yöntemin, transformatör arızalarını tespit etmek için ayırt edici özellikler sağlar nitelikte olduğu ve aynı zamanda koruma performansını iyileştirmek için etkili bir araç olarak da hizmet edebileceği değerlendirilmiştir. Ancak, ark arızası tespitine yönelik çalışma kapsam olarak sınırlı düzeyde kalmıştır (Yan vd., 2022).

Bjelić vd. (2022), transformatör arızalarının belirlenmesi için akustikte yaygın olarak kullanılan, yankılanma süresine (reverberation time) dayalı yeni bir gösterge önermiştir. Önerilen parametre, zaman alanı hesaplamasına dayalıdır ve trafo izolasyonunda meydana gelen kısa devre arızalarının güvenilir bir şekilde tespit edilmesi ve arızaların büyüklüklerinin doğru tahmin edilmesi sağlanmıştır. Önerilen yaklaşımın önemli bir avantajı, düşük maliyetli ölçüm ve sinyal işleme cihazlarının kullanılmasına imkân vermesi ve ölçülen sinyalin frekans aralığına bağımlılığının düşük olmasıdır. Ancak, yöntem, sistem enerjili durumdayken online olarak çözüm sunmamaktadır (Bjelić vd., 2022).

Zhu vd. (2023) tarafından, gerçek bir yağlı transformatörün mekanik ve elektromanyetik karakteristiği dikkate alınarak, ANSYS ortamında SEY sargılar arası arıza analizi yapılmıştır. Elde edilen verilere ek olarak transformatör muhafazası üzerindeki titreşimler ile arızanın tespitine yönelik çalışmalar yapılmıştır. Ancak, çalışmada ark arızası durumları incelenmemiştir (Zhu vd., 2023)

Elektriksel stres nedeniyle transformatörde meydana gelen iki ana elektriksel aktivite ark ve kısmi deşarjdır (korona) (Abu-Siada ve Hmood, 2015). Yağlı tip transformatörlerde geçerli olan yağda kısmi boşalma (Partial Discharge-PD), izolasyon yağında çok sayıda mikrokabarcığın asılı kalmasıyla ortaya çıkan düşük seviyeli bir enerji aktivitesidir (yaklaşık 700 °C). Bu tekli elektrik deşarjları 1 ms'den kısa sürmektedir. Yalıtım kağıdında kısmi boşalma ise, iletkene bitişik kâğıt sargılarına küçük deliklerin girmesiyle başlamaktadır. Ark ise 800-1200 °C sıcaklık aralığında yüksek enerjili deşarjın neden olduğu uzun süreli bir elektrik deşarjdır (Mehta vd., 2011). Arızalar sırasında elektriksel ve termal gerilimlerden dolayı yağ ve kâğıt ayrışması meydana gelir. Bu ayrışma sonucunda trafo yağının ısı dağıtma kabiliyetini ve dielektrik dayanımını azaltan bazı gazlar açığa çıkar (Thiviyanathan vd., 2022). Kısmi deşarjın yan ürünleri arasında hidrojen (H_2), eser miktarda metan (CH_4) ve eser miktarda asetilen (C_2H_2) yer alır. Yağ emdirilmiş yalıtım kağıdındaki kısmi deşarj reaksiyonundan ayrıca karbon monoksit (CO), karbon dioksit (CO_2) ve H_2 gazlarının bir kombinasyonu da üretilmektedir (Mehta vd., 2011)

Kısmi deşarj reaksiyonu aynı zamanda nem ve deşarj edilen parçacıklar (iyonlar, elektronlar) gibi başka yan ürünler de üretir. Bu yan ürünler, yalıtım yağının yaşlanma sürecini hızlandırmanın yanı sıra, iyon ve elektron bombardımanı yoluyla yalıtım kağıdının durumunu kötüleştirir (Lan vd., 2019). Öte yandan ark, az miktarda etan (C_2H_6), etilen (C_2H_4), H_2 , CH_4 ve büyük miktarda C_2H_2 gazı üretir (Abu-Siada ve Hmood, 2015). Hem ark hem de kısmi deşarj H_2 , CH_4 ve C_2H_2 gazları üretir. Bununla birlikte, sayısal teşhis yöntemleri, CH_4 ve H_2 gazlarının büyük miktarda birikmesinin, yağda kısmi boşalmanın meydana geldiğini gösterdiğini ortaya koymuştur (Ahmed vd., 2013; G. M. Ma vd., 2014; Sun vd., 2012). Büyük miktarda C_2H_2 ve H_2 kombinasyonu ise yağda ark reaksiyonunun meydana geldiğini göstermektedir (Ahmed vd., 2013; Haema ve Phadungthin, 2013) Transformatör yağının DGA, en etkili güç transformatörü durum izleme araçlarından biri olmasına ve DGA sonuçlarına yönelik pek çok yorumlama tekniği bulunmasına rağmen bu tekniklerin tamamı standart matematiksel formüllerden çok personel deneyimine dayanmakta ve önemli sayıda DGA sonucu mevcut yöntemlerin önerilen kodlarının dışında kalmakta ve bu yöntemlerle teşhis edilememektedir.

Yağdaki reaksiyonların teşhisinde belirsizlikler bulunduğundan, gaz kombinasyonunun kesin bir şekilde yorumlanamaması, güç transformatöründe bu yöntemle durum izlenmesinde bir zorluk olarak görülmeye devam etmektedir (Abu-Siada ve Islam, 2012). Bustamante vd. (2019) tarafından yapılan derleme çalışmada, DGA gaz tespit

tekniklerinin her birinin genel olarak bir testi tamamlamak için uzun süre gerektirmesi, masraflı olması, sık kalibrasyonlar gerektirmesi, yardımcı (taşıyıcı) gazı ihtiyaç bulunması, bakım maliyetlerinin yüksek olması, sıcaklık, basınç ve titreşimden etkilenen doğruluk derecesinin olması, yüksek gaz konsantrasyonlarını ölçme yeteneği sınırlaması, parazit yapan gazların doğruluğu etkileyebilmesi ve çok düşük veya çok yüksek gaz konsantrasyonlarını tespit etme yeteneğini sınırlaması gibi kısıtlardan bir kaçına sahip bulunduğu belirtilmiştir (Bustamante vd., 2019). Faizol vd. (2023) tarafından yapılan çalışmada başlıca zorluklardan birinin kısmi deşarj PD tespitinde yüksek hassasiyet ve doğruluk elde edilmesi olduğu ve PD sinyallerinin zayıf olabileceği ve gürültü tarafından kolayca maskelenebileceği, bu durumun bunların tespit edilmesini ve diğer sinyallerden ayırt edilmesini zorlaştırabileceği belirtilmiştir. Ayrıca, gaz miktarı ölçümü yalnızca yağlı tip transformatörlerde yapılabilmekte bu nedenle, kuru tip transformatörlerde DGA'ya dayalı yöntemler kullanılamamaktadır (Faizol vd., 2023).

Akım/gerilim rms sinyallerine dayanan diferansiyel koruma, güvenilirliği, kesinliği ve çalışma hızı nedeniyle çoğu güç transformatörünün birincil koruması olarak uzun yıllardır kullanılmaktadır (Meira vd., 2018). Transformatörün içinde kaçak akımların olmadığını doğrulamak için transformatörün primer ve sekonder akımlarının rms değerlerinin karşılaştırılmasından oluşur. Bu tür korumadaki en önemli sınırlama, geçici rejim koşulları altında doğru teşhislerin elde edilememesidir. Transformatörün elektrik şebekesine bağlantısı sırasında veya transformatöre gelen harici arızaların akım transformatörlerinin (CT) doymasına neden olduğu durumlarda diferansiyel röle hatalı alarm verebilmektedir (Eissa, 2005). Bu tür korumanın diğer bir sınırlaması, yalnızca yüksek oranda bobin sarımı söz konusu olduğunda veya faz-toprak arızası olduğunda arıza tespitinin etkili olmasıdır (Guzmán vd., 2009). Az sayıda sarım arasında veya yüksek sınırlayıcı empedanslı arızalarda teşhis kapasiteleri önemli oranda etkilenmektedir (Blackburn ve Domin, 2006).

Literatür incelemesinde, son yıllarda transformatör sargı arızalarının belirlenmesine yönelik çalışmaların özellikle frekans tepki analizine (Frequency Response Analysis-FRA) dayalı yöntemler üzerinde yoğunlaştığı görülmektedir (Khalili Senobari vd., 2018; Moradzadeh vd., 2021, 2022; Moradzadeh ve Pourhossein, 2019; Yoon vd., 2021; X. Zhao vd., 2020). FRA iki tipte olabilir: düşük gerilim darbe yöntemi (LVI) veya tarama frekansı yanıt analizi (SFRA). SFRA yönteminde genel olarak SFRA-Sweep Frequency Response Analyzer cihazı yardımıyla transformatör uçlarından yapılan bağlantılar vasıtasıyla transformatörün frekans cevabı elde edilmekte ve bu frekans cevabındaki değişim dikkate

alınarak çeşitli teknikler kullanılarak transformatörde sargılar arası bir arıza durumunun olup olmadığı anlaşılabilmektedir. Bu çalışmaların çoğunda, transformatör çevrimdışı (offline) durumdayken, yani devre dışına alındıktan sonra, yapılan testler neticesinde arıza tespiti yapılabilmiş, bununla birlikte daha sonra yöntem çevrimiçi olarak da hata tespiti amacıyla kullanılmıştır (Zhao vd., 2020). Ancak, bu yöntem her transformatör için oldukça pahalı olan SFRA cihazının bağlantısını gerektirmekle birlikte, ancak arıza olduğu şüphelenilen bir transformatörde arıza teyidi amacıyla kullanılması uygun olabilecek bir yöntem durumundadır. FRA ile çözüm sağlayan çalışmalardan Khalili Senobari vd. (2018) tarafından yapılan çalışmada, FR dayalı YSA kullanılarak yüksek empedans aşamasında transformatör sargılarındaki sargı ark arızalarının erken tespiti incelenmiştir. Çalışmada düşük empedanslı ve yüksek empedanslı kısa devre arızaları sargı modeli üzerine çeşitli konumlarda uygulanmış ve bunların FR hesaplanmıştır (Khalili Senobari vd., 2018). Moradzadeh ve Pourhussein (2019) yaptıkları çalışmada, yüksek empedans aşamasında FR dayalı YSA kullanarak, transformatör sargılarındaki sargı arızalarını erken tespit etmeyi amaçlamışlardır. Bu amaçla, önerilen yaklaşımın yeterliliğini doğrulamak için test nesnesi olarak bir sargı model kullanılmıştır. Sargı modelinde çeşitli düşük empedanslı ve yüksek empedanslı kısa devre arızaları test edilebilmiş, daha sonra sargının hem sağlam hem de arızalı durumdaki FR Düşük Gerilim Darbe (LVI) testi kullanılarak ölçülmüştür. Çok katmanlı algılayıcı (MLP) sinir ağı kullanılarak FR ile her hatanın kesin konumu arasındaki haritalama yapılmıştır. Frekans yanıtlarından çıkarılan özellikler, önerilen MLP'yi eğitmek ve test etmek için kullanılmıştır. Sonuçlar, bu yöntemin trafo sargısındaki sarımlar arası arızaları erken aşamada bile tespit edebildiğini göstermiştir. Ancak bu çalışmalarda erken safhadaki ark arızası durumu ele alınmamıştır ve ayrıca yöntem genel olarak transformatörün devreden alınmasını ve laboratuvar şartlarında testini gerektirmektedir (Moradzadeh ve Pourhossein, 2019).

Literatürdeki bazı çalışmalar, herhangi bir sinyal işleme yönteminin trafolarda farklı arızaların belirlenmesi için tek başına yeterli olmadığını göstermiştir (Frimpong vd., 2020; Hammond vd., 2020). DWT ve CWT sinyal işleme yöntemleri ile birlikte ANFIS ve CNN gibi makine öğrenme teknikleri de kullanılmıştır. YSA doğrusal olmayan karmaşık problemlerin çözümünde etkili bir araçtır (Moradzadeh ve Pourhossein, 2019).

Transformatör sargı arızaları konusundaki ilgili literatür incelendiğinde, genel olarak yapılan çalışmaların iletken teması şeklindeki rijit kısa devre arızalarını kapsadığı, ancak ark arızasının tespiti konusunda yeterli çalışma yapılmadığı, çalışmaların genel olarak tek faz

transformatörler modellenerek veya test edilerek yapıldığı, çalışmaların çoğunlukla transformatörün devreden alınmasını gerektirdiği, arıza çeşitlerinin kısıtlı noktalardaki sargılar arası arızaları kapsadığı veya sensör yardımıyla transformatör önemli zararlar gördükten sonra tespit edildiği görülmüştür.

Bu tezde, transformatör ve ark modelleri eş zamanlı olarak kuplajlanarak sargılarda ark arızası oluşturulmuştur. Ark arızası, giriş terminallerinden elde edilen akım/gerilim sinyallerinin geçici rejim etkilerini FFT uygulayarak harmonik bilgileri çıkarıldıktan sonra, MÖ algoritmaları kullanılarak arızalı sargı veya arızalı diske tahmin algoritması modeli geliştirilmiştir. Elde edilen sargı ve disk MÖ modelleri sayesinde ark tespit erken tespiti sağlanmıştır. Ayrıca, transformatördeki arızanın sistemden eş zamanlı alınan akım/gerilim sinyalleriyle tespit edilmesi, hem transformatörün sistemden ayrılmadan arızanın belirlenmesini hem de sensör kullanılmadan, erken aşamada ve transformatörün güvenli bir şekilde çalışmasına olanak sağlamıştır.

2. TRANSFORMATÖRLER MODELLENMESİ

Transformatörler elektrik enerjisinin gerilim seviyesini değiştirmek amacıyla kullanılan cihazlardır ve modern elektrik dağıtım sistemlerinin temel taşlarından biridir. Transformatörlerin gelişim süreci, elektromanyetik indüksiyonun keşfiyle başlamış ve günümüzün modern cihazlarına dönüşene kadar birçok önemli aşamadan geçmiştir. Bu bölümde, transformatörlerin teorisi ve çalışma prensibi özetlenecek, çalışmada kullanılan güç transformatörünün yapısı, parametreleri ve tasarımı açıklanacaktır.

2.1 Transformatörün Tarihçesi

Transformatörlerin tarihçesi, Michael Faraday'ın 1831 yılında elektromanyetik indüksiyon yasasını keşfetmesiyle başlar. Faraday, manyetik bir alanın bir elektrik devresinde akım indükleyebileceğini göstermiştir (Faraday, 1831). Bu keşif, transformatörlerin temel çalışma prensibini oluşturmuş ve elektrik enerjisinin iletimi ve dönüşümü için kritik bir buluş olarak kabul edilmiştir.

1880'lerde, Fransız mühendis Lucien Gaulard ve İngiliz mühendis John Dixon Gibbs, ilk pratik transformatörlerden birini geliştirip ve bu cihazı Londra'da tanıtmışlardır (Gaulard ve Gibbs, 1882). Bu transformatör, alternatif akım (AC) sistemlerinde kullanılmak üzere tasarlanmıştır ve elektrik enerjisinin farklı gerilim seviyelerine dönüştürülmesini sağlamıştır. Bu dönemde, George Westinghouse, Nikola Tesla ve William Stanley gibi isimler, transformatör teknolojisini daha da geliştirerek ticari kullanıma uygun hale getirmişlerdir (Westinghouse, 1886).

Transformatörlerin yaygınlaşmasında en önemli adımlardan biri, George Westinghouse'un Nikola Tesla'nın alternatif akım (AC) sistemlerini benimsemesiyle atılmıştır. Tesla'nın patentleri ve Westinghouse'un girişimleri, AC sistemlerinin dünya genelinde benimsenmesini sağlamıştır (Tesla, 1888). AC sistemleri, elektriğin uzun mesafelerde düşük kayıplarla iletilmesine olanak sağlarken, transformatörlerin enerji dönüşümünü farklı gerilim seviyelerinde gerçekleştirmesine imkan tanımıştır. Bu durum,

elektrik dağıtımını hem daha verimli hale getirmiş hem de enerjinin geniş coğrafi bölgelere kolayca ulaştırılmasını mümkün kılmıştır.

Günümüzde transformatörler, enerji üretiminden son kullanıcıya kadar pek çok alanda yaygın bir şekilde kullanılmaktadır. Güç transformatörleri, enerjinin yüksek gerilim seviyelerinde iletilmesini sağlarken, dağıtım transformatörleri ise enerji dağıtım şebekelerinde önemli bir rol üstlenmektedir. Bunun yanı sıra, özel uygulamalara yönelik tasarlanmış çeşitli transformatör türleri de mevcuttur. (Hurley ve Wölfle, 2013)


2.2 Transformatörler

Elektrik enerji sistemlerinin bileşenleri arasında, transformatörler boyut, ağırlık ve maliyet açısından en yüksek değerlere sahip cihazlardır. Bu nedenle, transformatör tasarımı, devre parametrelerinin belirlenmesi ve fiziksel özelliklerinin optimum seviyede olması büyük önem taşır.

2.2.1 Transformatör elektriksel modeli

Transformatörler, elektrik enerjisinin gerilim seviyesini değiştirmek için kullanılan elektriksel cihazlardır. Temel çalışma prensipleri, elektromanyetik indüksiyon yasasına dayanır. Transformatörün manyetik modeli, transformatörün içindeki manyetik alanların ve bu alanların sargılar üzerindeki etkilerinin anlaşılmasını sağlar.

Bir transformatör, genellikle manyetik bir çekirdek ve bu çekirdek üzerinde sarılı iki veya daha fazla sargıdan oluşur. Primer sargıya uygulanan alternatif akım (AC) bir manyetik alan oluşturur. Bu manyetik alan, çekirdek boyunca hareket eder ve sekonder sargıda bir gerilim indüklenir. Bu süreç, Faraday'ın elektromanyetik indüksiyon yasasına uygun olarak gerçekleşir. Bir fazlı ideal transformatörlerin şematik gösterimi Şekil 2.1'te verilmiştir.



Şekil 2.1 : Bir fazlı ideal transformatör.


$$V_1 = R_1 I_1 + jX_1 I_1 + jX_m I_m + R_c I_c \quad (2.5)$$

$$V_2 = R_2 I_2 + jX_2 I_2 \quad (2.6)$$

Burada I_1 primer akımı, I_m manyetik akı akımı, I_2 sekonder akımı ve I_c manyetik çekirdek kayıp akımıdır.

2.2.2 Transformatör manyetik modeli

Transformatörlerin manyetik modeli, elektrik devresi benzeri bir yaklaşımla incelenebilir. Manyetik devre, manyetik alanın akış yolunu ve bu alana karşı gösterilen manyetik direnci tanımlar. Şekil 2.3, Denklem (2.7)'deki ortalama uzunluğu l_c , manyetik alan yoğunluğunu H , sargıdan akım i ve kesit alanı A_c olan kapalı bir manyetik çekirdek üzerine N sarım sayısını belirtmektedir.



Şekil 2.3 : Nüve ve sargıları olan manyetik devre.

$$\oint_c \phi = H \cdot dl = Ni \quad (2.7)$$

Ohm'un elektrik devreleri için tanımladığı yasa, manyetik devrelerde de benzer şekilde uygulanır:

$$\mathcal{F} = \Phi \cdot \mathcal{R} \quad (2.8)$$

burada $\mathcal{F}$ manyetomotor kuvveti, Φ manyetik akıyı ve $\mathcal{R}$ ise relüktansı ifade etmektedir. Relüktans şu şekilde hesaplanır;

$$\mathcal{R} = \frac{l}{\mu A} \quad (2.9)$$

burada l manyetik devre uzunluğunu, μ nüve malzemesinin manyetik geçirgenliğini ve A manyetik devrenin kesit alanını ifade etmektedir. Transformatör çekirdeğinde oluşan manyetik alan, çekirdek malzemesinin manyetik özelliklerine bağlıdır:

$$B = \mu H \quad (2.10)$$

Bu denklemde B manyetik akı yoğunluğunu temsil etmektedir. Transformatör çekirdeği belirli bir manyetik akı yoğunluğuna ulaştığında doygunluk noktasına gelir. Bu noktadan sonra, çekirdeğin manyetik geçirgenliği azalır ve manyetik akı yoğunluğunda doğrusal olmayan artışlar gözlemlenir. Çekirdek doygunluğu, transformatörün verimliliğini olumsuz etkileyebilmektedir (Smith, 2010).

2.2.3 Transformatör kayıpları

Transformatörlerde demir kayıpları, bakır kayıpları, histerezis kayıpları, girdap akımı kayıpları, kaçak kayıplar ve dielektrik kayıplar gibi farklı kayıp türleri bulunmaktadır.

Çekirdek kayıpları, transformatör çekirdeğinde meydana gelen enerji kayıplarıdır ve iki temel kaynaktan gelir: Histerezis kayıpları ve girdap akımı (eddy current) kayıplarıdır. Histerezis kayıpları, transformatör çekirdeğinde kullanılan manyetik malzemelerin manyetik alan değişimlerine maruz kalması sonucunda oluşur. Çekirdeğin manyetik malzemesi sürekli olarak mıknatıslanıp de mıknatıslanmaya zorlandığında bir miktar enerji kaybolur. Bu enerji kaybı, çekirdek malzemesinin histerezis eğrisine bağlıdır. Histerezis kayıpları şu denklemle hesaplanır:

$$P_h = \eta V B_m^n f \quad (2.11)$$

burada, P_h histerezis kaybı gücünü, η malzemenin histerezis kayıp katsayısını, V çekirdek hacmi, B_m^n maksimum manyetik akı yoğunluğunu ve f ise frekansı temsil etmektedir. (Jiles, 2015), Bu kayıpların hesaplanmasında kullanılan histerezis modellerinin önemini vurgulamıştır. Çekirdek malzemesinin özelliklerine bağlı olarak bu kayıplar, frekans ve akı yoğunluğu ile doğru orantılıdır. Girdap kayıpları, transformatör çekirdeğinde değişen manyetik alanların indüklediği girdap akımlarından kaynaklanır. Bu akımlar, çekirdek malzemesinde enerji kaybına neden olur ve girdap kayıpları şu denklemle ifade edilir:

$$P_e = k_e V f^2 t^2 B_m^2 \quad (2.12)$$

denklemden P_e Fuko akım kayıplarını, k_e fuko kayıp katsayısını, t çekirdek levhasının kalınlığını ifade etmektedir. Fuko kayıplarını minimize etmek için transformatör çekirdeklerinde ince silikon çeliği levhalar kullanılır. Kulkarni ve Khaparde (2013), manyetik devrelerde fuko kayıplarını azaltmak için lamine çekirdek yapıların kullanılmasının önemini vurgulamıştır (Kulkarni ve Khaparde, 2013).

Bakır kayıpları, transformatörün birincil ve ikincil sargılarında meydana gelir. Bu kayıplar, sargılardan geçen akımların sebep olduğu Joule ısınması nedeniyle oluşur ve direnç kayıpları olarak da bilinir. Bakır kayıpları, sargılardaki akımın karesi ile sargıların direncinin çarpımıyla aşağıdaki gibi hesaplanır:

$$P_c = I^2 R \quad (2.13)$$

Kaçak kayıplar, transformatörün sargıları ve çekirdeği arasında meydana gelen kaçak akımlarından kaynaklanır. Bu kayıplar, özellikle yüksek frekanslı uygulamalarda belirgin hale gelir. Kaçak kayıpları şu şekilde ifade edilir:

$$P_k = I_k^2 R_k \quad (2.14)$$

burada P_k kaçak kayıpları, I_k kaçak akımı ve R_k ise kaçak akım direncini ifade etmektedir. Kulkarni ve Khaparde (2013), kaçak kayıplarının transformatörün toplam kayıpları içindeki etkisinin göz ardı edilmemesi gerektiğini vurgulamaktadır. Bu kayıpları azaltmak için uygun izole edici malzemeler kullanılması önerilmektedir (Kulkarni ve Khaparde, 2013).

Dielektrik kayıplar, transformatörün yalıtım malzemelerinde meydana gelir. Alternatif akımın etkisi altında, yalıtım malzemeleri bir miktar enerji kaybeder. Dielektrik kayıplar şu denklemle ifade edilir:

$$P_d = \varepsilon_r E^2 V_i f \quad (2.15)$$


Burada P_d dielektrik kayıpları, ε_r malzemenin dielektrik sabitini, E elektrik alanı ve V_i yalıtım hacmi ifade etmektedir. Yapılan bir çalışmada dielektrik kayıpların, transformatör verimliliği üzerindeki etkisini incelenmiş ve uygun yalıtım malzemelerinin seçiminin önemine vurgu yapılmıştır (Jiles, 2015).

2.3 Transformatör ANSYS@Maxwell Modeli

Maxwell yazılımları, SEY'e dayalı olarak ANSYS ortamında transformatörlerin 2D ve 3D modellerinin oluşturulmasına olanak tanımaktadır. Bu yazılım, transformatörlerin elektromanyetik akı yoğunlukları, elektromanyetik akı dağılımları, çekirdek kayıpları, termal analizler, kaçak akılar, radyal ve eksensel etki eden kuvvetler ile harmonik hesaplamaları gibi birçok geçici ve kararlı durumu hakkında hızlı ve nispeten güvenilir sonuçlar sunarak önemli bilgiler sağlamaktadır. Bu program, analiz edilecek geometrinin tüm bileşenlerine yönelik doğru, verimli ve uygun bir ağ yapısını otomatik olarak oluşturarak problemi çözmeye yardımcı olur. Otomatik uyarlanabilir ağ oluşturma (meshing) işlemi, çözüm sürecindeki karmaşıklığı azaltır ve daha etkin bir tasarım süreci sağlar. ANSYS@Maxwell arayüzü, ANSYS-PExprt ve Ansys-RMxprrt gibi tasarım platformlarını da içerir. ANSYS@Maxwell'in en önemli özelliklerinden biri, SEY çözümlerinden ANSYS@Simplorer ile kullanılmak üzere modeller üretebilmesidir. Bu özellik, karmaşık devreleri Maxwell'in detaylı bileşen modelleriyle entegre ederek güçlü bir elektromanyetik tabanlı tasarım süreci sağlamaktadır.

2.3.1 Geçici (Transient) transformatör modelinin oluşturulması


Maxwell 3D ortamında manyetik ve elektriksel çözümleme modelleri oluşturulmaktadır. Bu çalışma, sargılardaki ark arızasının geçici analizlerine dayandığı için hem elektriksel hem de manyetik değişimlerin önemli olduğu göz önünde bulundurularak tam geçici rejim (transient) modeli kullanılmıştır. ANSYS@Maxwell içerisinde çözümleme modelleri Şekil 2.4'te yer verilmiştir. Manyetik ve elektriksel modellerin çözümlemesi bu analizlerle yapılmaktadır. Sabit elektriksel alan, doğru akım iletimi ve zamanla değişen elektriksel alanların incelenmesi için **Electric** kısmı seçilmelidir. Sabit manyetik alanların analizi, girdap akımlarının AC etkilerinin analizi ve zamanla değişen manyetik alanların dinamik analizi (ör. anahtarlama veya kısa devre olayları) **Magnetic** kısmı seçilmelidir.



Şekil 2.4 : Maxwell çözümleme modelleri.

2.3.2 Nüve yapısının oluşturulması

Transformatör nüve yapısı Maxwell 3D ortamında çözümleme modeli ayarlandıktan sonra **Draw** menüsünden model kalıpları ve şekilleriyle oluşturabilir. Bunun yanında hazır Ansys-PEprt ve Ansys-RMxpert platformlarından da modeller istenilen modelin oluşturulmasında büyük kolaylık sağlar. Çekirdek yapısı oluşturmak için **View>User>Defined Primitive>RMxpert>TransCore** seçeneğinden hazır model yapısı oluşturulur. Oluşturulacak transformatörün çekirdek yapısını oluşturan bilgilerin girildiği **TransCore** Şekil 2.5'te gösterilmektedir. Şekilde, transformatörün manyetik çekirdek bileşeninin tanımlayıcı özellikleri yer almaktadır. Bu özellikler arasında ayak çapı, ayak mesafesi, boyunduruk mesafesi, katman sayısı ve çekirdek kalınlığı bilgileri bulunmaktadır.




Şekil 2.5 : Nüve modelinin oluşturulması.

2.3.3 YG ve AG sargılarının oluşturulması


Transformatör çekirdek yapısına benzer modeller, Draw menüsünden model kalıpları ve şekilleri seçilerek veya **View > User > Defined Primitive > RMxport > TransCoil** yolu izlenerek oluşturulabilir. Bu çalışmada, kullanılan sargı modelleri detaylı bir şekilde ele alınmış ve her bir disk bağımsız olarak tasarlanmıştır.

ANSYS@Maxwell ortamında oluşturulan transformatör sargı modelindeki YG sargıları Şekil 2.6’da gösterilmektedir. Şekilde, YG sargılarının disklerden oluşan üç boyutlu yapısı gösterilmektedir. Sargılar, sırasıyla C, A ve B sargıları olarak belirlenmiştir. AG sargılarının kalıp boyu 951 mm, iç genişliği ve derinliği 441 mm, kalınlığı 74 mm olup 11 diskten oluşan bir üç boyutlu yapıya sahiptir. YG sargılarının kalıp boyu 951 mm, iç genişliği ve derinliği 614 mm, kalınlığı 99.5 mm olup 11 diskten oluşan bir üç boyutlu yapıya sahiptir.



Şekil 2.6 : Sargı modelinin oluşturulması (YG sargıları).

Transformatörde AG sargılarının üzerine YG sargıları sarılmıştır. YG ve AG sargılarının üstten görünüşü Şekil 2.7’de yer verilmiştir. Turkuaz renkle gösterilen sargılar AG sargılarını ve Turuncu sargılar ise YG sargılarını ifade etmektedir.




Şekil 2.7 : AG ve YG sargılarının (üstten görünüm).

2.3.4 Malzeme seçimi

Transformatöre ait modelin nüve ve sargılıları bilgilerinin girilmesiyle boyutsal olarak tamamlanmıştır. Ancak, analizler için malzemenin seçimi oldukça önemlidir. Transformatör nüvesi için M125_027S malzemesi seçilirken, sargılar için bakır malzemesi kullanılmıştır.

Nüvenin M125_027S materyalinin seçimi Şekil 2.8’de gösterilmiştir. ANSYS@Maxwell kütüphanesinde yer almadığından dolayı materyal manuel olarak kütüphaneye eklenir. Bunun için **Assing Material>Add Material>Relative Permability>Nonlinear>Core Loss Model>Electrical Steel** menüsünden B-H karakteristik verileri girilir. Bu işlemin ardından **Core Loss at One Frequency** seçeneğiyle de B-P karakteristiği verileri ile materyale ait etiket bilgileri eklenir.



Şekil 2.8 : M125_027S nüve malzemesinin seçilmesi.

M125_027S malzemesi bilgisi Şekil 2.9’da gösterilmektedir. Gerekli çalışma frekansı seçildikten sonra, B-H ve B-P eğrileri kütüphaneye yüklenir. Yükleme işleminin ardından, malzemenin iletkenliği ve yoğunluğu girildikten sonra K_c ve K_h laminasyona ait parametreler program tarafından hesaplanır. Bu hesaplamalar manyetik, nüve kayıpları ve termal analizler için oldukça önemlidir.

Material Name: m125_027 Material Coordinate System Type: Cartesian

Properties of the Material

Name	Type	Value	Units
Relative Permeability	Nonlin	B-H Curve...	
Bulk Conductivity	Simple	0	siemens...
Magnetic Coercivity	Vector		
- Magnitude	Vector...	0	A_per...
- X Component	Unit V...	1	
- Y Component	Unit V...	0	
- Z Component	Unit V...	0	
Core Loss Model	Electrical Steel	w/m ³	
- Kh	Simple	65.4889503704...	
- Kc	Simple	0.59957846736...	
- Ka	Simple	0	
- Kdc	Simple	0	
- Equiv. Out Depth	Simple	0	fm
Mass Density	Simple	7650	kg/m ³
Composition	Solid		
Young's Modulus	Simple	0	N/m ²
Poisson's Ratio	Simple	0	
Magnetostriction	Custom	Edit...	

Notes:

Calculate Properties for:

Reset OK Cancel

View/Edit Material for:

☒ Active Design
☐ Active Project
☐ All Properties

Physics:

☒ Electromagnetic
☐ Thermal
☐ Structural

View/Edit Modifier for:

☐ Thermal Modifier

Material Appearance:

☐ Use Material Appearance


Color:

Transparency:


Validate Material

Şekil 2.9 : M125_027S malzemesi bilgisi.


Nüve materyalinin doğrusal olmayan B-H karakteristik eğrisi Şekil 2.10'da sunulmuştur. Bunun yanı sıra, materyalin B-P kayıp eğrisi ile kütle yoğunluğu, lamine kalınlığı, frekansı ve iletkenlik gibi özelliklere ilişkin bilgiler Şekil 2.11'de verilmiştir. Yüksek Gerilim (YG) ve Alçak Gerilim (AG) sargılarında kullanılan bakır materyali, ANSYS@Maxwell kütüphanesinde tanımlı olduğundan, bu materyale ait veriler doğrudan kullanılmıştır. Bakır materyalinin detaylı malzeme bilgileri ise Şekil 2.12'de gösterilmiştir.



Şekil 2.10 : M125_027S malzemesi B-H karakteristiği.




Şekil 2.11 : M125_027S malzemesine ait B-P kayıp karakteristiği ve materyal bilgileri.



Şekil 2.12 : Bakır materyal bilgileri.

2.3.5 Elektromekanik analiz için kuvvet analizlerinin oluşturulması

Güç transformatörlerinde oluşan elektromanyetik kuvvetler, yerel manyetik akı yoğunluğuna göre hesaplanmaktadır. Sargılardaki kaçak akıyı belirlemek amacıyla SEY kullanılır. Transformatör sargılarından geçen geçici kısa devre akımları, elektromanyetik kuvvetlerin hesaplanmasında kritik bir rol oynamaktadır. Kısa devre durumu, sistemde çok yüksek akımların aktığı bir arıza hali olarak tanımlanır ve bu durumda sistemden geçen akım, nominal akımdan çok daha fazla olmaktadır. Maxwell 3D ortamında tüm nüve ve sargılarla ilgili işlemler yapıldıktan sonra **Edit>Select All** yardımıyla tüm yüzeler seçilir ve **Maxwell> Parameters>Assign>Force** seçilerek kuvvet analizleri için setup kurulur. Transformatöre ait elektromekanik örgü yapısı Şekil 2.13'te yer verilmiştir.




Şekil 2.13 : Elektromekanik örgü yapısı.

2.4 Sonlu Elemanlar Yöntemi (SEY)

ANSYS@Maxwell, SEY üzerine kurulu bir elektromanyetik alan simülasyon yazılımıdır. SEY, karmaşık mühendislik problemlerinin sayısal olarak çözülebilmesi için

yaygın olarak kullanılan bir yöntemdir. Bu yöntemde, çözülmesi gereken alan küçük, basit ve çözülebilir parçalar olan sonlu elemanlara ayrılmaktadır. Maxwell'de SEY, elektromanyetik alanların, kuvvetlerin, manyetik akının ve diğer elektromanyetik parametrelerin hassas bir şekilde analiz edilmesi için kullanılır (Jin, 2014). ANSYS@Maxwell'de SEY kullanarak bir elektromanyetik analiz gerçekleştirmek birkaç temel adımdan oluşmaktadır:

- **Geometri Tanımlama:** İlk adım, analiz edilecek fiziksel sistemin geometrisinin oluşturulmasıdır. Bu adımda, bir elektrik motoru, bir mıknatıs veya bir transformatör gibi bileşenlerin üç boyutlu ya da iki boyutlu modelleri tanımlanır. Maxwell, geometriyi sonlu elemanlara bölmek için bu modeli kullanır.
- **Malzeme Tanımları:** SEY'in doğru sonuçlar üretebilmesi için malzemelerin manyetik, elektriksel ve termal özellikleri tanımlanmalıdır. Maxwell, malzeme özelliklerini doğru bir şekilde hesaplayarak çözüm sürecinde bunları kullanır. Özellikle elektromanyetik analizlerde malzeme özelliklerinin doğruluğu son derece önemlidir. Doygunluk, histerezis ve geçirgenlik gibi özellikler SEY ile modele entegre edilir.
- **Mesh (Ağ) Oluşturma:** EM'in en önemli aşamalarından biri mesh (ağ) oluşturmaktır. Maxwell, geometriyi küçük sonlu elemanlara böler ve bu elemanlar üzerinde sayısal hesaplamalar yapmaktadır. Mesh ne kadar ince olursa, çözüm o kadar hassas olur ancak hesaplama süresi de artar. Maxwell, kullanıcının mesh kalitesini kontrol etmesine ve belirli bölgelerde daha hassas mesh kullanmasına olanak tanır. Maxwell 3D programında nüve ve sargıya ayrı ayrı seçildikten sonra **Maxwell 3D > Mesh Operation > Assing > On selction** yada **Inside Selection>Leng Based** seçenekleriyle mesh ağları analize uygun bölünmelerle tanımlanmaktadır. Şekil 2.14'te sargılara ait Mesh örgü parametreleri gösterilmektedir. Sargı yapısı analizler için 10000 parçaya dilimlendiği görülmektedir.



Şekil 2.14 : Mesh örgü parametreleri.

- **Sınır Koşulları:** Maxwell'deki SEY analizlerinde sınır koşulları, elektromanyetik alanların doğru hesaplanabilmesi için kritik bir rol oynar. Sınır koşulları, elektromanyetik alanların belirli yüzeylerde veya bölgelerde nasıl davranacağını belirler. Örneğin, manyetik alanların sıfıra indirildiği bir sınır koşulu, bir manyetik devrenin çözümünde uygulanabilmektedir.
- **Çözüm Ayarları:** SEY analizlerinin başarılı olabilmesi için ANSYS@Maxwell çözüm ayarlarının dikkatle yapılması gerekir. Maxwell, kullanıcıya çözüm tipi (statik, zaman bağlı, harmonik vb.) seçme imkânı sunar. Zamanla değişen elektromanyetik analizlerde, SEY çözümü, her bir zaman adımında yeni bir çözüm üreterek elektromanyetik alanların zamana göre nasıl değiştiğini hesaplamaktadır.

3. ARK TEORİSİ VE MODELLENMESİ

Transformatörler, yüksek akım ve gerilim seviyelerinin etkili bir şekilde kontrol edilmesi ve güç aktarımında kritik bir rol oynayan cihazlardır. Transformatörlerde, enerji sargılardan manyetik çekirdeğe iletilir ve bu süreçte yağ dolu tanklarda yalıtım sağlanır. Transformatör yağı, elektriksel yalıtımın yanında aynı zamanda sargıların soğutulması için de kullanılır. Ancak çeşitli nedenlerle (yıldırım düşmesi, aşırı yüklenme, kısa devre) transformatör içinde bir ark oluşabilir. Yağ içerisindeki bu ark, sistemde ciddi arızalara, patlamalara ve yangın riskine yol açabilir. Transformatör yağı içerisindeki ark davranışı, yağın dielektrik özellikleri, akım yoğunluğu, sıcaklık ve sistemin dinamikleri ile ilişkilidir.

Bu bölümde, transformatör yağında oluşan elektrik arkının fiziksel ve kimyasal etkileri incelenecek, oluşan dinamik süreçler detaylandırılacak ve çalışmada kullanılan ark modeli sunulacaktır.

3.1 Transformatör Yağının Özellikleri ve Arkın Oluşumu

Transformatör yağı (genellikle mineral yağı), transformatörün elektriksel bileşenlerini yalıtır ve aynı zamanda sargılardan yayılan ısıyı dağıtılmasına yardımcı olur. Yağın en önemli özelliklerinden biri, yüksek dielektrik dayanım kapasitesidir. Bu özellik, transformatörün içindeki elektriksel gerilimlerin güvenli bir şekilde izole edilmesini sağlar. Ancak, bu yalıtım seviyesinin üzerinde gerilim uygulandığında veya yağ bozulduğunda elektriksel boşalma (ark) meydana gelebilir.

Transformatör sargıları arasında veya bağlantı elemanları üzerindeki arıza durumlarında, elektrik akımı sargılar arasında geçiş yapar ve iyonizasyon başlar. Bu durum, yağ moleküllerinin parçalanmasına ve plazma oluşumuna neden olur. Oluşan plazma, elektriksel ark olarak bilinen yüksek sıcaklıklı, iletken bir kanal oluşturur. Bu ark, transformatör yağı içindeki sıcaklığı hızla artırır ve yağın kimyasal yapısını değiştirir (Han vd., 2024).

3.2 Yağ İçinde Arkın Dinamikleri

Yağ içinde oluşan arkın dinamikleri, hava veya gaz ortamındaki ark davranışlarından oldukça farklıdır. Transformatör yağında meydana gelen arkın başlıca etkileri şunlardır:

İyonizasyon: Arkın oluşumu ile birlikte yağ içerisindeki hidrokarbon molekülleri iyonlaşır. Yağdaki moleküller, ark boyunca atomik düzeyde parçalanarak hidrojen ve karbon gazlarının oluşumuna neden olur. Bu iyonlaşma, elektriksel iletkenliği artırır ve ark boyunca daha yüksek akımların geçmesine olanak sağlar (CIGRÉ, 2013).

Plazma Oluşumu: Ark, yağın yerel olarak yüksek sıcaklıklara (3000 °C'nin üzerinde) ulaşmasına neden olur. Bu yüksek sıcaklık, yağın hızla buharlaşmasına ve plazma kanalının oluşumuna yol açar. Plazma içinde serbest elektronlar ve iyonlar bulunur ve bu ortam elektrik akımını iletmeye başlar. Plazma kanalı boyunca iletilen enerji, arkın sürekliliğini sağlar.

Kimyasal Tepkimeler: Ark nedeniyle transformatör yağı ciddi şekilde bozulur ve kimyasal yapısında değişiklikler meydana gelir. Yağ içindeki hidrokarbon zincirleri kırılarak, hidrojen, asetilen, metan gibi gazların açığa çıkmasına neden olur. Bu gazların birikimi transformatör tankında patlama riskini artırabilir. Gaz kromatografisi DGA ile bu gazlar ölçülerek ark arızaları tespit edilebilir (IEC 60599, 2022).

Gaz Baloncuklarının Oluşumu: Ark sırasında açığa çıkan ısı ve iyonlaşma enerjisi, yağın içinde gaz baloncuklarının oluşmasına neden olur. Bu gaz baloncukları, arkın olduğu bölgede birikerek yalıtımın bozulmasına ve kısa devrelere yol açabilir. Bu süreç, arkın genişlemesine ve daha büyük bir alana yayılmasına sebep olabilir (Iskender ve Mamizadeh, 2011).

3.3 Elektrik Arklarının Fiziksel Temelleri

Elektrik arkı, bir iletkenin gaz ortamında yalıtımı kırarak akımın iletilmesine neden olan elektriksel boşalma olayının sonucudur. Arkın oluşumu, temel olarak üç ana aşamadan geçer: iyonizasyon, boşalma ve plazma evresidir. İletkenler arasında yüksek gerilim farkı olduğunda, ortamda serbest elektronlar ivmelenir ve gaz atomlarıyla çarpışarak bu atomların iyonlaşmasına neden olur. İyonlaşma sonucunda bir plazma kanalı oluşur ve bu kanalda iletken bir yol meydana gelir. Bu süreçte, elektriksel enerji termal enerjiye dönüşür ve yüksek sıcaklıklarla sonuçlanmaktadır.

3.4 Arkın Elektriksel Davranışı

Elektrik arklarının davranışını anlamak için statik ve dinamik modellerin birleştirilmesi gerekmektedir. Statik modeller, kararlı durumlarda arkın gerilim-akım ilişkisini ele alırken, dinamik modeller, zamanla değişen elektriksel ve termal süreçleri açıklamaktadır.

3.4.1 Arkların statik modeli

Transformatör yağında ortaya çıkan arkın elektriksel özellikleri, arkın akımı ve gerilim değişimine göre değişir. Arkın elektriksel özellikler genellikle akım-gerilim bağlantısıyla sağlanır. Yağ ortamında arkın özellikleri gerilim-akım eğrisi, gaz veya hava ortamındakine benzer şekilde dinamik değişiklikler gösterir. Bu süreç şu şekilde açıklanabilir:

$$V_A = V_0 + R_A \cdot I_A \quad (3.1)$$

Burada, V_A ark boyunca oluşan gerilim, V_0 arkın başlangıç gerilimi, R_A ark direnci (yağ içindeki plazma kanalının direnci) ve I_A ark boyunca geçen akımı ifade etmektedir. R_A , hava veya gaz ortamlarına göre daha yüksektir. Bunun nedeni, sıcaklıktaki yüksek dielektrik farklılıkları ve plazma kanalının farklı fiziksel yayınlara sahip olmasıdır. Arkın yoğunluğunun, geriliminin ve parlaklığının büyüklüğü de artar ve bu durum arkın potansiyelinin ortaya çıkması sağlanır. Yağda meydana gelen bu ark genellikle geçici bir doğaya sahip olabilir, ancak tekrarlayan arklar transformatörün ciddi şekilde zarar görmesine neden olabilir (Chen vd., 2016).

Statik modellerin, deneysel sonuçlarla uyumlu olduğu birçok durumda kullanımı kolaydır, ancak dinamik etkileri ve geçici süreçleri göz ardı ettikleri için arkın zamanla değişen davranışını tam olarak açıklayamazlar. Bu nedenle, daha gelişmiş ve ayrıntılı bir analiz için dinamik modellere başvurulmaktadır.

3.4.2 Arkların dinamik modelleri

Dinamik ark modelleri, ark olaylarının zaman içinde nasıl geliştiğini ve sistem üzerinde nasıl etkiler yarattığını analiz etmektedir. Bu modellerde, gerilim, akım ve diğer fiziksel büyüklüklerin zamanla nasıl değiştiği incelenir. Arkın dinamik davranışları, gazın iyonizasyonu, plazmanın genişlemesi ve termal etkiler gibi karmaşık süreçlerle bağlantılıdır. Genel bir dinamik ark modeli şu şekilde ifade edilebilir:

$$\frac{dV_A(t)}{dt} = k_1 \frac{dI_A(t)}{dt} + k_2 I_A \quad (3.2)$$

Burada $V_A(t)$ zamanla değişen ark gerilimi, k_1 ve k_2 arkın termal ve elektriksel karakteristiklerine bağlı sabitleri ve $I_A(t)$ zamanla değişen ark akımını ifade eder. Bu denkleme göre, ark akımının zamana göre ark gerilimini doğrudan etkiler. Akımın hızlı değişimlerinde gerilim de aynı şekilde hızla değişir. Bu model, özellikle geçici durum analizlerinde faydalıdır. Zamanla değişen akım ve gerilim profilleri, arkın anlık etkilerini analiz etmeyi mümkün kılar. Literatür çalışmalarında kabul görmüş bazı önemli dinamik ark modelleri bulunmaktadır. Bunlar; Cassie, Mayr, Schwarz, Habdank ve Kema ark modelleri denklemleriyle birlikte aşağıda sunulmaktadır.

Cassie ark modeli: Cassie ark modeli, bir AC arkının dinamik özelliklerini aşağıdaki diferansiyel denklemle temsil eder:

$$\frac{d \ln g_c(t)}{dt} = \frac{1}{\tau_c} \left(\frac{V_A^2(t)}{V_c^2} - 1 \right) \quad (3.3)$$

Bu denklemde, $g_c(t)$, Cassie modelinin ark iletkenliği, τ_c Cassie modelinin zaman sabiti ve V_c Cassie modelinin ark voltajı sabitidir (Yang vd., 2022).

Mayr ark modeli: Mayr ark modeli, bir AC arkının dinamik özelliklerini aşağıdaki diferansiyel denklemle temsil eder:

$$\frac{d \ln g_m(t)}{dt} = \frac{1}{\tau_m} \left(\frac{V_A(t)}{P_0} - 1 \right) \quad (3.4)$$

Bu denklemde $g_m(t)$ Mayr modelinin ark iletkenliği, τ_m Mayr denkleminin zaman sabitini ve P_0 Mayr modelinin güç dağılım sabitini göstermektedir (Yang vd., 2022).

Schwarz ark modeli: Schwarz ark modeli, bir AC arkının dinamik özelliklerini aşağıdaki diferansiyel denklemle temsil eder:

$$\frac{1}{g_s(t)} \frac{dg_s(t)}{dt} = \frac{1}{\tau_s g_s^a(t)} \left(\frac{V_A(t)i}{P_0 g_s^b(t)} - 1 \right) \quad (3.5)$$

Bu denklemde τ_s , a ve b parametreleri ark voltajının dalga formunu tanımlar, P_0 Schwarz modelinin ise ark voltajının ortalama değerini verir (Yuan vd., 2013).

Habdank ark modeli: Habdank ark modeli, Cassie ve Mayr ark modelinin bir seri bağlantısıdır ve iki diferansiyel denklem ve bir cebirsel denklemden oluşur. AC arkının dinamik özelliklerini aşağıdaki diferansiyel denklemle temsil eder (Yuan vd., 2013):

$$\frac{d \ln g_c(t)}{dt} = \frac{1}{\tau_c} \left(\frac{V_A^2(t)}{V_c^2(t)} - 1 \right) \quad (3.6)$$

$$\frac{d \ln g_m(t)}{dt} = \frac{1}{\tau_m} \left(\frac{V_A(t)}{P_0} - 1 \right) \quad (3.7)$$

$$\frac{1}{g_h(t)} = \frac{1}{g_c(t)} + \frac{1}{g_m(t)} \quad (3.8)$$

Bu denklemde $g_c(t)$ Cassie denklemindeki ark iletkenliğini, τ_c Cassie zaman sabitini, g_m Mayr denklemindeki ark iletkenliğini, τ_m Mayr zaman sabitidir ve P_0 ise ark voltajının ortalama değerini (sabit) ifade etmektedir (Yuan vd., 2013).

Kema ark modeli: Seri şekilde birbirine bağlanmış üç farklı Mayr ark modelinden oluşmaktadır. Diferansiyel denklem olarak ifadesi aşağıdaki gibidir.

$$\frac{dg_1(t)}{dt} = \frac{A_1}{\tau_1} \cdot g_1^{\lambda_1}(t) \cdot u_1^2(t) - \frac{1}{\tau_1} g_1(t) \quad \lambda_1 = 1.4375 \quad (3.9)$$

$$\frac{dg_2(t)}{dt} = \frac{A_2}{\tau_2} \cdot g_2^{\lambda_2}(t) \cdot u_2^2(t) - \frac{1}{\tau_2} g_2(t) \quad \lambda_2 = 1.9 \quad (3.10)$$


$$\frac{dg_3(t)}{dt} = \frac{A_3}{\tau_3} \cdot g_3^{\lambda_3}(t) \cdot u_3^2(t) - \frac{1}{\tau_3} g_3(t) \quad \lambda_3 = 2 \quad (3.11)$$

$$\frac{1}{g(t)} = \frac{1}{g_1(t)} + \frac{1}{g_2(t)} + \frac{1}{g_3(t)} \quad (3.12)$$

Bu denklemde $g(t)$ arkın toplam iletkenliği, τ_1, τ_2 ve τ_3 arkın zaman sabitleri, A_1, A_2 ve A_3 arkın (soğutma) sabiti ve λ_1, λ_2 ve λ_3 n'inci arkın Cassie-Mayr kontrolü ark kontrol katsayılarını ifade etmektedir (Smeets ve Kertész, 2000).


3.5 MATLAB'ta Arkın Modellenmesi

Tezde ark kullanılan ark modeli MATLAB@Simulink ortamında modellenmiştir. Ark'ın nonlinear yapısını oluşturan diferansiyel denklemler Simulink ortamında ANSYS@Simplorer ile eş zamanlı olarak çözdürülmektedir. Bu veri akışı karşılıklı olarak aynı sekansta gerçekleştirilmektedir. MATLAB@Simulink ortamında yazılan kodlama içerikleri ekler kısmında ayrıca yer verilmiştir. Kullanılan ark modeline ilişkin yapı Şekil 3.1'de verilmiştir.



Şekil 3.1 : MATLAB@Simulink'e kuplajlanan ark modeli.

ANSYS@Simplorer ortamından kuplajlanan modele aktarılan Simulink dosyası **AnsfotSfunction** yapısıyla tüm ilişkili **Input/Outputlar** adreslenmiştir. Böylelikle modeller enjekte edilmiş olur. Kuplajlanan MATLAB@Simulink yapısı Şekil 3.2'de sunulmuştur. Arkın akım ve gerilim bilgileri eş zamanlı olarak Simulink ortamından Simplorer ortamına aktarılırken, Simplorer ortamındaki tüm terminal akım ve gerilim bilgileri de eş zamanlı olarak Simulink ortamına aktarılır. Böylelikle, her iki ortamdaki veriler depolanırken veri kaybı da önlenmiş olur.



Şekil 3.2 : MATLAB@Simulink modeli.

3.6 Ark Modelinin Seçilmesi

Literatür kapsamında birçok ark modeli bulunmaktadır. Çalışmada sargılar üzerinde oluşan ark arızası için Habedank modeli kullanılmıştır. Habedank modeli, genel anlamda Cassie ve Mayr modellerinin özelliklerinin birleşiminden oluşur. Habedank modeli, elektrik arklarının dinamik davranışlarını anlamak ve modellemek için geliştirilmiş bir yöntemdir ve Cassie ile Mayr modellerinin güçlü yönlerini bir araya getirir. Habedankk modeli, enerji sistemlerindeki dinamik ve statik davranışları gerçekçi bir şekilde modelleyebilmesi nedeniyle tercih edilmiştir.

Cassie Modeli, elektrik arkının yüksek akım bölgelerindeki davranışlarını modellemek için tasarlanmıştır. Genellikle sabit enerji yoğunluğu prensibine dayanmaktadır.

Arkın genişlediği durumlarda (yüksek akım bölgelerinde), enerji dağılımını ve stabiliteyi iyi temsil etmektedir.

Mayr modeli, elektrik arkının düşük akım bölgelerindeki davranışlarını modellemek için uygundur. Termodinamik denklemleri kullanarak arkın enerji dengesini temsil etmektedir. Düşük akım seviyelerinde, özellikle arkın sönümlenme dinamiklerinde daha doğru sonuçlar vermektedir (X. Li vd., 2020).

Habedank modeli, Cassie ve Mayr modellerinin birbirini tamamlayıcı doğalarını birleştirerek şu özellikleri sunar:

- Yüksek akım bölgelerinde Cassie modeli,
- Düşük akım bölgelerinde ise Mayr modeli devreye girer.

Bu entegrasyon, Habedank modelinin daha geniş bir akım aralığında ark davranışını doğru bir şekilde modellemesini sağlamaktadır (X. Li vd., 2020). Model, iki yaklaşımın farklı akım seviyelerindeki üstünlüklerini bir araya getirerek daha gerçekçi ve kapsamlı bir yöntem sunmaktadır. Habedank Modelinin aşağıdaki avantajlardan dolayı seçilmiştir.

- Geniş Dinamik Aralık: Hem düşük hem de yüksek akım bölgelerinde doğru sonuçlar sağlamaktadır.
- Enerji Dengesinin Detaylı Temsili: Cassie modelinin enerji yoğunluğu yaklaşımını ve Mayr modelinin enerji değişim dinamiklerini birleştirmektedir.
- Daha Gerçekçi Simülasyon: Elektrik arklarının hem stabil hem de sönümlenme aşamalarını başarılı bir şekilde temsil etmektedir.

Habedank modeli, Cassie ve Mayr modellerine dayalı bir diferansiyel denklem ile ifade edilir. Modelde:


- Cassie modeli, ark enerjisinin akıma bağlı bir fonksiyonu olarak kullanılır.
- Mayr modeli ise arkın enerjisinin zamana bağlı değişimini temsil etmektedir.

Bu iki modeli birleştiren Habedank modeli, parametreleri akım seviyelerine ve sistem koşullarına göre optimize ederek kullanılmaktadır. Sonuç olarak, Habedank modeli, Cassie ve Mayr modellerinin bir kombinasyonu olarak geliştirilmiştir ve bu nedenle her iki modelin avantajlarını birleştirerek daha kapsamlı bir ark davranışı analizi sunmaktadır. Bu özellik,

Habedank modelini elektrik tesislerindeki dinamik analizler ve optimizasyon çalışmaları için ideal hale getirmektedir (Parizad vd., 2009).


3.7 Ark yapısının ANSYS@Simplorer Modeli

Elektrik arklarının doğrusal olmayan yapısı, akım ve gerilim arasındaki karmaşık ve doğrusal olmayan ilişkiyi ifade eder. Bu durum, arkın fiziksel özelliklerinden, elektriksel dinamiklerinden ve çevresel faktörlerden kaynaklanır. Akım ve gerilim sinyallerindeki farklılık, ark ile ilgili çalışmalarda doğrusal olmayan bir direnç olarak modellenmektedir (Oliveira vd., 2011; Oliveira ve Cardoso, 2010, 2012). Ark'ın doğrusal olmayan değişimini gösteren modeller Şekil 3.3'te sunulmuştur.



Şekil 3.3 : Ark'ın doğrusal olmayan model gösterimi.

Bu çalışmada, Matlab ortamından alınan Ark'a ait akım ve gerilim bilgileri ANSYS@Simplorer ortamına aktarılır. Simplorer ortamındaki Ark modeli parametreleri Şekil 3.4 gösterilmektedir. Şekil 3.4'te doğrusal olmayan direnç modeli R10 ile ifade edilmiştir. R10 içerisindeki değişimler, sırasıyla X ekseninin akım bilgisini ve Y ekseninin gerilim bilgisini temsil etmektedir. Arkın akım/gerilim anlık değişim bilgisi ayrıca Şekil 3.4'te ayrıntılı olarak gösterilmektedir.



Şekil 3.4 : Doğrusal olmayan ark modelinin Simplorer ortamındaki davranışı.

4. FOURIER DÖNÜŞÜMÜ

Fourier Dönüşümü (FT), zamanla değişmeyen durağan bir sinyali, çeşitli harmonik bileşenlere ayıran bir tekniktir (Sarıbulut vd., 2013). Fourier, her periyodik fonksiyonun, uygun sinüs ve kosinüs fonksiyonlarının toplamı olarak ifade edilebileceğini ortaya koymuştur. FT, sinyalleri ifade etmek için sinüs ve kosinüs taban fonksiyonlarından yararlanır. Bu şekilde sinyalin trigonometrik bir seri olarak açılması, o sinyal hakkında anlamlı bilgiler sağlamaktadır (Cooley ve Tukey, 1965).


Matematiksel olarak, bir $f(t)$ fonksiyonu için Fourier dönüşümü şu şekilde tanımlanır:

$$F(\omega) = \int_{-\infty}^{+\infty} f(t)e^{-i\omega t} dt \quad (4.1)$$


şeklinde tanımlanırken, $F(\omega)$ 'nin ters Fourier dönüşümü ise;

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(\omega)e^{i\omega t} d\omega \quad (4.2)$$

olarak tanımlanmaktadır. Bu eşitlikler, genellikle Fourier dönüşüm çifti olarak adlandırılır ve zaman veya frekans alanındaki $(-\infty, \infty)$ aralığında herhangi bir fonksiyonu, ters alanda sürekli bir fonksiyona dönüştürmek için kullanılır. Fourier dönüşümü, zaman alanındaki bir sinyali frekans alanına veya frekans alanındaki bir sinyali zaman alanına dönüştürmek amacıyla uygulanır. Örnek olarak τ aralıklı bir dikdörtgensel bir fonksiyonun zaman domaindeki şekli Şekil 4.1'de, frekans uzayındaki dönüşmüş hali ise Şekil 4.2'de verilmiştir.



Şekil 4.1 : Dikdörtgen bir darbenin zaman uzayındaki gösterimi.



Şekil 4.2 : Dikdörtgen bir darbenin zaman uzayındaki gösterimi.

4.1 Ayırık Fourier Dönüşümü (DFT)

Fourier dönüşümünün pratik uygulamaları genellikle Ayırık Fourier Dönüşümü (Discrete Fourier Transform-DFT) kullanılarak gerçekleştirilir. DFT, sonlu ve periyodik bir diziye frekans domainine dönüştürür. DFT'nin matematiksel ifadesi şu şekildedir:

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-i \frac{2\pi}{N} k n} \quad (4.3)$$

burada $X(k)$ frekans alanındaki k -inci bileşenin değeri, $x(n)$ zaman alanında n -inci örnek değerini, N sinyalin toplam örnek sayısı (DFT'nin boyutu) ve n zaman örneğinin indis değerini ifade etmektedir. DFT, hızlı Fourier dönüşümü (FFT) algoritmaları kullanılarak verimli bir şekilde hesaplanabilir. FFT, DFT hesaplamalarını önemli ölçüde hızlandırır ve büyük veri setlerinin analizini mümkün kılar (Cooley ve Tukey, 1965).

4.2 Hızlı Fourier Dönüşümü (FFT)

FFT'ler FT'leri kolaylaştırmak için geliştirilmiştir. Bir $x[n]$ sinyalinin DFT'si aşağıdaki gibidir (Akmaz, 2017; Cooley ve Tukey, 1965).

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-i\omega n} \quad k = 0, 1, 2 \dots N - 1 \quad (4.4)$$

burada her k değeri için N adet karmaşık çarpma ve $N - 1$ adet karmaşık toplama işlemi gereklidir. Bir N noktalı DFT için N^2 hesaplama yükü ortaya çıkmaktadır. DFT'deki faz faktörü aşağıdaki gibi tanımlanır:

$$W_N = e^{-i\left(\frac{2\pi}{N}\right)} \quad (4.5)$$

bu durumda, her k değeri için N adet karmaşık çarpma ve $N - 1$ adet karmaşık toplama işlemi gereklidir. Bir N noktalı DFT için N^2 hesaplama yükü ortaya çıkar. Faz faktörünün simetri özellikleri, Discrete Fourier Transform (DFT) hesaplamalarında verimliliği artırabilir. Eğer sinyalin her elemanı, $N/2$ konumundaki bir elemana simetrik ise (burada N DFT'nin boyutudur), bu durumda sinyalin DFT'si genellikle gerçek ve simetriktir. Bu durumda, sinyalin negatif frekans bileşenleri, pozitif frekans bileşenlerinin kompleks konjugesi ile ilişkilidir. Bu simetri, hesaplama maliyetini yarıya indirebilir, çünkü sadece yarısını hesaplamak yeterlidir. Özellikle şu iki simetri özelliği dikkate değerdir:

$$W_N^{k+\frac{N}{2}} = -W_N^k \quad (4.6)$$

Eğer sinyal periyodik ise, DFT'de elde edilen spektrum da periyodik olacaktır. Bu durumda, sinyalin bir periyot boyunca alınan verileri tekrar edilebilir, böylece DFT hesaplamalarında daha az veri işlenir yani sinyalin tüm periyotlarını işlemek yerine yalnızca bir periyodunu işlemek yeterlidir (Akmaz, 2017; Alpsalaz ve Mamiş, 2024). Denklem yeniden aşağıdaki gibi düzenlenir.

$$W_N^{k+N} = W_N^k \quad (4.7)$$

bu durum FFT'nin zamanda örnek seyreltme yöntemi olarak bilinir ve DFT hesaplamalarını büyük ölçüde hızlandırmaktadır. Bu yöntem, özellikle sinyalin boyutu N büyüdükçe hesaplama maliyetini azaltır ve FFT'nin pratikte aşağıdaki gibi yaygın olarak kullanılmasını sağlamaktadır:

$$X[k] = \sum_{n=0}^{N-1} x[n] W_N^{kn} \quad k = 0, 1, 2, \dots, N-1 \quad W_N = e^{-i\left(\frac{2\pi}{N}\right)} \quad (4.8)$$

böylece en yaygın haliyle yazılmıştır. W_N^{kn} faz faktörü n 'ye bağlı olmadığı için toplamın dışarısına çıkarıldığında eşitlik,

$$X[k] = \sum_{n=0}^{\frac{N}{2}-1} x[2n] W_N^{k(2n)} + W_N^k \sum_{n=0}^{\frac{N}{2}-1} x[2n+1] W_N^{k(2n)} \quad (4.9)$$

şeklinde ifade edilir. $W_N^{k(2n)} = W_{\frac{N}{2}}^{kn}$ şeklindeki ifadeden dolayı $N/2$ noktalı DFT'ye göre yeniden yazıldığında;

$$X[k] = \sum_{n=0}^{\frac{N}{2}-1} x[2n] W_{\frac{N}{2}}^{kn} + W_N^k \sum_{n=0}^{\frac{N}{2}-1} x[2n+1] W_{\frac{N}{2}}^{kn} \quad (4.10)$$

şeklinde yazılabilmektedir. $x_1[n] = x[2n]$ ve $x_2[n] = x[2n+1]$ olduğundan denklem yeniden yazılırsa;

$$X[k] = \sum_{n=0}^{\frac{N}{2}-1} x_1[n] W_{\frac{N}{2}}^{kn} + W_N^k \sum_{n=0}^{\frac{N}{2}-1} x_2[n] W_{\frac{N}{2}}^{kn} \quad (4.11)$$

ifadesi elde edilmektedir. İfade yeniden düzenlendiğinde;

$$X[k] = X_1[k] + W_N^k X_2[k] \quad k = 0, 1, 2, \dots, N-1 \quad (4.12)$$

bulunur. Faz vektörünün simetri özelliği $W_N^{k+\frac{N}{2}} = -W_N^k$ dikkate alınarak burada $X[k]$ 'nin ilk $N/2$ değeri alınır;

$$X[k] = X_1[k] + W_N^k X_2[k] \quad k = 0, 1, 2, \dots, N/2-1 \quad (4.13)$$

elde edilir. Burada $X[k]$ 'nin sonraki $N/2$ değeri alınır;

$$X[k] = X_1[k] - W_N^k X_2[k] \quad k = 0, 1, 2, \dots, N/2-1 \quad (4.14)$$

bulunur. Böylelikle örnek seyreltme denklemleri elde edilmiş olur. Örnek seyreltme ile FFT hesabında, işaret önce çift ve tek sayılı örneklerine ayrılarak başlanır. En alt seviyede, sadece iki noktalı bir DFT hesaplanarak işaret dizileri oluşturulur. Bu işlemler, denklem (4.13) ve denklem (4.14) ile belirtilen dönüşümlerle birleştirilerek bir üst seviyenin DFT'si elde edilir. Bu süreç, her seviyede tekrarlanarak $x[n]$ işaretinin en üst seviyedeki FT'si elde edilir. Rekansta örnek seyreltme yönteminde, giriş işaret örnekleri yerine DFT çıkışı $X[k]$, çift ve

tek sayılı frekans örneklerine ayrıştırılabilir (Alpsalaz vd., 2024). Zamanda örnek seyreltme algoritmasında olduğu gibi, çift ve tek frekans örneklerini içeren diziler sürekli olarak ayrıştırılır. İşaret sürekli olarak ikiye bölünür ve her iki parça toplanıp farkları hesaplanarak, gerekli faz faktörleriyle çarpılır. En alt seviyede sadece iki noktalı DFT hesaplaması ile işaretin FFT'si elde edilir (Akmaz, 2017; Cooley ve Tukey, 1965).



5. MAKİNA ÖĞRENME ALGORİTMALARI

Makine öğrenme (MÖ) algoritmaları, bilgisayarların verilerden öğrenmesini ve bu öğrenmeyi kullanarak kararlar almasını sağlamaktadır. Bu algoritmalar, genellikle büyük veri kümeleri üzerinde çalışarak desenleri, ilişkileri ve eğilimleri tespit eder. Makine öğrenme algoritmalarının temel amacı, verilerden otomatik olarak bilgi çıkararak gelecekteki verilere ilişkin tahminlerde bulunmaktır.

Makine öğrenme algoritmaları, genel olarak üç ana kategoriye ayrılabilir bunlar, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmesidir. Denetimli öğrenme algoritmaları, etiketli verilerle çalışarak belirli bir girişin karşılık gelen çıkışını tahmin etmeyi öğrenmektedir. Denetimsiz öğrenme algoritmaları ise etiketlenmemiş verilerle çalışır ve verilerdeki gizli desenleri ortaya çıkarmaya çalışır. Kümeleme algoritmaları bu kategoriye örnektir ve müşteri segmentasyonu gibi uygulamalarda yaygın olarak kullanılır. Pekiştirmeli öğrenme algoritmaları, bir ajanı belirli bir ortamda ödül kazanacak şekilde eğiterek optimal stratejiler geliştirmeyi amaçlamaktadır.

Denetimli öğrenme algoritmalarından en yaygın kullanılanları arasında doğrusal regresyon, lojistik regresyon, destek vektör makineleri, karar ağaçları ve rastgele ormanlar bulunmaktadır. Örneğin, doğrusal regresyon, bağımsız değişkenlerle bağımlı değişken arasındaki doğrusal ilişkiyi modellemek için kullanılır (Hastie vd., 2009). Karar ağaçları ve rastgele ormanlar ise veriyi dallara ayırarak karar verme süreçlerini modellemek için kullanılır ve genellikle karmaşık veri kümelerinde güçlü performans sergilemektedir (Ignatenko vd., 2024; Leo Breiman, 2001).

Denetimsiz öğrenme algoritmalarında ise, K-means ve hiyerarşik kümeleme gibi algoritmalar öne çıkar. K-means algoritması, veri noktalarını belirli sayıda kümeye ayırarak her bir kümedeki verilerin benzerliğini maksimize etmeyi amaçlar. Hiyerarşik kümeleme ise verileri hiyerarşik bir yapıda organize ederek benzerliklerine göre alt kümeler oluşturur (Murtagh ve Contreras, 2012).

Pekiştirmeli öğrenme algoritmaları arasında Q-öğrenme ve Derin Pekiştirmeli Öğrenme (DQN) gibi algoritmalar bulunmaktadır. Q-öğrenme algoritması, bir ajanı belirli bir ortamda en yüksek ödülü kazanacak şekilde eğitirken, DQN algoritması, derin öğrenme tekniklerini kullanarak daha karmaşık ve yüksek boyutlu ortamlarda performansını artırmayı hedeflemektedir (Mnih vd., 2015).

5.1 Denetimli Öğrenme Algoritmaları

Denetimli öğrenme (supervised learning), makine öğrenmesinin en yaygın kullanılan alt dallarından biridir. Bu öğrenme paradigmasında, modelin eğitilmesi için giriş verileri ve bu verilere karşılık gelen doğru çıktılar kullanılmaktadır. Denetimli öğrenme algoritmaları, bu giriş-çıkış çiftlerini kullanarak bir fonksiyon öğrenir ve bu fonksiyonu kullanarak yeni, görülmemiş veriler için tahminlerde bulunur.

Denetimli öğrenme algoritmaları iki ana kategoriye ayrılır: bunlar regresyon ve sınıflandırmalardır. Bu iki kategori, bağımlı değişkenin (output) türüne göre belirlenmektedir.

5.1.1 Regresyon Algoritmaları

Regresyon, sürekli bir değeri tahmin etmeyi amaçlar. En yaygın regresyon algoritmalarından biri doğrusal regresyondur (linear regression). Doğrusal regresyonda, model, bağımsız değişkenler (input) ve bağımlı değişken (output) arasındaki doğrusal ilişkiyi öğrenir. Doğrusal regresyon modeli şu şekilde ifade edilir:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n + \epsilon \quad (5.16)$$

burada y bağımlı değişkeni, x_n bağımsız değişkenleri, β_i katsayıları ve ϵ hata terimini temsil eder. Model, eğitim verisi kullanarak β_i katsayılarını öğrenir ve böylece yeni veriler için y tahminleri yapabilmektedir.

Doğrusal regresyon modelinin eğitimi, genellikle en küçük kareler yöntemi (Ordinary Least Squares, OLS) kullanılarak yapılır. Bu yöntemde, tahmin edilen değerler $\hat{y}$ ile gerçek değerler y arasındaki hata karelerinin toplamını minimize eden β katsayıları aşağıdaki denklemle bulunmaktadır (Bishop, 2006).

$$OLS = \beta = \min_{\beta} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (5.2)$$

burada $\hat{y} = X\beta$ olup, X bağımsız değişkenlerin matrisidir. En küçük kareler çözümü ise aşağıdaki gibi bulunur:

$$\beta = (X^T X)^{-1} X^T y \quad (5.3)$$

5.1.2 Sınıflandırma Algoritmaları

Sınıflandırma, kategorik verileri sınıflandırmayı amaçlamaktadır. En yaygın sınıflandırma algoritmalarından biri lojistik regresyondur (logistic regression). Lojistik regresyon, bir olasılık tahmini yapar ve bu olasılık belirli bir eşik değerine göre sınıf etiketine dönüştürülmektedir. Lojistik regresyon modeli şu şekilde ifade edilir:

$$P(y = 1 | x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n)}} \quad (5.4)$$

Burada, $(y = 1 | x)$ bağımlı değişkenin 1 sınıfına ait olma olasılığını temsil eder. Lojistik regresyon modelinin eğitimi, maksimum olabilirlik tahmini (Maximum Likelihood Estimation, MLE) ile yapılır (James vd., 2021). Bu yöntem, gözlemlenen veri için olasılık fonksiyonunu maksimize eden aşağıdaki parametreleri bulmaktadır.

$$\begin{aligned} \beta = \max_{\beta} \sum_{i=1}^m [y_i \log(P((y = 1 | x))) \\ + \max_{\beta} \sum_{i=1}^m [(1 + y_i) \log(1 - P((y = 1 | x_i)))] \end{aligned} \quad (5.5)$$

burada genellikle lojistik regresyon veya olasılığa dayalı modellerde kayıp fonksiyonunu optimize etmek için kullanılmaktadır.

5.2 Denetimsiz öğrenme algoritmaları

Denetimsiz öğrenme, etiketsiz veri üzerinde model eğitmek için kullanılan bir makine öğrenimi türüdür. Bu tür algoritmalar, veri kümesindeki gizli desenleri ve yapıları keşfetmeyi amaçlamaktadır. Denetimsiz öğrenme algoritmaları, özellikle büyük veri setlerinde gizli bilgileri açığa çıkararak henüz keşfedilmemiş ilişkileri tespit edebilmektedir.

5.2.1 Kümeleme (Clustering)

Kümeleme algoritmaları K-means, Hiyerarşik Kümeleme, DBSCAN (Density-Based Spatial Clustering of Applications with Noise) en yaygın denetimsiz kümeleme algoritmalarıdır. K-Means, veri noktalarını belirli bir sayıda kümeye (k) ayıran popüler bir

kümeleme algoritmasıdır. Hiyerarşik kümeleme, veri noktalarını hiyerarşik bir yapıda düzenlenmektedir. Bu yapı, kümeleme işlemi sırasında veri noktalarının birleşmesi (agglomeratif) veya ayrılması (bölücü) ile oluşturulur. DBSCAN, yoğunluk tabanlı bir kümeleme algoritmasıdır. Algoritma, yoğun bölgelerdeki veri noktalarını kümelerken, yoğun olmayan bölgelerdeki veri noktalarını gürültü olarak kabul etmektedir (Ester vd., 1996; MacQueen, 1967; Murtagh ve Contreras, 2012).

5.2.2 Boyut İndirgeme (Dimensionality Reduction)

PCA (Principal Component Analysis), t-SNE (t-Distributed Stochastic Neighbor Embedding), Özyinelemeli Sinir Ağları (Autoencoders), Bağlantı Kurma ve Kurallar (Association Rule Learning) denetimsiz boyut indirgeme algoritmalarıdır. PCA, veri setinin boyutunu azaltmak için kullanılan doğrusal bir yöntemdir. Bu yöntem, veriyi daha az sayıda boyutta temsil eden yeni değişkenler (ana bileşenler) oluşturur (Aggarwal ve Reddy, 2014; Bishop, 2006).

5.2.3 Özyinelemeli Sinir Ağları (Autoencoders)

Özyinelemeli, veri noktalarının düşük boyutlu temsillerini öğrenmek için kullanılan sinir ağı modelleridir. Bu modeller, girdi veriyi sıkıştırarak bir gizli katman temsiliinde kodlar ve daha sonra bu temsil üzerinden veriyi yeniden oluşturur (Z. Ma vd., 2023).

5.2.4 Bağlantı kurma ve kurallar (Association Rule Learning)

Veri setindeki sık görülen öge kümelerini ve bunlar arasındaki ilişkileri (kuralları) keşfetmek için kullanılan bir algoritmadır. Özellikle market sepeti analizinde yaygın olarak kullanılır (Rawat vd., 2023).

5.3 Pekiştirmeli Öğrenme Algoritmaları

Pekiştirmeli öğrenme (Reinforcement Learning, RL), bir ajan (agent) ve bir ortam (environment) arasında gerçekleşen etkileşimler yoluyla öğrenmeyi amaçlayan bir makine öğrenmesi paradigmasıdır. Bu yöntemde, ajan belirli bir durumdan (state) başlayarak, ortamda belirli eylemler (actions) gerçekleştirir ve bu eylemler sonucunda ödül (reward) veya ceza (penalty) alır. Ajan, en yüksek toplam ödülü elde etmek için stratejisini (policy) zamanla öğrenir ve geliştirir.

5.3.1 Q-Öğrenme (Q-Learning)

Q-Öğrenme, model tabanlı olmayan ve değer tabanlı bir algoritmadır. Ajan, her durum-eylem çifti için bir Q-değeri öğrenir ve bu Q-değerlerini Bellman denklemine dayanarak güncellemektedir:

$$Q(s, a) \leftarrow Q(s, a) + a[r + \gamma \max_{a'} Q(s', a') - Q(s, a)] \quad (5.6)$$

Burada, a öğrenme oranı, γ indirim faktörü, s' ve a' sonraki durum ve bir sonraki eylemdir (Sutton ve Barto, 2018).

5.3.2 Sonsuz Küçük Gradyan İnişi (Deep Q-Network, DQN)

DQN, Q-Öğrenmenin derin sinir ağları ile genişletilmiş halidir. Bu algoritma, Q-değerlerini tahmin etmek için derin sinir ağlarını kullanır. DQN'nin önemli bileşenleri; Deneyim tekrarı ve Hedef ağıdır. Deneyim tekrarı, Eğitim verilerini yeniden kullanarak korelasyonu azaltır. Hedef ağ, Hedef Q-değerlerini hesaplamak için ayrı bir ağ kullanarak öğrenme stabilitesini artırmaktadır. Genel denklemi ise;

$$y = r + \gamma \max_{a'} Q(s', a'; \theta^-) \quad (5.7)$$

şeklinde. Burada y hedef değeri ve θ^- hedef ağın ağırlıklarıdır. Sonsuz küçük gradyan inişi, gradyan inişi algoritmasının sürekli zaman analizi ile ilgilidir (Mnih vd., 2015).

5.4 Transformatör Arızalarıyla İlgili MÖ Çalışmaları

Son yıllarda transformatör arızalarının MÖ algoritmalarıyla tespitine ilişkin birçok çalışma bulunmaktadır. Bunlar genellikle mekanik arızalar, kısa devre arızaları ve sargı arızalarını içermektedir.

Santamaria-Bonfi vd. (2023), güç transformatörleri arıza tespiti için geleneksel makine öğrenmesi ve otomatik makine öğrenmesi (autoML) algoritmalarının karşılaştırmalı analizi yapmıştır. Çalışmada, tam otomatik MÖ yaklaşımlarının, insan müdahalesi gerektiren geleneksel MÖ modellerine kıyasla daha iyi performans gösterip göstermediğini incelenmiştir. Bununla birlikte, makale sınırlı veri seti kullanımı ve arıza şiddetini tam olarak ele almama gibi eksiklikler taşımaktadır (Santamaria-Bonfil vd., 2023).

Bjelić vd. (2024) güç transformatörlerinin ömrünün değerlendirilmesi için tarama frekans yanıt analizi (SFRA) ve MÖ yöntemlerini kullanmıştır. Çalışmada, SFRA

sonuçlarının yorumlanmasındaki sübjektifliği azaltmak için makine öğrenmesi algoritmalarını çeşitli istatistiksel göstergelerle kullanmayı hedeflemiştir. Ancak, çalışmada sınırlı deneysel veri seti ve transformatörün yaşı ile arıza şiddeti arasındaki ilişkiyi daha kesin bir şekilde belirleyememe gibi bazı eksiklikler bulunmaktadır (Bjelić vd., 2024).

Kazemi vd. (2021), üç fazlı güç transformatörlerinde arıza tespiti ve sınıflandırması için Genişletilmiş Kalman Filtresi (EKF) ve destek vektör makineleri (SVM) tabanlı bir makine öğrenmesi yöntemi önermiştir. Çalışma, transformatörün primer sargılarındaki üç fazlı akımları tahmin etmek ve bu tahminlerle arıza tespitinde yüksek doğruluk elde etmek amacıyla tasarlanmıştır. Ancak, çalışma sınırlı deneysel veri setleri ve modelin enerji altında transformatör arızalarını daha geniş bir yelpazede inceleyememesi gibi eksiklikler taşımaktadır (Kazemi vd., 2021).

Thomas vd. (2023), tarafından güç sistemi ağlarında hata tespiti için evrişimli sinir ağları (Convolutional Neural Network- CNN) tabanlı bir transformatör modeli geliştirilmiştir. Mevcut yöntemler bazı ilerlemeler sağlamış olsa da özellikle Yüksek Empedanslı Hataların (HIF) tespiti konusundaki eksiklikler vardır. Çalışmanın amacı, bu boşluğu doldurmak ve daha etkin bir hata tespit sistemi sunmaktır. Önerilen model, zaman serisi verilerinden uzun dönemli bağımlılıkları öğrenerek, hata türü, faz ve konumunu başarılı bir şekilde belirlemektedir (Thomas vd., 2023).

5.5 Algoritmaların Belirlenmesi


Yapılan literatür çalışmalarında ve ön analizlerinde makine öğrenmesi algoritmaları içinde çakışma yapısına en uygun algoritmaların sınıflandırma algoritmaları olduğu belirlenmiştir. Sınıflandırma, verileri özelliklerine göre farklı sınıflara veya kategorilere ayırmayı içeren, makine öğreniminin temel kavramlarından biridir. Bu süreçte, etiketli eğitim verilerinden öğrenilen kalıplar ve bilgiler doğrultusunda, yeni ve daha önce görülmemiş örneklerle doğru bir şekilde etiket atanabilen bir model veya algoritma geliştirilmesi hedeflenir (Özbilgin, 2023). Bu çalışmada, literatürde yaygın olarak kullanılan denetimli makine öğrenmesi yöntemlerinden Karar Ağaçları, K-En Yakın Komşu, Destek Vektör Makineleri, Ansamble Algoritması ve YSA sınıflandırıcıları kullanılmıştır. Kullanılan sınıflandırma yöntemleri, aşağıdaki alt başlıklarda detaylandırılmaktadır.

5.5.1 Karar ağaçları algoritması (DT)

Karar ağaçları, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan, sezgisel ve kolay anlaşılabilir bir makine öğrenmesi algoritmasıdır. Karar ağaçları, verilerin özelliklerine göre karar düğümleri ve yaprak düğümleri oluşturur. Bu yaprak düğümleri, sınıflandırma problemlerinde sınıfları, regresyon problemlerinde ise sayısal değerleri temsil etmektedir (Lu vd., 2022).

Karar ağaçları, kök düğümünden başlayarak dallanan ve yaprak düğümlerinde sona eren bir yapıdadır. Her iç düğüm bir özelliği temsil eder ve bu düğümlerden çıkan dallar, bu özelliklerin alabileceği farklı değerleri veya aralıkları temsil eder. Bu şekilde, veri seti tekrar tekrar bölünerek homojen alt kümeler ayrılmaktadır (Taha Jijo ve Mohsin Abdulazeez, 2021).

Karar ağaçlarının öğrenme süreci, genellikle üç adımı içerir. Bunlar kök düğümünün seçimi, ağaç yapısının oluşturulması ve budama (pruning) adımlarıdır. Kök düğümü, veri setinin en iyi bölünmesini sağlayan özellik seçilerek başlatılmaktadır. Bu özellik, entropi veya Gini indeksi gibi kriterler kullanılarak seçilir. Ağaç yapısının oluşturma her düğümde, en iyi bölünmeyi sağlayan özellik seçilir ve veri seti bu özellik üzerinden bölünmektedir. Bu süreç, her yaprak düğümü saf bir sınıfa ulaşana veya önceden belirlenen bir durdurma kriteri karşılanana kadar tekrarlanmaktadır. Budama, aşırı öğrenmeyi önlemek için ağaç, gereksiz dallardan temizlenmektedir. Bu adım, genellikle çapraz doğrulama veya başka bir doğrulama seti kullanılarak gerçekleştirilmektedir.




Şekil 5.1 : Karar ağaçları algoritma yapısı.

5.5.2 k-En yakın komşu (k-NN)

k-En Yakın Komşu (k-Nearest Neighbors, k-NN) algoritması, sınıflandırma ve regresyon amaçlarıyla yaygın olarak kullanılan bir makine öğrenmesi algoritmasıdır. Bu algoritma, örnekleri eğitim veri kümesindeki mevcut örneklerle benzerliklerine göre sınıflandıran bir öğrenme metoduna dayanmaktadır. Algoritmanın çalışma prensibi, tahmin edilmek istenen örneğin eğitim verileri içerisindeki en yakın k komşu arasındaki mesafeyi hesaplamaya dayanır. Tahmin edilecek veri, en kısa mesafeye sahip k komşunun değerine bakılarak belirlenir. Sınıflandırma problemlerinde verinin sınıf etiketi, k komşunun sınıflarının oy çokluğu ile belirlenir. k-NN sınıflandırıcısı, parametrik olmayan bir yöntemdir, yani verilerin temel dağılımı hakkında herhangi bir varsayımda bulunmaz. Algoritma, sayısal, kategorik ve karışık veriler dahil olmak üzere her tür veriyle çalışabilir (Liao ve Vemuri, 2002).


Sınıflandırma işleminin doğruluğunu etkileyebilecek parametrelerden biri, k değerinin seçimidir. Küçük bir k değeri, modelin çok karmaşık hale gelmesine ve verilerdeki gürültüye uyduğu aşırı uyuma neden olabilirken, büyük bir k değeri ise modelin basitleşmesine ve yetersiz uyuma yol açabilmektedir. Şekil 5.2’de iki farklı sınıfa ait örnek bir veri dağılımı gösterilmektedir. Şekilde sarı renkli veriler birinci sınıfı, mor renkli veriler ikinci sınıfı temsil ederken, kırmızı renkli veri ise sınıf değerinin tahmin edileceği veriyi temsil etmektedir. Kırmızı verinin etrafında k=3 ve k=6 için çizilmiş daireler bulunmaktadır. k değerinin 3 olması, verinin ikinci sınıfa ait olacağını belirtirken, k değerinin 6 olması, verinin birinci sınıfa ait olacağını göstermektedir (Alfeilat vd., 2019; Özbilgin, 2023).



Şekil 5.2 : K-NN sınıflandırıcısı için iki farklı sınıfa ait örnek bir veri dağılımı (Özbilgin, 2023).

5.5.3 Destek vektör makineleri (SVM)

Destek Vektör Makineleri (SVM), istatistiksel öğrenme teorisi çerçevesinde geliştirilmiş bir sınıflandırma yöntemidir. SVM'ler, sınıflandırma ve regresyon analizlerinde kullanılan güçlü bir araçtır ve özellikle yüksek boyutlu verilerde etkilidir. SVM'nin temel prensibi, bir düzlemde yer alan iki farklı sınıfın veri gruplarını ayıran bir hiperdüzlem oluşturmaktır. Hiperdüzlem, iki boyutlu bir uzayda bir doğruya, üç boyutlu bir uzayda ise bir düzleme karşılık gelir. Bu hiperdüzlem, her iki sınıfa ait verilerden olabildiğince uzak olacak şekilde yerleştirilir (Suthaharan ve Suthaharan, 2016). Şekil 5.3'de örnek bir veri grubuna ait iki sınıflı SVM örneği yer almaktadır.



Şekil 5.3 : İki sınıflı örnek bir veri grubu için hiperdüzlem ve destek vektörlerinin gösterimi (Özbilgin, 2023).

SVM'nin tercihinde bazı avantaj ve dezavantajlar bulunmaktadır. Avantajları, yüksek boyutlu verilerde iyi performans gösterir, aşırı öğrenme (Overfitting) riskini azaltır ve genel olarak güçlü ve esnek bir modeldir. Dezavantajları ise, büyük veri setlerinde hesaplama maliyeti yüksektir, kernel seçimi ve parametre ayarları karmaşık olabilir ve veri noktalarının doğru şekilde sınıflandırılmasını zorlaştırabilmektedir (Öztürk vd., 2023).


5.5.4 Yapay sinir ağları (YSA)

YSA, biyolojik sinir sistemlerinden ilham alınarak geliştirilmiş bilgi işlem sistemleridir. Bu ağlar, insan beynindeki nöronların işleyişini taklit ederek öğrenme ve karar verme yeteneklerine sahiptirler. YSA'lar, matematiksel modeller ve algoritmalar kullanarak veri analizi, sınıflandırma ve tahmin gibi görevleri gerçekleştirirler (Goodfellow Ian vd., 2016).

YSA ait Nöronlar, sinir ağlarının temel yapı taşlarıdır. Her nöron, belirli sayıda girdi (input) alır, bu girdileri işler ve bir çıkış (output) üretir. Nöronların matematiksel modeli, genellikle aşağıdaki şekilde ifade edilir:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (5.8)$$

Burada x_i giriş değerleri, w_i ağırlıklar, b bias terimi ve f aktivasyon fonksiyonudur. Katmanlar, nöronların farklı yapılar oluşturduğu bir düzende organize edilmektedir. Giriş Katmanı, verilerin ağa aktarıldığı ilk katmandır. Gizli katmanlar (Hidden Layers), verilerin işlendiği ve öğrenmenin gerçekleştiği katmanlardır. Derin öğrenme modelleri, genellikle birden fazla gizli katman içermektedir. Çıkış katmanı (Output Layer), modelin nihai tahminini veya sınıflandırmasını veren son katmandır. Nöronlar arasındaki bağlantılar, belirli ağırlıklarla çarpılan sinyalleri taşır. Bu ağırlıklar, öğrenme süreci boyunca ayarlanır ve modelin performansını optimize etmektedir. Her nöron, girdilerini işledikten sonra bir aktivasyon fonksiyonu uygular. Bu fonksiyonlar, nöronun üreteceği çıkışı belirler. Yaygın aktivasyon fonksiyonları arasında sigmoid, tanh ve ReLU bulunur (Schmidhuber, 2015). İleri yayılım (Forward Propagation), giriş verilerini ağ boyunca ileriye doğru taşınır ve her katmanda işlenir. Çıkış katmanına ulaşana kadar bu işlem devam eder. İleri yayılım süreci, ağın tahmin yapma yeteneğini belirler. Hata hesaplama, çıkış katmanında üretilen tahminler, gerçek değerlerle karşılaştırılır ve hata hesaplanır. Hata fonksiyonları, ağın performansını değerlendirmek için kullanılır. Yaygın hata fonksiyonları arasında ortalama karesel hata (MSE) ve çapraz entropi bulunur. Geri yayılım, Hata, ağırlıkları ayarlamak için ağ boyunca geriye doğru yayılır. Ağın öğrenme kapasitesini artırmak için ağırlıkları günceller. Öğrenme oranı (learning rate) gibi parametreler, bu sürecin etkinliğini etkiler (Schmidhuber, 2015). YSA yapısı Şekil 5.4'te gösterilmektedir.



Şekil 5.4 : YSA'nın kendi yapısında giriş, çıkış ve gizli katmanları.

5.5.5 Ansambl öğrenme (ESM)


Ansambl (Ensemble) Öğrenme yöntemleri, birden fazla öğrenme modelini bir arada kullanarak daha iyi performans ve genelleme yeteneği sağlamak amacıyla geliştirilmiştir. Bu yöntemler, çeşitli modellerin birlikte çalışarak tek bir güçlü model oluşturmalarını sağlar. Ansambl, makine öğreniminde genellikle model doğruluğunu artırmak ve overfitting gibi sorunları azaltmak için kullanılır.

Bagging, verilerin farklı alt kümeleri üzerinde aynı modelin birden fazla kez eğitilmesi ve bu modellerin sonuçlarının birleştirilmesi sürecidir. Bu yöntem, genellikle karar ağaçları gibi yüksek varyanslı modellerin performansını artırmak için kullanılır. Eğitim verisinden rastgele örnekler alınır (bootstrap) ve her örnekle bir model eğitilir. Her modelin tahminleri birleştirilir (örneğin, sınıflandırma için çoğunluk oylaması, regresyon için ortalama) (Zhou, 2021). Boosting, zayıf öğrencilerden (weak learners) oluşan bir ansambl oluşturur ve her yeni öğrenci, önceki öğrencilerin hatalarını düzeltmeye çalışır. Bu yöntem, modelin doğruluğunu artırmak için güçlü bir stratejidir. Boosting, zayıf öğrencilerden (weak learners) oluşan bir ansambl oluşturur ve her yeni öğrenci, önceki öğrencilerin hatalarını düzeltmeye çalışır. Bu yöntem, modelin doğruluğunu artırmak için güçlü bir stratejidir. Stacking, farklı türdeki öğrencilerden oluşan bir ansambl oluşturur ve bu öğrencilerin tahminlerini bir üst seviye model ile birleştirir. Bu yöntem, çeşitli modellerin güçlü yönlerini bir araya getirir.

5.6 Performans Parametreleri

Sınıflandırma sonuçlarının doğruluğunu ve etkinliğini değerlendirmek, modelin performansını anlamak açısından oldukça kritik bir adımdır. Bu tezde, model performansını objektif bir biçimde ölçmek amacıyla k-katlı çapraz doğrulama, karışıklık matrisine dayalı metrikler ve ROC eğrileri gibi yöntemler kullanılmıştır. Çapraz doğrulama, makine öğrenmesinde yaygın olarak tercih edilen bir tekniktir ve modelin performansını değerlendirmek, aşırı uyum sorununu önlemek ve hiper parametre ayarlamalarını yapmak için kullanılmaktadır. Bu yöntem, veri setini eşit boyutlarda k parçaya böler ve her seferinde bir parçayı test seti olarak kullanırken geri kalan k-1 parçayı eğitim seti olarak kullanarak k kez işlem yapmaktadır. Sonuç olarak, her parça test seti olarak kullanıldığında modelin performansı k kez ölçülür ve bu sonuçların ortalaması alınarak modelin gerçek performansı tahmin edilir. Şekil 5.5'te çapraz doğrulamanın bir örneği görsel olarak gösterilmektedir.

Genellikle k değeri 5 veya 10 olarak belirlenir, ancak veri setinin boyutuna ve modelin karmaşıklığına bağlı olarak farklı değerler de seçilebilir.



Şekil 5.5 : K-katlı çapraz doğrulama gösterimi.

K-katlı çapraz doğrulama işlemindeki test bloklarının değerlendirilmesi için Çizelge 5.1’de yer alan KAH ve Kontrol olmak üzere iki sınıflı karışıklık matrisi tablosu kullanılmaktadır (Luque vd., 2019).

Çizelge 5.1 : İki sınıflı bir karışıklık matrisi

Gerçek Sınıf	Tahmin Sınıf	
	1: Pozitif (KAH)	0: Negatif (Kontrol)
1: Pozitif (KAH)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
0: Negatif (Kontrol)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Tablodaki kısaltmaların anlamları şu şekildedir: DP, KAH grubundaki kişilerin doğru şekilde KAH olarak sınıflandırılmasını ifade eder; YN, KAH grubundaki kişilerin yanlışlıkla Kontrol olarak sınıflandırılmasını belirtir; YP, Kontrol grubundaki kişilerin yanlışlıkla KAH olarak sınıflandırılmasını ifade eder; ve DN, Kontrol grubundaki kişilerin doğru şekilde Kontrol olarak sınıflandırılmasını temsil eder. Karışıklık matrisini kullanarak

sınıflandırma performansını değerlendirmek için kullanılan metriklerin tanımları ve matematiksel ifadeleri aşağıda verilmiştir:

Konfüzyon Matrisi (Confusion Matrix): Modelin tahminleri ile gerçek etiketlerin karşılaştırıldığı bir tabloda dört ana bileşen bulunur: True Positive (TP), True Negative (TN), False Positive (FP) ve False Negative (FN).

AUC-ROC (Area Under the Curve - Receiver Operating Characteristic): AUC, modelin sınıflar arasındaki ayrımı ne kadar iyi yaptığına dair genel bir özet sağlar. 1'e yakın AUC değerleri, mükemmel performansı gösterirken, 0.5 değerleri modelin rastgele tahminler yaptığını gösterir. AUC-ROC, farklı eşik değerlerinin etkisini analiz etmek için kullanılmaktadır.

Doğruluk (Accuracy, ACC): Doğruluk, tüm tahminlerin ne kadarının doğru olduğunu ölçer. Yüksek doğruluk, modelin genellikle doğru tahminler yaptığını gösterir. Ancak, dengesiz veri setlerinde (örneğin, çok sayıda negatif örnek ve az sayıda pozitif örnek) yanıltıcı olabilir, çünkü model çoğunlukla baskın sınıfı tahmin ederek yüksek doğruluk oranına sahip olabilir. Doğruluk (ACC) performans metriği aşağıdaki denklemle hesaplanır:

$$ACC = \frac{TP + TN}{TP + FN + TN + FP} \quad (5.9)$$

Hassasiyet (Precision): Hassasiyet, modelin pozitif tahminlerinin ne kadarının doğru olduğunu gösterir. Yüksek hassasiyet, modelin pozitif sınıfa ait doğru tahminleri yapma konusunda iyi olduğunu gösterir. Yanıltıcı pozitiflerin (false positives) ne kadar düşük olduğunu anlamak için kullanılmaktadır. Hassasiyet (PRC) performans metriği aşağıdaki denklemle hesaplanır:

$$PRC = \frac{TP}{TP + FP} \quad (5.10)$$

Duyarlılık (Recall/Sensitivity) / Tespit Oranı (True Positive Rate): Duyarlılık, modelin gerçek pozitif örnekleri yakalama yeteneğini göstermektedir. Yüksek duyarlılık, modelin pozitif sınıfa ait örnekleri ne kadar iyi yakaladığını ispatıdır. Yanıltıcı negatiflerin (false negatives) ne kadar düşük olduğunu anlamak için kullanılmaktadır. Duyarlılık (RCL) performans metriği aşağıdaki denklemle hesaplanır:

$$RCL = \frac{TP}{TP + FN} \quad (5.11)$$

F1 Skoru (F1 Score): F1 skoru, hassasiyet ve duyarlılığı birleştirerek bu iki metrik arasındaki dengeyi sağlar. Özellikle dengesiz veri setlerinde veya bir sınıfın diğerlerinden daha önemli olduğu durumlarda faydalıdır. F1 skoru, yüksek hassasiyet ve yüksek duyarlılığın birlikte sağlanıp sağlanamadığını göstermektedir. F1 skoru (F_1) performans metriği aşağıdaki denklemle hesaplanır:

$$F_1 = 2 \times \frac{SNS \times PRC}{SNS + PRC} \quad (5.12)$$

Özgüllük (Specificity): Özgüllük, modelin negatif örnekleri doğru bir şekilde tahmin etme yeteneğini göstermektedir. Yüksek özellikler değeri, modelin yanlış pozitif tahminlerin ne kadar düşük olduğunu sonucuna varılmaktadır. Özgüllük (SPC) performans metriği aşağıdaki denklemle hesaplanır:


$$SPC = \frac{TN}{TN + FP} \quad (5.13)$$

6. BENZETİM ORTAMLARININ BİRLEŞTİRİLEREK ANALİZLERİN ÇERÇEKLEŞTİRİLMESİ

Bu bölümde, tez çalışmasında uygulanan ve tüm değerlendirme aşamalarını kapsayan sistematik yaklaşımı sunulmaktadır. Bu aşamalar, önerilen metodolojinin tanımlanması, tasarlanan transformatör modeli ile referans transformatörün parametrelerinin kıyaslanması, ark ve transformatör modellerinin kuplajlanması, ark arızası verilerin elde edilmesi, arızaya ait akım gerilim sinyallerinin işlenmesi, arızalı disk ve sargıya ait özelliklerinin çıkarılması ve seçilmesi, sınıflandırma, önerilen yığın öğrenme yönteminin uygulanması ve sistem performansının değerlendirilmesini içerir. Önerilen Ark Arızası Tespiti (AFD) tahmin metodolojisi Şekil 6.1’de gösterilmiştir.

6.1 Önerilen Metodoloji

Transformatör sargılarında meydana gelen ark arızasının, henüz arızanın başlangıç anında iken transformatör girişindeki geçici rejim akım ve gerilim sinyallerinin işlenmesi yoluyla arızalı sargı ve arızalı diskin tespit edilmesine yönelik bir tahmin yöntemi sunulmaktadır. Şekil 6.1’de aşağıdaki bölümlerde daha ayrıntılı olarak açıklanan her bir bloğun bir bileşeni temsil ettiği sistemi göstermektedir. Önerilen AFD tahmin sistemi dört ana bloktan oluşmaktadır: Transformatör Modelinin Uygunluğu, Transformatör ve Ark Modellerinin Kuplajı, Sinyal İşleme ve Sınıflandırma.



Şekil 6.1 : Önerilen Ark Arızası Tespiti (AFD) tahmin metodolojisi.

Transformatör modelinin uygunluğu aşaması, 15 MVA gücündeki tasarımı ve etiket değerleri bilinen güç transformatörü ile ANSYS@MATLAB ortamında 3 boyutlu olarak modellenen transformatör verilerinin kıyaslanması ile elde edilecektir. Model uygunluğu için, akım ve gerilim verileri, bakır kayıpları, demir kayıpları, $\%U_k$ ve manyetik akı yoğunluğu dağılımları karşılaştırılacaktır. Böylelikle referans transformatör modeline en uygun ve yaklaşık model belirlenmiş olacaktır.

Transformatör ve ark modellerinin kuplajı aşaması, ANSYS@Maxwell ortamında tasarlanan transformatör modeli ile MATLAB@Simulink ortamında modellenen ark modeli ANSYS@Simplorer ortamında eş zamanlı olarak kuplajlanmıştır. Böylece sargılarda meydana gelen ark, elektriksel ve elektromanyetik etkileri doğrudan transformatör üzerinde izlenmektedir. Transformatörde, toplam 6 sargı (3 adet YG ve 3 adet AG) ve 66 diskten (her bir sargıda 11 disk) oluşan sistemden sabit ark uzunluğuna ait toplam 361 adet ark arızası verisi elde edilmiştir.

Sinyal işleme aşaması, transformatör girişinden her bir sargıya ait akım ve gerilim sinyalleri FFT yöntemiyle işlenmiştir. Ark arızasından kaynaklı oluşan yüksek frekanslı bileşenler transformatör girişinde küçük genliğe sahip yüksek frekanslı dalgalanmalara neden olmaktadır. Böylelikle ark arızası durumundaki arızalı sargı ve arızalı diske ait özellikler elde edilmiştir.

Sınıflandırma aşamasında, arızalı sargı ve arızalı disk özellikleri birbirinden bağımsız olarak analiz edilir ve her iki özellik grubunun birlikte ele alındığı analizler yapılır. Her özellik için sınıflandırma amacıyla 10 kat çapraz doğrulamalı makine öğrenmesi yöntemleri ve küme öğrenme yöntemleri kullanılmıştır. Performans değerlendirmeleri buna göre yapılmıştır.


6.2 Transformatör performans parametrelerinin elde edilmesi

Bu çalışmanın başlangıcında, tasarımı ve etiket değerleri bilinen bir transformatörün ANSYS@Maxwell 3D ortamında geçici durum modeli olarak tasarlanmıştır. Bu transformatöre ait parametreler Çizelge 6.1’de verilmiştir. Maxwell ortamında sargı malzemesi olarak bakır, nüve malzemesi olarak M125-027S kullanmıştır.

Çizelge 6.1 : Transformator parametreleri

Etiket Bilgisi	Değer	Etiket Bilgisi	Değer
Nominal Güç	15 MVA	Nüve Malzemesi	M125-027S
YG/AG Gerilimleri	33 000 / 11 000 V	Yığılma Faktörleri	0.93
YG/AG Bağlantısı	Δ / Y	Nüve Tipi	Step Lap
YG/AG Sarım Sayısı	665/119	Nüve Malzeme Kütle Yoğunluğu	7 650 kg/m ³
Akım Yoğunluğu (YG Sargısı)	3.68 A/mm ²	Nüve Kh Malzeme Laminasyonu	43.59 W/m ³
Akım Yoğunluğu (AG Sargısı)	3.19 A/mm ²	Nüve Kc Malzeme Laminasyonu	0.599 W/m ³
YG Sargısı Direnci	1.7 Ω	Nüve Malzeme Kalınlığı	0.27 mm
AG Sargısı Direnci	40 m Ω	Nüve Malzeme İletkenliği	5 000 000 S/m
Frekans	50 Hz	Nüve Çapı	430 mm
Kısa Devre Gerilimi	%10	Nüve Yoke Uzunluğu	1 416 mm
Yüzdesi			
Bakır Kaybı	97 000 W	Nüve Ayak Boyu	839 mm
Demir Kaybı	12 000 W	Nüve Kesit Alanı	1 270 cm ²

Nüve yapısı tasarım ölçülerinde oluşturulmuş olup, nüve şebeke frekansı olan 50 Hz'e göre ayarlanmıştır. Sargı yapıları hem YG hem de AG sargıları her biri 11 diskten oluşup Şekil 6.2'de gösterilmektedir.

**Şekil 6.2 : Transformator ANSYS@Maxwell tasarımı**

6.2.1 Normal Koşullarda Çalışması


Transformatör modelinin uygunluğu belirlemek için normal koşullar altında çalıştırılmalıdır. Modelden elde edilen veriler, transformatör etiket değeri ve hesaplanmış transformatör değeriyle kıyaslanması modelin uyumluluğuna ait önemli bir kriter sunmaktadır. Böylelikle modelin ark arızası altındaki davranışının güvenilirliği açısından kafa karışlığına neden olan sorunları da ortadan kaldırmış olur.

ANSYS@Maxwell ortamında modellenen transformatör, maksimum $t=0.1s$ simülasyon süresi ve 0.001 ms örnekleme aralığı ile analiz edilmiştir. Transformatör için üretici tarafından sağlanan hesaplanmış tasarım özellikleri ile elde edilen simülasyon sonuçları karşılaştırılmış ve Çizelge 6.2'de sunulmuştur. Elde edilen model sonuçları ile hesaplanmış veriler uyum içindedir.

Çizelge 6.2 : Fabrika verileri ile modelleme sonuçlarının karşılaştırılması

Özellikler	Etiket Verileri	Hesaplama Verileri	Simülasyon Sonuçları
Sekonder Faz Akımı	156 A	151.5 A	154.9 A
Sekonder Hat Voltajı	11 000 V	10 883 V	10.963 V
Çekirdek Kayıpları	12 000 W	12 357 W	12 129 W
Bakır Kayıpları	97 000 W	96 848 V	94 342 W
Maksimum Manyetik Akı Yoğunluğu	1.87 T	1.84 T	1.87 T
U_k	10%	9.69%	9.76%


Analiz edilen transformatörün çekirdek kayıpları Şekil 6.3'te gösterilmiştir. Çekirdek kayıpları Ediriweera vd. (2020) ve Nicolae vd. (2013) tarafından sunulanlarla karşılaştırılmış ve iyi bir uyum gözlenmiştir (Ediriweera vd., 2020; Nicolae vd., 2013).



Şekil 6.3 : Transformatör modeli çekirdek kayıpları değişimi

6.2.2 Kısa Devre Çalışması


Transformatörün elektromanyetik analiz yöntemi, kısa devre akımı, kaçak akı tahmini ve elektromanyetik kuvvet hesaplamalarıyla ilgili matematiksel modelleme ve hesaplama bilgilerini kapsamaktadır. Ayrıca, transformatörün 3D modelleme sürecini gösteren akış diyagramı Şekil 6.4'te sunulmuştur (Alpsalaz vd., 2022a). ANSYS@Maxwell ortamında oluşturulan model, kısa devre analizinden başlayarak elektromanyetik alan çözümüne kadar olan bir süreç akışını göstermektedir. İlk aşamada eşdeğer devre çözümü yapılır, ardından devre denklemleri ve kısa devre akımları hesaplanır. Sonrasında elektromanyetik analiz yapılır ve kaçak akımlar ile kısa devre kuvvetleri hesaplanır. Bu süreç, elektromanyetik analizler (radyal ve eksenel kuvvetler dahil) tamamlanarak sona erer. Tüm aşamalar birbirleriyle bağlantılı olup analizlerin detaylı bir şekilde gerçekleştirilmesini sağlamıştır.




Şekil 6.4 : Kısa devre çalışma diyagramı

Modellenen transformatörde, en yaygın arıza türlerinden biri olan tek faz arızası durumunda sargılarında oluşan elektromanyetik kuvvetler analiz edilmiştir. Transformör

tasarımına göre faz sargıları soldan sağa C-A-B sırasına göre düzenlenmiştir. Şekil 6.5'te, transformatörün alçak gerilim sargısındaki A fazının akım yoğunluğu gösterilmektedir. Kısa devre anında, nominal gerilim ve akım seviyelerindeki B ve C fazlarındaki dağılımla kıyaslandığında, manyetik akı yoğunluğunun daha geniş bir alana yayıldığı transformatörün üst görünümünde gözlemlenmiştir. Arıza nedeniyle transformatör sargılarına etki eden elektromanyetik radyal kuvvetler ise Şekil 6.6'da sunulmaktadır. Arızanın olmadığı normal çalışma koşullarında sargılara etkiyen radyal kuvvetler 77 N seviyelerinde salınırken, kısa devreye uğrayan A sargısındaki radyal kuvvetler 664N değerlerine kadar salınım yaptığı tespit edilmiştir. Kısa devre sırasında, transformatörden geçen akım nominal çalışma akımına göre çok daha yüksek seviyelere çıkar. Bu yüksek akım, manyetik alan yoğunluğunu artırır ve sargılar üzerindeki elektromekanik kuvvetlerin, özellikle radyal kuvvetlerin, büyümesine neden olur. Radyal kuvvetler, akımın karesiyle orantılı olarak artar. Arızalı durumdaki radyal kuvvetlerin, normal çalışma koşullarındaki radyal kuvvetlerden birkaç katından daha fazla olması beklenmektedir.



Şekil 6.5 : A faz-Toprak arızası manyetik akım yoğunluğu



Şekil 6.6 : A faz-Toprak arızası sonucu transformatör sargılarına etki eden elektromanyetik radyal kuvvetler

6.2.3 Harmonikli Çalışma

Transformatörler, genellikle doğrusal yükleri beslemek için 50 veya 60 Hz sinüzoidal güç frekansında çalışacak şekilde tasarlanmıştır. Ancak, yarı iletken teknolojisinin gelişimiyle doğrusal olmayan yükler yaygınlaşmış ve bu yüklerin sebep olduğu harmonikler, şebeke sinyalinde bozulmalara yol açmıştır. Bu bozulmalar, şebeke frekansının katları şeklinde daha düşük genlikli sinyallerde ortaya çıkar ve harmonik olarak adlandırılmaktadır. Harmoniklerin şebeke üzerindeki olumsuz etkileri, IEC 61000-3-6 ve IEEE 519-2014 standartları ile sınırlandırılmıştır (Alpsalaz ve Mamiş, 2023). Standartlara uygun seviyelerde harmonik oluşumunun sağlanması, transformatör kayıplarının analizini ve etkilerinin hesaplanmasını gerektirir (Alpsalaz vd., 2022b). IEC standardına göre daha düşük seviyede harmonik üretimi, hem bireysel harmonik yüzdeleri hem de toplam harmonik bozulma (THD - Total Harmonic Distortion) seviyesini sağlamayı gerektirir. 33 kV (RMS) genliğe sahip şebekelerde izin verilen maksimum THD sınırları, IEC 61000-4-7 standartlarına göre belirlenmiştir (Albadi, 2016). Modellemede kullanılan THD harmonik değerleri Tablo 6.3'te verilmiştir.

Çizelge 6.3 : Harmonik seviyelerine ait THD değerleri

Harmonik	Maksimum sınır değeri(%)	THD0 (%)	THD1 (%)
5	5	0	3,5
7	4	0	3
11	3	0	2
13	2,5	0	1,5
Total		0	4,97

Çizelge 6.3'te THD=4.92 değeri için her bir harmonik bileşene ait yüzdelik harmonik katsayıları, ana harmoniğe eklendiğinde oluşan histerezis, Fuko ve çekirdek kayıplarının ortalama ve maksimum değerleri Çizelge 6.4'te sunulmaktadır. Şebekedeki bozulma miktarındaki artışın, kayıpların ve özellikle maksimum noktalardaki kayıp değerlerinin yükselmesine neden olduğu gözlemlenmiştir.


Çizelge 6.4 : THD=0 ile THD=4.97 kayıpların karşılaştırmaları

Kayıplar (kW)	THD=0	THD=4.97
Ortalama Histerezis Kayıpları	7.22	7.24
Maksimum Histerezis Kayıpları	9.51	9.85
Ortalama Fuko Kayıpları	4.09	4.17
Maksimum Fuko Kayıpları	6.82	6.52
Ortalama Çekirdek Kayıpları	12.12	12.66
Maksimum Çekirdek Kayıpları	15.67	16.23

6.3 Modellerin ANSYS@Simplorer Ortamında Birleştirilmesi

ANSYS@Maxwell ortamında tasarlanan 15 MVA trafo modeli, MATLAB@Simulink ortamında oluşturulan ark modelleri ile ANSYS@Simplorer içerisinde birleştirilmiştir. Maxwell trafo manyetik analizini gerçekleştirirken, ark olayından gelen akım ve gerilim bilgileri eş zamanlı olarak Simulink üzerinden aktarılır (Alpsalaz ve Mamiş, 2024). Bu kuplajlama olayı Simulink ortamında gerekli ortamlarda alt dosyalarla ilinti oluşturulduktan sonra, “AnsoftSFunction” komutla oluşturulmuş olan model aktarımı gerçekleştirilir. Şekil 6.7'de MATLAB@Simulink'te modellenen arkın ANSYS'teki manyetik modele uyarlanmış yapısı gösterilmektedir. Ayrıca, Şekil 6.7'deki MDL1 MATLAB@Simulink modelini gösterirken, FEAl ANSYS@Maxwell modelini göstermektedir. Diğer devre elemanları MATLAB ve ANSYS arasında bağlantı kurmak için

kullanılan ANSYS@Simplorer'ın bileşenleridir. Diyagramda E1, E2 ve E3 kaynak gerilimlerini; VM voltme-terleri; AM ampermetreleri, R1, R2 ve R3 kaynak iç dirençlerini; R11, R12 ve R13 birincil sargı dirençlerini; R4, R7 ve R9 ikincil sargı dirençlerini; R5, R6 ve R8 nominal yük dirençlerini ve R10 doğrusal olmayan ark direncini göstermektedir. Simülasyon ANSYS@Simplorer ortamında başlatıldığında, matematiksel modelin gömülü olduğu MATLAB@Simulink eşzamanlı olarak çalışmaktadır. Akım ve gerilim bileşenleri Simulink aracılığıyla doğrusal olmayan R10 direncine iletilerek analizlerin gerçekleştirilmesi sağlanmıştır.




Şekil 6.7 : Ark analizi için geliştirilen MATLAB@Simulink uyumlu ANSYS@Simplorer modeli

ANSYS@Simplorer ortamında gerçekleştirilen kuplajlama işlemine ait Şekil 6.7'deki parametreler aşağıdaki gibidir:

- Faz rms gerilimleri: $E1=19.05\angle 0^\circ$ kV, $E2=19.05\angle 120^\circ$ kV ve $E3=19.05\angle 240^\circ$ kV'tur.
- Kaynak direnci: $R1=100\text{ m}\Omega$, $R2=100\text{ m}\Omega$ ve $R3=100\text{ m}\Omega$ 'dur.
- Birincil sargı dirençleri: $R11=1.7\text{ }\Omega$, $R12=1.7\text{ }\Omega$ ve $R13=1.7\text{ }\Omega$ 'dur.
- İkincil sargı dirençleri: $R4=40\text{ m}\Omega$, $R7=40\text{ m}\Omega$ ve $R9=40\text{ m}\Omega$ 'dur.
- Yük değerleri: $R5=8.06\text{ }\Omega$, $R6=8.06\text{ }\Omega$ ve $R8=8.06\text{ }\Omega$ 'dur.
- Seri direnç, $R14=1\text{ m}\Omega$ 'dur.

6.4 Ark Arızasının Akım ve Gerilim Sinyallerinin Elde Edilmesi


Ark arızası analizi için maksimum simülasyon süresi $t=0.04$ s, örnekleme aralığı ise 0.001 ms olarak belirlenmiştir. Arklanma, $t=0.015$ s'de başlatılmıştır; bu, transformatörün ilk enerjilendirilme anındaki geçici durumu ortadan kaldırmakta ve arklanma anındaki geçici durumlar üzerinde herhangi bir etkisi bulunmamaktadır. Transformatör sargılarındaki farklı noktalardaki ark rızası için oluşturulan sargı yapıları Şekil 6.8'de yer verilmiştir.



Şekil 6.8 : Transformatör sargılarındaki farklı noktalardaki ark rızası için oluşturulan sargı yapıları


Transformatör çekirdeğindeki manyetik akı yoğunluğu dağılımı ($t=0.35$ ms'deki) Şekil 6.9'de gösterilmektedir. ANSYS@Maxwell ortamında 3 boyutlu olarak gerçekleştirilen elektromanyetik geçici durum analizi ve anlık akı dağılımını yerel olarak izleyerek akı dağılımı hakkında kapsamlı bilgi sağlamaktadır. Kullanılan sac malzemesinin

maksimum akı yoğunluğu 1.87 T olup, bu değer kırmızı renkle en yoğun akı geçişini göstermektedir. Akı geçişinin az olduğu veya hiç olmadığı bölgeler ise mavi renkle yer verilmiştir.




Şekil 6.9 : Ark Arızası olmuş transformatör çekirdeğindeki manyetik akı yoğunluğu dağılımı ($t=0.35$ ms'deki)

Ark arızası $t=0.015$ sn başlayan ark sinyaline ait akım ve gerilimin zamana karşı değişimi Şekil 6.10'da gösterilmiştir. Ark'ın oluşma anındaki gerilim değeri sabit kalmakta çekilen akım sinüzoidal olarak değişmekte iken gerilim seviyesi arkın atlama seviyesini dışına çıktığında ise akım hızlıca sönümlenmektedir. Buradaki durum ark akımının rijit (katı) geçiş durumunun o anlık kesildiği anlamını taşımaktadır. Gerilim atlama seviyesine tekrar ulaştığında geçiş rijit hale tekrardan döndüğü görülmektedir. Akım ve gerilim seviyelerindeki bu dengesiz değişim transformatör girişinde harmonikler oluşturmaktadır. Ark'ın gerilime bağlı akım değişimi Şekil 6.11'de yer verilmiştir.




Şekil 6.10 : Ark akımı ve geriliminin zamana bağlı değişimi




Şekil 6.11 : Ark'ın Gerilim-Akım değişimi

ANSYS@Simplorer ortamındaki Transformatör giriş terminallerinden akım ve gerilim bilgisi hem ANSYS ortamından hem de MATLAB ortamından elde edilmiştir. Simülasyon sonucunda ANSYS@Simplorer ortamından elde edilen veri Şekil 6.12’de yer verilirken MATLAB ortamına aktarılan akım ve gerilim bilgisi Şekil 6.13’te gösterilmiştir.



Şekil 6.12 : ANSYS@Simplorer ortamındaki ark arızası sonucu oluşan terminal geriliminin değişimi




Şekil 6.13 : MATLAB ortamına aktarılan ark arızası sonucu oluşan terminal akım/gerilim değişimi

6.5 Transformatör Girişlerinden Alınan Akım/Gerilim Sinyallerinin İşlenmesi


Transformatörlerdeki arızanın tespiti noktasında sinyal işleme yöntemleri yaygın olarak kullanılmaktadır. Ark'ın doğrusal olamayan yapısından dolayı transformatör girişinden elde edilen akım ve gerilim sinyallerinde şebekede yüksek frekansa sahip harmonikler oluşturmaktadır. Bu düşük genliğe sahip yüksek harmoniklerin analizlerinin hızlı ve kolay işlenebilmesinden dolayı FFT yöntemi tercih edilmiştir.

Frekans spektrumu zaman alanı sinyalleri 25.6 kHz'de örneklenmiş ve 1024 adet örnek alınmıştır. FFT sızıntısını azaltmak için, FFT öncesinde örneklenmiş gerilim ve akım sinyallerine Hanning penceresi uygulanmıştır. 40 ms örnekleme süresi için FFT spektrum çözünürlüğü 50 Hz'dir. Bu çözünürlük, özellikle düşük frekanslarda, arıza mesafesi tahmininin doğruluğunu etkileyebilir. FFT frekans çözünürlüğünü 12.5 Hz'e artırmak için, pencereleme sonrasında, pencere uygulanmış örnek sinyale 1024 sıfır eklenmiştir. Simülasyon sonuçlarından, 12.5 Hz çözünürlüğün önerilen arıza mesafesi tespit tekniği için yeterli olduğu gözlemlenmiştir. Diğer olası hata kaynağı ise sayısal hesaplamalardaki kesme hatası olarak kabul edilmektedir.

Transformatör giriş terminalerinden alınan akım/gerilim sinyallerine FFT dönüşümü uygulanır. FFT hesaplamalarını önemli ölçüde hızlandırır ve büyük veri setlerinin analizini mümkün kılar. MATLAB ortamına aktarılan akım/gerilim sinyalleri FFT yardımıyla frekans spektrumları çıkarılır.




a)




b)

Şekil 6.14 : YG meydana gelen ark arızasına ait gerilim spektrumları a) *Disk1*
b) *Disk3*

YG tarafında meydana gelen ark arızasına ait gerilim spektrumları Şekil 6.14' te gösterilmektedir. YG tarafında meydana gelen ark arızasına ait akım spektrumları Şekil 6.15' de gösterilmektedir.




a)




b)

Şekil 6.15 : YG meydana gelen ark arızasına ait akım spektrumları a)Disk1 b)Disk3

AG tarafında meydana gelen ark arızasına ait gerilim spektrumları Şekil 6.16' da görülmektedir.




a)




b)

Şekil 6.16 : AG meydana gelen ark arızasına ait gerilim spektrumları a)Disk1
b)Disk3

AG tarafında meydana gelen ark arızasına ait gerilim spektrumları Şekil 6.17' de görülmektedir.



a)




b)

Şekil 6.17 : AG meydana gelen ark arızasına ait akım spektrumları a)Disk1 b)Disk3


Çalışmada ilk önce transformatör modeli nominal yükte çalıştırılmış elde edilen sonuçlarda genellikle çok düşük genlikli ve 5, 7, 11 ve 13. harmoniklerin olduğunu sonraki bulunan diğer harmoniklerin değerleri çok düşük olduğu belirlenmiştir. Ancak, Ark arızalarının oluşturduğu harmoniklerin frekans spektrumlarında YG sargılarında 2.2 kHz ile 5 kHz arasında, AG sargılarında 1 kHz ile 5 kHz etkin değeri nispeten yüksek harmoniklerin olduğu görülmüştür. Bu sonuçlardan yola çıkarak 15.milisaniyede meydana gelen ark ile transformatör çalışmasına başladığındaki geçici durumlarından bu frekans aralığındaki geçici rejimleri etkilemediği kanısı hakimdir.

FFT uygulanan sinyallerin daha belirgin hale gelmesi için Filtre uygulanır. Bu filtre işlemi yüksek harmoniklerdeki frekansları daha belirgin yapmaktadır. Normalize edilmiş geçiş bandının köşe frekansı, durdurma bandının köşe frekansı, geçiş bandındaki dalgalanma ve durdurma bandındaki zayıflamaya ilişkin parametreleri kullanılmıştır. Bu parametrelere ilişkin değerler ve kodlaması Ek F’de verilmiştir. Bir başka ifadeyle ana harmonik ve ona yakın seviyelerdeki harmonikleri baskılanmıştır. YG tarafında meydana gelen ark arızasına ait filtre uygulanmış akım spektrumları Şekil 6.18’ de gösterilmektedir. Arıza noktası giriş terminalinden uzaklaştıkça oluşturduğu yüksek frekanslı harmoniklerin hem genlik hem de frekans değerleri gittikçe küçülmektedir. Disk1’de meydana gelen ark arızasına ait harmoniğin en yüksek frekans değeri 3550 Hz iken, Disk11’de meydana gelen ark arızasına ait harmoniğin frekans değeri 2200 Hz’dir. AG sargılarında ise Disk1’de meydana gelen ark


arızasına ait harmonik değeri 2125 Hz iken, Disk11'de meydana gelen ark arızasına ait harmoniğin frekans değeri 900 Hz'dir. Harmoniklerin ilk birkaç diskte frekans değerleri çok hızlı değişirken sargının sonuna doğru çok az değişmektedir. Elde edilen arıza sinyallerine ait spektrum özellikleri yapay zeka uygulamalarındaki sınıflama verileri için önemli bir ayırıcı parametre olarak kullanılmasında büyük avantaj sağlamaktadır.




a)




b)



c)



d)



e)

Şekil 6.18 : YG Sargısında meydana gelen ark arızasına ait filtre uygulanmış akım spektrumları a)Disk1, b)Disk3, c)Disk5, d) Disk9, e)Disk11

6.6 Arıza Fazı ve Arıza Diskinin MÖ Yöntemiyle Tespiti ve Metrik Parametrelerin karşılaştırılması

Arızalı sargı ve arızalı disk tespiti amacıyla çeşitli makine öğrenmesi algoritmalarının performansı değerlendirilmiştir. K-en yakın komşuluk (K-NN), Yapay Sinir Ağları (YSA), Karar Ağaçları (DT), Destek Vektör Makineleri (SVM) ve Ansamble yöntemleri kullanılarak gerçekleştirilen sınıflandırma işlemleri sonucunda, her bir modelin doğruluk (accuracy), duyarlılık (sensitivity), özgüllük (specificity), kesinlik (precision) ve F1 skoru gibi metrikler üzerinden başarıları analiz edilmiştir. Çalışmada kullanılan eğitim ve test verileri üzerinde modellerin gösterdiği performans, arızalı sargı ve disklerin doğru şekilde tespit edilmesi açısından büyük önem taşımaktadır. Bu bölümde, her bir makine öğrenmesi algoritmasının sunduğu sonuçlar detaylı bir şekilde ele alınacak ve modellerin performans farkları irdelenmiştir.


Çizelge 6.5'te çalışmada kullanılan MÖ modellerine ait hiper parametreleri verilmektedir. Bu hiper parametreleri ile en uygun sonuçları veren algoritmalar seçilmiştir. Hiper parametreler Bayes optimizasyon kullanılarak elde edilmiştir.

Çizelge 6.5 : MÖ modellerinin hiper parametre değerleri


Model	Hiper parametre
K-NN	Mesafe metriği: Kosinüs, Komşu sayısı: 15, Mesafe ağırlığı: Ters Kare
YSA	İlk katman boyutu: 75, İkinci katman boyutu: 232, Aktivasyon Fonksiyonu: Sigmoid, Lambda: 5.59
DT	Maksimum bölünme sayısı: 101, Bölünme ölçütü: Gini Çeşitlilik İndeksi
SVM	Çekirdek fonksiyonu: Gauss, Çekirdek Ölçeği: 0.094, Kutulama kısıt seviyesi: 840.31
ESM	Maksimum bölünme sayısı: 223, Yöntem: RUS Boost, Öğrenme Döngüsü Sayısı: 13, Öğrenme Hızı: 0.961

K-NN: K-en yakın komşuluk, YSA: Yapay Sinir Ağları, DT: Karar Ağacı Algoritması, SVM: Destek Vektör Makinesi, ESM: Ansamble

Şekil 6.19 ve Şekil 20’de arızalı sargı eğitim ve test verilerine ait AUC-ROC eğrileri gösterilmektedir. AGA, YGA ve YGC modellerinin AUC değerleri 1 olarak belirtilmiştir. Bu, modellerin mükemmel performans gösterdiği, yani hiçbir yanlış sınıflandırma yapmadığı anlamına gelmektedir. AGB ve YGB modellerinin AUC değerleri sırasıyla 0.9975 ve 0.9997’dir. Bu modeller de oldukça yüksek performans sergiliyor; ancak, çok küçük bir hata payı ile diğerlerine göre daha düşük performansa sahiptirler. AGA ve YGC modelleri, AUC-ROC eğrisinde en yukarıda ve solda konumlanmış olup, bu durum en yüksek doğruluk oranlarını temsil eder. AGB ve YGB modelleri ise AUC değerlerinin biraz daha düşük olduğunu gösteren küçük sapmalarla çizilmiş, ancak yine de AUC-ROC eğrisi boyunca oldukça iyi performans göstermiştir.




Şekil 6.19 : Arızalı sargı eğitim verisine ait AUC-ROC eğrisi (DT)




Şekil 6.20 : Arızalı sargı test verisine ait AUC-ROC eğrisi (DT)

Şekil 6.21 ve 6.22’de Arızalı sargı eğitim ve test verisine performansını değerlendirmek için kullanılmıştır. Her satır, gerçek sınıfı (True Class) ve her sütun, tahmin edilen sınıfı (Predicted Class) göstermektedir. Kutular içindeki değerler kaç adet doğru tahmin yaptığını göstermektedir. Diyagonal olarak her seferinde doğru tahminler yapıldığını, modelin sınıfları oldukça iyi ayırt ettiğini gösterdiği görülmektedir.




Şekil 6.21 : Arızalı sargı eğitim verisine ait konfüzyon matrisi (SVM)




Şekil 6.22 : Arızalı sargı eğitim verisine ait konfüzyon matrisi (SVM)


Şekil 6.23 ve Şekil 6.24’te arızalı diske ait test ve eğitim verilerine ait AUC-ROC eğrileri verilmiştir. AUC-ROC eğrisi boyunca eğriler sağ üst köşeye yakınsa, bu modellerin pozitif sınıfları doğru şekilde sınıflandırmada başarılı olduğu görülmektedir. Eğrinin düz çizgiye yakın olması (örneğin, AGAD4 gibi) düşük performanslı modelleri işaret eder. Genel olarak, çoğu model oldukça iyi performans sergilerken birkaç modelde performans düşüklüğü gözlemlendiği belirlenmiştir.




Şekil 6.23 : Arızalı Disk eğitim verisine ait AUC-ROC eğrisi (K-NN)



Şekil 6.24 : Arızalı Disk eğitim verisine ait AUC-ROC eğrisi (K-NN)



Şekil 6.25 : Arızalı diskin eğitim verisine ait konfüzyon matrisi (ESM)



Şekil 6.26 : Arızalı diskin test verisine ait konfüzyon matrisi (ESM)

Şekil 6.25 ve 6.26’da arızalı disk eğitim ve test verisine performansını değerlendirmek için kullanılmıştır. Her satır, gerçek sınıfı (True Class) ve her sütun, tahmin edilen sınıfı (Predicted Class) göstermektedir. Doğru sınıflandırmalar diyagonal çizgi üzerinde yer alırken, yanlışlar bu çizginin dışındaki hücrelerde bulunmaktadır. Burada, sınıflandırmalar çoğunlukla doğru yapılmış, ancak bazı yanlış sınıflandırmalar mevcut olduğu görülmektedir.

Çizelge 6.6 : Arızalı sargıya ait MÖ parametreleri

Arızalı Sargıyı Bulma	Sınıflayıcı	Doğruluk (Accuracy)	Hata (Error)	Duyarlılık (Sensitivity)	Özgüllük (Specificity)	Kesinlik (Precision)	F1 skoru
Eğitim Sonuçları	K-NN	1	0	1	1	1	1
	YSA	0.9607	0.0393	0.9571	0.9920	0.9682	0.9598
	DT	1.0000	0	1	1	1	1
	SVM	0.9956	0.0044	0.9952	0.9991	0.9961	0.9956
	ESM	1	0	1	1	1	1
Test Sonuçları	K-NN	1	0	1	1	1	1
	YSA	0.9470	0.0530	0.9470	0.9894	0.9532	0.9467
	DT	0.9956	0.0044	0.9952	0.9991	0.9959	0.9955
	SVM	1	0	1	1	1	1
	ESM	1	0	1	1	1	1

K-NN: K-en yakın komşuluk, YSA: Yapay Sinir Ağları, DT: Karar Ağacı Algoritması, SVM: Destek Vektör Makinesi, ESM: Ensemble

Arızalı sargıya ait MÖ sonuçları Çizelge 6.6’da yer verilmiştir. K-NN, DT, SVM ve ESM algoritmaları hem eğitim hem de test sonuçlarında %100 doğruluk ve %0 hata oranı ile mükemmel performans sergilemiştir. Bu sonuçlar, söz konusu modellerin arızalı sargıları tespit etmede hem pozitif hem de negatif örnekleri eksiksiz bir şekilde sınıflandırdığını göstermektedir.

Öte yandan, YSA modeli biraz daha düşük bir performans sergilemiştir. Eğitim setinde %96.07, test setinde ise %94.70 doğruluk oranına ulaşmıştır. Test sonuçlarındaki hata oranı %5.3’e yükselmiştir. Ancak, duyarlılık (%94.7) ve özgüllük (%98.94) gibi önemli metrikler yine de oldukça tatmin edici seviyededir. Ayrıca, F1 skoru da dengeli bir performans sergileyerek modelin genel başarısını desteklemektedir.

Sonuç olarak, K-NN, DT, SVM ve ESM yöntemleri arızalı sargı tespitinde mükemmel sonuçlar elde ederken, YSA modeli biraz daha düşük bir performans göstermiştir.

Çizelge 6.7 : Arızalı diske ait MÖ parametreleri

Arızalı Sargıyı Bulma	Sınıflayıcı	Doğruluk (Accuracy)	Hata (Error)	Duyarlılık (Sensitivity)	Özgüllük (Specificity)	Kesinlik (Precision)	F1 skoru
Eğitim Sonuçları	K-NN	0.8646	0.1354	0.8502	0.9979	0.8414	0.8620
	YSA	0.7991	0.2009	0.7439	0.9969	0.7839	0.8012
	DT	0.6419	0.3581	0.4680	0.9945	0.6921	0.6841
	SVM	0.8297	0.1703	0.8516	0.9974	0.8513	0.8411
	ESM	0.9039	0.0961	0.9139	0.9985	0.9215	0.9054
Test Sonuçları	K-NN	0.9697	0.0303	0.9697	0.9995	0.9798	0.9677
	YSA	0.9545	0.0455	0.9545	0.9993	0.9722	0.9525
	DT	0.6515	0.3485	0.6515	0.9946	0.6827	0.6744
	SVM	0.9621	0.0379	0.9621	0.9994	0.9747	0.9596
	ESM	0.9621	0.0379	0.9621	0.9994	0.9747	0.9596

K-NN: K-en yakın komşuluk, YSA: Yapay Sinir Ağları, DT: Karar Ağacı Algoritması, SVM: Destek Vektör Makinesi, ESM: Ensemble

Arızalı diske ait MÖ sonuçları Çizelge 6.7’de yer verilmiştir K-NN modeli, test sonuçlarına göre %96.97 doğruluk oranıyla arızalı diski tespit etmede yüksek bir başarı göstermiştir. Ancak eğitim setinde doğruluk oranı %86.46’ya düşmektedir. Bu durum, modelin eğitim aşamasında bazı zorluklarla karşılaştığını, fakat test setinde iyi bir genelleme yapabildiğini göstermektedir. YSA modeli ise, arızalı disk bulma konusunda eğitim setinde %79.91 doğruluk sağlarken, test setinde bu oran %95.45’e yükselmiştir. Bu, modelin test setinde daha iyi bir genelleme yeteneğine sahip olduğunu ortaya koymaktadır.

DT modeli ise eğitim setinde oldukça düşük bir doğruluk (%64.19) sergilemekte, test sonuçları da benzer şekilde düşük kalmaktadır (%65.15). Özellikle duyarlılık değerleri eğitimde %46.80 ve testte %65.15 civarında olup, bu da modelin arızalı diskleri tespit etmede zorluk yaşadığını göstermektedir.

SVM ve ESM modelleri, test sonuçlarında %96.21 doğruluk ile benzer bir performans sergilemektedir. Duyarlılık ve özgüllük gibi metrikler %96 ve %99’un üzerinde çıkmakta, bu da her iki modelin de oldukça başarılı olduğunu göstermektedir.

Sonuç olarak, arızalı disk tespitinde genel olarak K-NN, SVM ve ESM modelleri test setlerinde etkileyici sonuçlar elde etmektedir. YSA modelinin test setinde iyi bir performans

göstermesine rağmen, eğitim setindeki düşük doğruluk oranı dikkat çekmektedir. DT modeli ise hem eğitim hem de test aşamalarında düşük performans sergilemiş, bu da modelin disk arızasını tespit etmede zorlandığını göstermektedir.



7. SONUÇ VE ÖNERİLER

Bu tez kapsamında gerçekleştirilen araştırmalar, transformatör iç ark arızalarının erken tespiti için kullanılan sinyal işleme ve makine öğrenmesi yöntemlerinin etkinliğini kapsamlı bir şekilde ortaya koymuştur. Çalışma, enerji sürekliliği ve güvenliğinin daha da önem kazandığı günümüzde, transformatör arızalarının dijital yöntemlerle daha erken aşamalarda tespit edilmesinin mümkün olduğunu kanıtlamaktadır. Çeşitli makine öğrenme algoritmaları ve sinyal işleme teknikleri kullanılarak geliştirilen model, transformatörlerde meydana gelen arızaların doğru ve hızlı bir şekilde belirlenebilmesini sağlayabilecektir.

Çalışmanın ilk aşamasında, etiket değerleri ve tasarımı bilinen bir transformatörün modeli 3D Maxwell ortamında tasarlanmıştır. Tasarımın uygunluğu, fabrika etiket verileri ile hesaplanmış veriler karşılaştırılarak değerlendirilmiştir. Simülasyon sonuçlarının, verilerle uyum göstermiştir. Ayrıca, transformatör modeline kısa devre ve harmonik analizler de uygulanmıştır.

Çalışmanın ikinci aşamasında, MATLAB ortamında bir ark modeli matematiksel olarak diferansiyel denklemlerle Simulink ortamında tasarlanmıştır. Ark'ın doğrusal olmayan yapısından dolayı değişimlerinin transformatör sargılarındaki etkisini belirlemek için ark modeli Simplorer ortamına entegre edilmiştir. Böylece Simplorer ortamı, Maxwell ve Simulink ortamlarının eş zamanlı şekilde çalışmasını sağlamıştır. Transformatör giriş terminallerinden alınan akım gerilim sinyalleri FFT uygulanarak frekans spektrumları elde edilmiştir. Gerçekleştirilen analizlerde, arıza noktasının giriş terminaline yakınlığının daha yüksek frekanslı harmoniklere neden olduğu tespit edilmiştir. Transformatör giriş terminallerinden elde edilen frekans spektrumları incelendiğinde, YG disk1 sargısının üst noktasına yakın bir bölgede 3500 Hz, en alt noktasındaki disk11 sargısının alt noktasında ise 2200 Hz olduğu belirlenmiştir. Karşılaştırma yapıldığında, AG disk 1 sargısının en üst noktasında 2125 Hz, disk 11 sargısının en alt noktasında ise 925 Hz tespit edilmiştir. Elde edilen bulgulara göre, sargıların üst noktalarındaki harmonik frekanslar, ilk birkaç diskte hızlı bir değişim gösterirken, orta disklerde bu değişim daha az belirgin hale gelmektedir. Alt disklerde ise oluşan harmonik frekanslar çok az değişim göstermiştir.

Çalışmanın üçüncü aşamasında ise 361 farklı noktaya ark arızasına ilişkin elde edilen veriler makine öğrenme algoritmaları uygulanarak, arızalı faz ve arızalı diskin tespitine ilişkin alıcı işletim karakteristiği (AUC-ROC) eğrisi, karışıklık matrisi (Confusion Matrix) ve metrik parametreler elde edilmiştir. Makine öğrenmesine ilişkin elde edilen bulgular eğitim ve test verilerindeki sistemin tahmin performansına ilişkin bilgiler sunar. K-NN, DT, SVM ve ESM yöntemleri arızalı sargı tespitinde mükemmel sonuçlar elde ederken, YSA modeli biraz daha düşük bir performans göstermiştir. Arızalı disk tespitinde genel olarak K-NN, SVM ve ESM modelleri test setlerinde etkileyici sonuçlar elde etmektedir. YSA modelinin test setinde iyi bir performans göstermesine rağmen, eğitim setindeki düşük doğruluk oranı dikkat çekmektedir. DT modeli ise hem eğitim hem de test aşamalarında düşük performans sergilemiş, bu da modelin disk arızasını tespit etmede zorlandığını göstermektedir. Böylelikle sargılardaki ark arızaları sensör kullanmadan arızanın erken safhasında tespit edecek yüksek doğruluğa sahip bir tahmin modeli geliştirilmiştir.

Tez sürecinde karşılaşılan zorluklar, bunlara yönelik çözüm önerileri ve kullanılan alternatif yöntemler bu bölümde maddeler halinde sunulmuştur:

- Transformatör modeli, fabrika etiket verileri ve tasarım bilgileri temel alınarak oluşturulmuştur. Ancak modelin ANSYS@Maxwell ortamına aktarımı sırasında, program içerisinde uyumsuzluk, eksiklik veya farklı indekslerdeki parametreler gibi sorunlar ortaya çıkmıştır. Bu sorunların çözümünde, numerik ve analitik hesaplama yöntemleri, parametre optimizasyonu ve en uygun elemanların seçimi gibi yaklaşımlar uygulanmıştır.
- ANSYS@Maxwell tasarımında geçici durum (Transient) modeli kullanılmıştır. Tasarımın çözümlemesinde ise SEY kullanılmıştır. Örneklem aralığının küçük tutulması, geçici durum etkilerinin hem elektriksel hem de manyetik açıdan detaylı bir şekilde incelenebilmesi açısından büyük önem taşımaktadır. Daha iyi sonuçlar elde edebilmek için SEY kapsamında parça sayısının artırılması, tasarımın güvenilirliğini artırmıştır. Ancak, hem daha fazla parça kullanımı hem de düşük örneklem süresi, analiz süresinin ciddi şekilde uzamasına yol açmıştır. Bu olumsuz etkileri minimize etmek amacıyla, değişik özelliklerde bilgisayarlar kullanılarak eş zamanlı analizler gerçekleştirilmiştir. Ayrıca, yeni nesil teknolojiye sahip bilgisayarlarla destek sağlanarak toplamda 361 farklı arızanın simülasyonu başarıyla tamamlanmıştır.

- ANSYS ortamında, aynı sargı grubundaki yakın sargılar arasında ark arızası analizleri başarılı bir şekilde gerçekleştirilebilmiştir. Ancak, farklı gruplardaki sargılar (YG-AG) ve sargılar ile nüve arasındaki (YG-Nüve ve AG-Nüve) ark arızası analizleri bazı teknik engeller nedeniyle tamamlanamamıştır. Bu engeller arasında ark boyunun uzun olması nedeniyle yeterli ark oluşumunun sağlanamaması ve ANSYS çözümleme sürecinde ortaya çıkan yazılımdan kaynaklı hata ve eksiklikler yer almaktadır.
- Ark modeli, akım ve gerilimin doğrusal olmayan yapısı nedeniyle ANSYS ortamlarında diferansiyel denklemlerle çözümlenememektedir. Bu durum, ark modelinin doğru bir şekilde elde edilmesinde önemli bir eksiklik yaratmaktadır. Ancak MATLAB ortamının sağladığı kolay çözümleme olanakları sayesinde, ANSYS ve MATLAB ortamları eş zamanlı olarak birleştirilmiştir. Bu entegrasyon, analiz süresini uzatmakla birlikte, verilerin kaybolmasını engellemiş ve her iki ortamda da verilere erişim sağlama konusunda önemli bir avantaj sunmuştur.
- Ark arızası nedeniyle terminallerden alınan akım ve gerilim sinyallerinin işlenmesinde, uygun örnekleme frekansı ve algoritma eksikliği nedeniyle analizlerden doğru spektrumlar elde edilememiştir. Ancak, uzun süren çalışmalar sonucunda doğru veri aktarımı sağlanmış ve uygun örnekleme frekansı seçilerek bu sorun giderilmiştir.
- Akım ve gerilim spektrum verileri, MÖ algoritmaları kullanılarak uygun tahmin modelleri oluşturmak için işlenmiştir. Hem sargılarda hem de disklerde meydana gelen ark arızalarının tespiti için yüksek doğruluk oranına sahip tahmin algoritmaları başarılı sonuçlar vermiştir. Bununla birlikte, aynı verilerle yapılan derin öğrenme (DÖ) algoritmaları denemelerinde yeterli performans elde edilememiştir.

Bu tez çalışmasından elde edilen kazanımlar ışığında, gelecekte gerçekleştirilebilecek ve konuyla ilgili ilerlemeye katkı sağlayabilecek çeşitli çalışma önerileri geliştirilmiştir. Bu öneriler hem teorik hem de uygulamalı yaklaşımları içerecek şekilde detaylandırılmış olup, ilgili alanlarda daha kapsamlı araştırmaların yapılmasına rehberlik edebilecek niteliktedir. Aşağıda bu öneriler maddeler halinde sunulmaktadır.

- Endüstriyel Uygulamalar için Entegrasyon: Önerilen metodoloji, büyük güç transformatörlerinde online izleme sistemlerine entegre edilebilir. Bu sayede, arıza tespiti süresi önemli ölçüde kısaltılarak, transformatörlerin güvenli ve verimli

alışması saęlanabilir. Endüstri 4.0 kapsamında, sistemlerin otomatik bakım ve izleme platformlarına baęlanması önerilebilir.

- Farklı Makine Öğrenme Algoritmalarının Denenmesi: Mevcut algoritmaların yanı sıra, Derin Öğrenme, Pekiştirmeli Öğrenme ve Hibrit Algoritmalar gibi yöntemler de ilerleyen alışmalarda kullanılabilir. Özellikle daha büyük ve karmaşık veri setlerinde bu yöntemlerin performansı karşılaştırılabilir ve arıza tespit süresi daha da kısaltılabilir.
- Veri Çeşitliliğinin Artırılması: Tezde kullanılan veri setlerinin genişletilmesi, daha fazla gerçek saha verisiyle alışılması önerilmektedir. Özellikle farklı tiplerdeki transformatörlerden elde edilen verilerle algoritmaların eğitilmesi, sonuçların daha geliştirilebilir olmasını sağlayabilir.
- Hızlı ve Düşük Maliyetli Çözümler: Buchholz rölesi ve mevcut koruma sistemlerinin yerine ya da tamamlayıcı olarak daha hızlı, düşük maliyetli ve çevrim içi alışan bir sistem geliştirilmesi teşvik edilebilir. Bu, özellikle küçük ve orta ölçekli transformatörler için ekonomik bir çözüm sağlayabilir.
- Deneysel Testlerin Arttırılması: Simülasyon tabanlı sonuçların gerçek deneysel verilerle daha fazla karşılaştırılması gerekmektedir. Laboratuvar ortamında farklı arıza türlerine yönelik testlerin artırılması ve sonuçların doğruluğunun deneylerle daha sağlam temellere oturtulması, algoritmaların güvenilirliğini artıracaktır.
- Diğer Elektriksel Sistemlere Uygulamalar: Bu tezde geliştirilen yöntemler yalnızca transformatörlerle sınırlı kalmamalıdır. Jeneratörler, elektrik motorları ve enerji depolama sistemleri gibi diğer elektriksel cihazlara da uygulanabilir. Böylece geniş bir arıza tespit ağı oluşturularak, enerji sistemlerinde bütünsel bir izleme ve tespit ağı kurulabilir.
- Yapay Zekâ Tabanlı Otomasyon Sistemleri: Gelecekte, yapay zekâ tabanlı bu tespit sistemlerinin, transformatörlerin bakım ve yönetim süreçlerini otomatikleştiren akıllı sistemlere dönüştürülmesi önerilebilir. Proaktif bakım sistemleri sayesinde, arızalar meydana gelmeden önce bile risk faktörleri izlenip, gerekli önlemler alınabilir.

KAYNAKLAR

- Abbasi, A. R.** (2022). Fault detection and diagnosis in power transformers: a comprehensive review and classification of publications and methods. *Electric Power Systems Research*, 209, 107990. <https://doi.org/10.1016/J.EPSR.2022.107990>
- Abu-Siada, A., ve Hmood, S.** (2015). A new fuzzy logic approach to identify power transformer criticality using dissolved gas-in-oil analysis. *International Journal of Electrical Power & Energy Systems*, 67, 401–408. <https://doi.org/10.1016/J.IJEPES.2014.12.017>
- Abu-Siada, A., ve Islam, S.** (2012). A new approach to identify power transformer criticality and asset management decision based on dissolved gas-in-oil analysis. *IEEE Transactions on Dielectrics and Electrical Insulation*, 19(3), 1007–1012. <https://doi.org/10.1109/TDEI.2012.6215106>
- Aggarwal, C. C., ve Reddy, C. K.** (2014). *Data Clustering: Algorithms and Applications*. CNC Press. <https://doi.org/10.1201/9781315373515-1>
- Ahmed, M. R., Geliel, M. A., ve Khalil, A.** (2013). Power transformer fault diagnosis using fuzzy logic technique based on dissolved gas analysis. *2013 21st Mediterranean Conference on Control and Automation, MED 2013 - Conference Proceedings*, 584–589. <https://doi.org/10.1109/MED.2013.6608781>
- Akhmetov, Y., Nurmanova, V., Bagheri, M., Zollanvari, A., ve Gharehpetian, G. B.** (2021). A New Diagnostic Technique for Reliable Decision-Making on Transformer FRA Data in Interturn Short-Circuit Condition. *IEEE Transactions on Industrial Informatics*, 17(5), 3020–3031. <https://doi.org/10.1109/TII.2020.3007607>
- Akmaz, D.** (2017). İletim Hatlarında Arıza Yeri ve Türünün Geçici Rejim Sinyalleri ve Makine Öğrenme Algoritmaları ile Belirlenmesi (Doktora Tezi). İçinde *Fen Bilimleri Enstitüsü*. İnönü Üniversitesi.
- Albadi, M. H.** (2016). Impact of Harmonic Resonance and V-THD in Sohar Industrial Port–C Substation. *International Journal of Electrical, Computer, Energetic, Electronic and Communication Engineering*, Vol.10, No.2, 2016. <https://squ.elsevierpure.com/en/publications/impact-of-harmonic-resonance-and-v-thd-in-sohar-industrial-portc->
- Alfeilat, H. A. A., Hassanat, A. B. A., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., Salman, H. S. E., ve Surya, V. B.** (2019). Effects of Distance Measure Choice on K-Nearest Neighbor Classifier Performance: A Review. *Big Data*, 7(4), 13–30. <https://doi.org/10.5121/iju.2012.3202>
- Alpsalaz, F., ve Mamiş, M. S.** (2023). Using Ansys 3D Electromagnetic Analysis for Investigation the Effect of Harmonics on Power Transformers. *Sivas Cumhuriyet Üniversitesi Mühendislik Fakültesi Dergisi*, 1(2), 89–93. <https://dergipark.org.tr/en/pub/cumfad/issue/82420/1378805>
- Alpsalaz, F., ve Mamiş, M. S.** (2024). Detection of Arc Faults in Transformer Windings via Transient Signal Analysis. *Applied Sciences 2024*, Vol. 14, Page 9335, 14(20), 9335. <https://doi.org/10.3390/APP14209335>

- Alpsalaz, F., Mamiş, M. S., ve Mamiş, A.** (2022a). Güç Transformatörünün Kısa Devre Durumundaki Elektromanyetik Kuvvetlerin 3D Analizi. *Güç sistemleri Konferansı III*. <https://doi.org/10.5281/zenodo.7267724>
- Alpsalaz, F., Mamiş, M. S., ve Mamiş, A.** (2022b). Harmonikli Sistemin Güç Transformatörü Üzerindeki Etkisinin İncelenmesi. *Güç sistemleri Konferansı III*. <https://doi.org/10.5281/zenodo.7267706>
- Alpsalaz, F., Yalçınöz, Z., Kaygusuz, A., ve Mamiş, M. S.** (2024). Fault Location Prediction in Power Transmission Lines Using an Artificial Neural Network Model. *2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1–6. <https://doi.org/10.1109/IDAP64064.2024.10710637>
- Athikessavan, S. C., Jeyasankar, E., Manohar, S. S., ve Panda, S. K.** (2019). Inter-Turn Fault Detection of Dry-Type Transformers Using Core-Leakage Fluxes. *IEEE Transactions on Power Delivery*, 34(4), 1230–1241. <https://doi.org/10.1109/TPWRD.2018.2878460>
- Bandaru, R. K., Kumar, A. H. V., ve Gaddala, R. K.** (2022). Assessment of 765/400 kV, 500 MVA, Inter-Connecting Transformer Using DGA Alanysis After Feeding High Through Fault Current. *Proceedings of 2022 6th International Conference on Condition Assessment Techniques in Electrical Systems, CATCON 2022*, 67–71. <https://doi.org/10.1109/CATCON56237.2022.10077649>
- Behjat, V., ve Vahedi, A.** (2011). Numerical modelling of transformers interturn faults and characterising the faulty transformer behaviour under various faults and operating conditions. *IET Electric Power Applications*, 5(5), 415–431. <https://doi.org/10.1049/IET-EPA.2010.0095/CITE/REFWORKS>
- Behkam, R., Karami, H., Salay Naderi, M., ve B. Gharehpetian, G.** (2022). Generalized regression neural network application for fault type detection in distribution transformer windings considering statistical indices. *COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, 41(1), 381–409. <https://doi.org/10.1108/COMPEL-06-2021-0199/FULL/PDF>
- Bishop, C. M.** (2006). *Pattern Recognition and Machine Learning* (1. baskı). Springer.
- Bjelić, M., Brković, B., Žarković, M., ve Miljković, T.** (2022). Fault detection in a power transformer based on reverberation time. *International Journal of Electrical Power & Energy Systems*, 137, 107825. <https://doi.org/10.1016/J.IJEPES.2021.107825>
- Bjelić, M., Brković, B., Žarković, M., ve 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>
- Blackburn, J. L., ve Domin, T. J.** (2006). *Protective Relaying: Principles and Applications* (3. baskı, Sayı 0). CNC Press. <https://doi.org/10.1201/9781420017847>
- Bustamante, S., Manana, M., Arroyo, A., Castro, P., Laso, A., ve Martinez, R.** (2019). Dissolved Gas Analysis Equipment for Online Monitoring of Transformer

- Oil: A Review. *Sensors* 2019, Vol. 19, Page 4057, 19(19), 4057. <https://doi.org/10.3390/S19194057>
- Chen, Z., Wang, X., ve Li, Y.** (2016). Analysis of Electric Arc Dynamics in Power Transformers. *IEEE Transactions on Power Delivery*, 31(1), 123–130.
- Christopoulos, C., ve Wright, A.** (1999). *Electrical power system protection* (2. baskı). Springer Science & Business Media.
- CIGRÉ.** (2013). *Guide for Transformer Fire Safety Practices*.
- Cooley, J. W., ve Tukey, J. W.** (1965). An Algorithm for the Machine Calculation of Complex Fourier Series. *Mathematics of Computation*, 19(90), 297. <https://doi.org/10.2307/2003354>
- Duan, L., Hu, J., Zhao, G., Chen, K., Wang, S. X., ve He, J.** (2019). Method of inter-turn fault detection for next-generation smart transformers based on deep learning algorithm. *High Voltage*, 4(4), 282–291. <https://doi.org/10.1049/HVE.2019.0067>
- Ediriweera, E. G. P., Wickramasinghe, K., Sithmini, K. R. I., Ekanayaka, E. A. A. G., Samarasinghe, R., ve Lucas, J. R.** (2020). Localizing hotspot in an oil immersed distribution transformer using finite element analysis. *2020 IEEE Electric Power and Energy Conference, EPEC 2020*. <https://doi.org/10.1109/EPEC48502.2020.9320046>
- Ehsanifar, A., Allahbakhshi, M., Tajdinian, M., Dehghani, M., Montazeri, Z., Malik, O. P., ve Guerrero, J. M.** (2021). Transformer inter-turn winding fault detection based on no-load active power loss and reactive power. *International Journal of Electrical Power & Energy Systems*, 130, 107034. <https://doi.org/10.1016/J.IJEPES.2021.107034>
- Eissa, M. M.** (2005). A novel digital directional transformer protection technique based on wavelet packet. *IEEE Transactions on Power Delivery*, 20(3), 1830–1836. <https://doi.org/10.1109/TPWRD.2005.848646>
- Ester, M., Kriegel, H.-P., Sander, J., ve Xu, X.** (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. *KDD-96 Proceedings*, 96(34), 226–231. <https://doi.org/10.1016/B978-0-444-64165-6.03005-6>
- Faizol, Z., Zubir, F., Saman, N. M., Ahmad, M. H., Rahim, M. K. A., Ayop, O., Jusoh, M., Majid, H. A., ve Yusoff, Z.** (2023). Detection Method of Partial Discharge on Transformer and Gas-Insulated Switchgear: A Review. *Applied Sciences* 2023, Vol. 13, Page 9605, 13(17), 9605. <https://doi.org/10.3390/APP13179605>
- Fan, R., Meliopoulos, A. P. S., Sun, L., Tan, Z., ve Liu, Y.** (2016, Kasım 17). Transformer inter-turn faults detection by dynamic state estimation method. *NAPS 2016 - 48th North American Power Symposium, Proceedings*. <https://doi.org/10.1109/NAPS.2016.7747999>
- Faraday, M.** (1831). On the Induction of Electric Currents. *Philosophical Transactions of the Royal Society*.
- Farzin, N., Vakilian, M., ve Hajipour, E.** (2019). Transformer Turn-to-Turn Fault Protection Based on Fault-Related Incremental Currents. *IEEE Transactions on Power Delivery*, 34(2), 700–709. <https://doi.org/10.1109/TPWRD>

- Floyd, T. L.** (2009). *Principles of Electric Circuits* (9. baskı). Pearson.
- Frimpong, E. A., Bright, T., Kojo, B., ve Michael, T. A.** (2020, Ağustos 1). Inter-Turn Fault Detection Using Wavelet Analysis and Adaptive Neuro- Fuzzy Inference System. *2020 IEEE PES/IAS PowerAfrica, PowerAfrica 2020*. <https://doi.org/10.1109/POWERAFRICA49420.2020.9219856>
- Gaulard, L., ve Gibbs, J. D.** (1882). *Improvements in the Transmission of Electrical Energy*.
- Gedney, S.** (2003). The finite element method in electromagnetics [Book Review]. İçinde *IEEE Antennas and Propagation Magazine* (3. baskı, C. 36, Sayı 3). Wiley-IEEE Press. <https://doi.org/10.1109/map.1994.1068064>
- Gémez, N. A., Wilhelm, H. M., Santos, C. C., ve Stocco, G. B.** (2014). Dissolved gas analysis (DGA) of natural ester insulating fluids with different chemical compositions. *IEEE Transactions on Dielectrics and Electrical Insulation*, 21(3), 1071–1078. <https://doi.org/10.1109/TDEI.2014.6832250>
- Goodfellow Ian, Bengio, Y., ve Courville, A.** (2016). *Deep Learning* (36. baskı). MIT press.
- Granados-Lieberman, D., Razo-Hernandez, J. R., Venegas-Rebollar, V., Olivares-Galvan, J. C., ve Valtierra-Rodriguez, M.** (2021). Harmonic PMU and Fuzzy Logic for Online Detection of Short-Circuited Turns in Transformers. *Electric Power Systems Research*, 190, 106862. <https://doi.org/10.1016/J.EPSR.2020.106862>
- Guzmán, A., Fischer, N., ve Labuschagne, C.** (2009). Improvements in transformer protection and control. *2009 62nd Annual Conference for Protective Relay Engineers*, 563–579. <https://doi.org/10.1109/CPRE.2009.4982542>
- Haema, J., ve Phadungthin, R.** (2013). A prediction technique of power transformer condition assessment via DGA parameters. *Asia-Pacific Power and Energy Engineering Conference, APPEEC*. <https://doi.org/10.1109/APPEEC.2013.6837171>
- Haghjoo, F., ve Mostafaei, M.** (2016). Flux-based method to diagnose and identify the location of turn-to-turn faults in transformers. *IET Generation, Transmission & Distribution*, 10(4), 1083–1091. <https://doi.org/10.1049/IET-GTD.2015.1180>
- Hajiaghahi, S., Hosseini Ahmadi, M. M., Goleij, P., ve Salemnia, A.** (2021). Transformer inter-turn failure detection based on leakage flux and vibration analysis. *IET Electric Power Applications*, 15(8), 998–1012. <https://doi.org/10.1049/ELP2.12076>
- Hammond, D. N. A., Frimpong, E. A., ve Ohene, J. Y.** (2020, Ağustos 1). Detection of Inter-Turn Faults in Transformers Using Continuous Wavelet Transform and Convolutional Neural Network. *2020 IEEE PES/IAS PowerAfrica, PowerAfrica 2020*. <https://doi.org/10.1109/POWERAFRICA49420.2020.9219917>
- Han, M., Zhu, M., Gu, Z., Zhang, Q., Zhao, R., ve Liu, H.** (2024). Investigating Pressure Patterns in Transformer Tanks after an Interturn Short Circuit: A Finite Element Approach. *Energies* 2024, Vol. 17, Page 564, 17(3), 564.

<https://doi.org/10.3390/EN17030564>

- Hastie, T., Friedman, J., ve Tibshirani, R.** (2009). *The elements of statistical learning: data mining, inference, and prediction* (3. baskı). Springer.
- Holdyk, A., Gustavsen, B., Arana, I., ve Holboell, J.** (2014). Wideband modeling of power transformers using commercial sFRA equipment. *IEEE Transactions on Power Delivery*, 29(3), 1446–1453. <https://doi.org/10.1109/TPWRD.2014.2303174>
- Hurley, W. G., ve Wölflé, W. H.** (2013). *Transformers and inductors for power electronics: theory, design and applications* (2. baskı). Wiley.
- IEC 60599.** (2022). Mineral oil-filled electrical equipment in service - Guidance on the interpretation of dissolved and free gases analysis
- Ignatenko, V., Surkov, A., ve Koltcov, S.** (2024). Random forests with parametric entropy-based information gains for classification and regression problems. *PeerJ Computer Science*, 10, e1775. <https://doi.org/10.7717/PEERJ-CS.1775>
- Iskender, I., ve Mamizadeh, A.** (2011). An improved nonlinear thermal model for MV/LV prefabricated oil-immersed power transformer substations. *Electrical Engineering*, 93(1), 9–22. <https://doi.org/10.1007/S00202-010-0186-Y/METRICS>
- Ivanchenko, D. I., ve Aleksey, B. A.** (2018). Transformer fault analysis using instantaneous symmetrical components. *Proceedings of the 2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering, ElConRus 2018*, 2018-January, 641–644. <https://doi.org/10.1109/EICONRUS.2018.8317178>
- James, G., Witten, D., Hastie, T., ve Tibshirani, R.** (2021). *An Introduction to Statistical Learning* (2. baskı). Springer. <https://doi.org/https://doi.org/10.1007/978-1-0716-1418-1>
- Jiles, D.** (2015). *Introduction to Magnetism and Magnetic Materials* (3. baskı). CRC Press. <https://doi.org/https://doi.org/10.1201/b18948>
- Kazemi, Z., Naseri, F., Yazdi, M., ve Farjah, E.** (2021). An EKF-SVM machine learning-based approach for fault detection and classification in three-phase power transformers. *IET Science, Measurement & Technology*, 15(2), 130–142. <https://doi.org/10.1049/SMT2.12015>
- Khalili Senobari, R., Sadeh, J., ve Borsi, H.** (2018). Frequency response analysis (FRA) of transformers as a tool for fault detection and location: A review. *Electric Power Systems Research*, 155, 172–183. <https://doi.org/10.1016/J.EPSR.2017.10.014>
- Kulkarni, S. V., ve Khaparde, S. A.** (2013). *Transformer Engineering: Design, Technology, and Diagnostics* (3. baskı). CRC Press. <https://doi.org/https://doi.org/10.1201/b13011>
- Kumar, A., Bhalja, B. R., ve Kumbhar, G. B.** (2022). Approach for Identification of Inter-Turn Fault Location in Transformer Windings Using Sweep Frequency Response Analysis. *IEEE Transactions on Power Delivery*, 37(3), 1539–1548. <https://doi.org/10.1109/TPWRD.2021.3092397>
- Lan, S., Huang, M., Zhang, Y., ve Yuan, Y.** (2019). Experimental study of oil-paper

- insulation under combined thermal stress and corona discharge. *IEEE Transactions on Dielectrics and Electrical Insulation*, 26(3), 1001–1008. <https://doi.org/10.1109/TDEI.2019.007699>
- Leal, G., Meira, M., Bossio, G., Álvarez, R., ve Verucchi, C.** (2020, Aralık 1). Detection of inter-turn short circuits in power transformers windings: State of the art. *2020 IEEE Congreso Bienal de Argentina, ARGENCON 2020 - 2020 IEEE Biennial Congress of Argentina, ARGENCON 2020*. <https://doi.org/10.1109/ARGENCON49523.2020.9505462>
- Leo Breiman.** (2001). Machine Learning. İçinde R. E. Schapire (Ed.), *Random Forests* (ss. 5–32). Springer.
- Li, P., ve Guo, P.** (2022). Diagnosis of interturn faults of voltage transformer using excitation current and phase difference. *Engineering Failure Analysis*, 134, 105979. <https://doi.org/10.1016/J.ENGFAILANAL.2021.105979>
- Li, X., Pan, C., Luo, D., ve Sun, Y.** (2020). Series DC Arc Simulation of Photovoltaic System Based on Habedank Model. *Energies 2020, Vol. 13, Page 1416*, 13(6), 1416. <https://doi.org/10.3390/EN13061416>
- Li, X., Wu, H., ve Wu, D.** (2011). DGA interpretation scheme derived from case study. *IEEE Transactions on Power Delivery*, 26(2), 1292–1293. <https://doi.org/10.1109/TPWRD.2010.2091325>
- Liu, S., Liu, Z., ve Mohammed, O. A.** (2007). FE-based modeling of single-phase distribution transformers with winding short circuit faults. *IEEE Transactions on Magnetics*, 43(4), 1841–1844. <https://doi.org/10.1109/TMAG.2006.892302>
- Lu, Y., Ye, T., ve Zheng, J.** (2022). Decision Tree Algorithm in Machine Learning. *2022 IEEE International Conference on Advances in Electrical Engineering and Computer Applications, AEECA 2022*, 1014–1017. <https://doi.org/10.1109/AEECA55500.2022.9918857>
- Luque, A., Carrasco, A., Martín, A., ve de las Heras, A.** (2019). The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91, 216–231. <https://doi.org/10.1016/J.PATCOG.2019.02.023>
- Ma, G. M., Li, C. R., Mu, R. D., Jiang, J., ve Luo, Y. T.** (2014). Fiber bragg grating sensor for hydrogen detection in power transformers. *IEEE Transactions on Dielectrics and Electrical Insulation*, 21(1), 380–385. <https://doi.org/10.1109/TDEI.2013.004381>
- Ma, Z., Zhang, H., ve Liu, J.** (2023). MM-RNN: A Multimodal RNN for Precipitation Nowcasting. *IEEE Transactions on Geoscience and Remote Sensing*, 61. <https://doi.org/10.1109/TGRS.2023.3264545>
- MacQueen, J.** (1967). *Some methods for classification and analysis of multivariate observations* (1 (Ed.); ss. 281–297). In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*.
- Martin, D., Lelekakis, N., Wijaya, J., Duval, M., ve Saha, T.** (2014). Investigations into the stray gassing of oils in the fault diagnosis of transformers. *IEEE Transactions on Power Delivery*, 29(5), 2369–2374. <https://doi.org/10.1109/TPWRD.2014.2316501>

- Medeiros, R. P., Aires, M. N. O., Franca, R. L. S., ve Costa, F. B.** (2020, Kasım 12). Performance Assessment of a Wavelet-Based Differential Protection scheme in the Inter-Turn Fault Detection in a Transformer. *2020 Workshop on Communication Networks and Power Systems, WCNPS 2020*. <https://doi.org/10.1109/WCNPS50723.2020.9263743>
- Mehta, A., Sharma, R. N., ve Chauhan, S.** (2011). Partial discharge study by monitoring key gases of power transformers. *ICECT 2011 - 2011 3rd International Conference on Electronics Computer Technology*, 4, 183–186. <https://doi.org/10.1109/ICECTECH.2011.5941883>
- Meira, M., Ruschetti, C. R., Álvarez, R. E., ve Verucchi, C. J.** (2018). Power transformers monitoring based on electrical measurements: state of the art. *IET Generation, Transmission & Distribution*, 12(12), 2805–2815. <https://doi.org/10.1049/IET-GTD.2017.2086>
- Mirzaei, H. R., Akbari, A., Gockenbach, E., Zanjani, M., ve Miralikhani, K.** (2013). A novel method for ultra-high-frequency partial discharge localization in power transformers using the particle swarm optimization algorithm. *IEEE Electrical Insulation Magazine*, 29(2), 26–39. <https://doi.org/10.1109/MEI.2013.6457597>
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., ve Hassabis, D.** (2015). Human-level control through deep reinforcement learning. *Nature* 2015 518:7540, 518(7540), 529–533. <https://doi.org/10.1038/nature14236>
- Moradzadeh, A., Moayyed, H., Mohammadi-Ivatloo, B., Gharehpetian, G. B., ve Aguiar, A. P.** (2022). Turn-to-Turn Short Circuit Fault Localization in Transformer Winding via Image Processing and Deep Learning Method. *IEEE Transactions on Industrial Informatics*, 18(7), 4417–4426. <https://doi.org/10.1109/TII.2021.3105932>
- Moradzadeh, A., ve Pourhossein, K.** (2019). Early Detection of Turn-to-Turn Faults in Power Transformer Winding: An Experimental Study. *Proceedings 2019 International Aegean Conference on Electrical Machines and Power Electronics, ACEMP 2019 and 2019 International Conference on Optimization of Electrical and Electronic Equipment, OPTIM 2019*, 199–204. <https://doi.org/10.1109/ACEMP-OPTIM44294.2019.9007169>
- Moradzadeh, A., Pourhossein, K., Mohammadi-Ivatloo, B., ve Mohammadi, F.** (2021). Locating Inter-Turn Faults in Transformer Windings Using Isometric Feature Mapping of Frequency Response Traces. *IEEE Transactions on Industrial Informatics*, 17(10), 6962–6970. <https://doi.org/10.1109/TII.2020.3016966>
- Muraleedharan, R., Joseph, J., ve Varghese, A. S.** (2019). An FEM Based Approach for Detection of Short Circuit Faults in Transformer Windings by Magnetic Field Measurement. *Proceedings of the 3rd International Conference on Electronics and Communication and Aerospace Technology, ICECA 2019*, 1024–1028. <https://doi.org/10.1109/ICECA.2019.8822088>
- Murtagh, F., ve Contreras, P.** (2012). Algorithms for hierarchical clustering: an overview. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*,

- Mutha, S., ve Saratkar, A.** (2020, Eylül 25). Online Detection and Correction of Inter Turn Faults in Transformers. *Proceedings of 2020 IEEE 1st International Conference on Smart Technologies for Power, Energy and Control, STPEC 2020*. <https://doi.org/10.1109/STPEC49749.2020.9297731>
- Nicolae, P. M., Constantin, D., ve Nitu, M. C.** (2013). 2D electromagnetic transient and thermal modeling of a three phase power transformer. *IYCE 2013 - 4th International Youth Conference on Energy*. <https://doi.org/10.1109/IYCE.2013.6604148>
- Obulareddy, S., ve Munagala, S. K.** (2021). Application of Machine learning algorithms for Power transformer Internal faults identification. *2021 7th International Conference on Advanced Computing and Communication Systems, ICACCS 2021*, 331–335. <https://doi.org/10.1109/ICACCS51430.2021.9441719>
- Oliveira, L. ., Cardoso, A. J. M., ve Cruz, S. M. A.** (2011). Power transformers winding fault diagnosis by the on-load exciting current Extended Park's Vector Approach. *Electric Power Systems Research*, 81(6), 1206–1214. <https://doi.org/10.1016/J.EPSR.2011.01.009>
- Oliveira, L., ve Cardoso, A. J. M.** (2010). A permeance-based transformer model and its application to winding interturn arcing fault studies. *IEEE Transactions on Power Delivery*, 25(3), 1589–1598. <https://doi.org/10.1109/TPWRD.2009.2039149>
- Oliveira, L., ve Cardoso, A. J. M.** (2012). Application of Park's power components to the differential protection of three-phase transformers. *Electric Power Systems Research*, 83(1), 203–211. <https://doi.org/10.1016/j.epsr.2011.11.004>
- Özbilgin, F.** (2023). *İris görüntüleri kullanılarak makine öğrenmesi ile koroner arter hastalığının tespiti*. Samsun Ondokuz Mayıs Üniversitesi.
- Öztürk, C. E., Yilmaz, E. H., ve Köksal, Ö.** (2023). Transformer-Based Bug/Feature Classification. *31st IEEE Conference on Signal Processing and Communications Applications, SIU 2023*. <https://doi.org/10.1109/SIU59756.2023.10223806>
- Parizad, A., Baghaee, H. R., Tavakoli, A., ve Jamali, S.** (2009). Optimization of arc models parameter using genetic algorithm. *2009 International Conference on Electric Power and Energy Conversion Systems, (EPECS)*, 1–7.
- Rawat, R., Chakrawarti, R. K., Raj, A. S. A., Mani, G., Chidambarathanu, K., ve Bhardwaj, R.** (2023). Association rule learning for threat analysis using traffic analysis and packet filtering approach. *International Journal of Information Technology (Singapore)*, 15(6), 3245–3255. <https://doi.org/10.1007/S41870-023-01353-0/TABLES/7>
- Santamaria-Bonfil, G., Arroyo-Figueroa, G., Zuniga-Garcia, M. A., Azcarraga Ramos, C. G., ve Bassam, A.** (2023). Power Transformer Fault Detection: A Comparison of Standard Machine Learning and autoML Approaches. *Energies* 2024, Vol. 17, Page 77, 17(1), 77. <https://doi.org/10.3390/EN17010077>
- Saribulut, L., Teke, A., ve Tümay, M.** (2013). Fundamentals and literature review of Fourier transform in power quality issues. *Journal of Electrical and*

- Schmidhuber, J.** (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/J.NEUNET.2014.09.003>
- Sheryar, M., Ali, M. A., Umer, F., Rashid, Z., Amjad, M., Haider, Z. M., ve Khan, M. O.** (2022). An Approach to Performing Stability Analysis for Power Transformer Differential Protection: A Case Study. *Energies* 2022, Vol. 15, Page 9603, 15(24), 9603. <https://doi.org/10.3390/EN15249603>
- Smeets, R. P. P., ve Kertész, V.** (2000). Evaluation of high-voltage circuit breaker performance with a validated arc model. *IEE Proceedings: Generation, Transmission and Distribution*, 147(2), 121–125. <https://doi.org/10.1049/IP-GTD:20000238>
- Smith, J.** (2010). *Fundamentals of Magnetism* (3. baskı). McGraw-Hil.
- Sun, H. C., Huang, Y. C., ve Huang, C. M.** (2012). A Review of Dissolved Gas Analysis in Power Transformers. *Energy Procedia*, 14, 1220–1225. <https://doi.org/10.1016/J.EGYPRO.2011.12.1079>
- Suthaharan, S., ve Suthaharan, S.** (2016). Support Vector Machine. İçinde 1 (Ed.), *Machine Learning Models and Algorithms for Big Data Classification* (1. baskı, ss. 207–235).
- Sutton, R. S., ve Barto, A. G.** (2018). *Reinforcement learning: An introduction*. MIT press.
- Taha Jijo, B., ve Mohsin Abdulazeez, A.** (2021). Classification Based on Decision Tree Algorithm for Machine Learning. *Journal of Applied Science and Technology Trends*, 2(01), 20–28. <https://doi.org/10.38094/jastt20165>
- Terzija, V. V., Ćirić, R., ve Nouri, H.** (2011). Improved fault analysis method based on a new arc resistance formula. *IEEE Transactions on Power Delivery*, 26(1), 120–126. <https://doi.org/10.1109/TPWRD.2010.2076369>
- Terzija, V. V., ve Koglin, H. J.** (2004). On the modeling of long arc in still air and arc resistance calculation. *IEEE Transactions on Power Delivery*, 19(3), 1012–1017. <https://doi.org/10.1109/TPWRD.2004.829912>
- Tesla, N.** (1888). *Alternating Current Electro Magnetic Motor*. US Patent.
- Thiviyanathan, V. A., Ker, P. J., Leong, Y. S., Abdullah, F., Ismail, A., ve Zaini Jamaludin, M.** (2022). Power transformer insulation system: A review on the reactions, fault detection, challenges and future prospects. *Alexandria Engineering Journal*, 61(10), 7697–7713. <https://doi.org/10.1016/J.AEJ.2022.01.026>
- Thomas, J. B., Chaudhari, S. G., Shihabudheen, K. V., ve Verma, N. K.** (2023). CNN-Based Transformer Model for Fault Detection in Power System Networks. *IEEE Transactions on Instrumentation and Measurement*, 72. <https://doi.org/10.1109/TIM.2023.3238059>
- Tightiz, L., Nasab, M. A., Yang, H., ve Addeh, A.** (2020). An intelligent system based on optimized ANFIS and association rules for power transformer fault diagnosis. *ISA Transactions*, 103, 63–74. <https://doi.org/10.1016/J.ISATRA.2020.03.022>
- Tripathy, M., Maheshwari, R. P., ve Verma, H. K.** (2007). Probabilistic neural-network-

- based protection of power transformer. *IET Electric Power Applications*, 1(5), 793–798. <https://doi.org/10.1049/IET-EPA:20070009>
- Wang, Z., ve Sharma, A.** (2021). Research on transformer vibration monitoring and diagnosis based on Internet of things. *Journal of Intelligent Systems*, 30(1), 677–688. <https://doi.org/10.1515/JISYS-2020-0111/MACHINEREADABLECITATION/RIS>
- Westinghouse, G.** (1886). *System of Electrical Distribution*. US Patent.
- Xian, R., Wang, L., Zhang, B., Li, J., Xian, R., ve Li, J.** (2024). Identification Method of Interturn Short Circuit Fault for Distribution Transformer Based on Power Loss Variation. *IEEE Transactions on Industrial Informatics*, 20(2), 2444–2454. <https://doi.org/10.1109/TII.2023.3292972>
- Yan, C., Liu, S., Zhang, P., ve Xu, Y.** (2022). Finite Element Modeling and DWT Analysis of Power Transformer Interturn Faults. *CEFC 2022 - 20th Biennial IEEE Conference on Electromagnetic Field Computation, Proceedings*. <https://doi.org/10.1109/CEFC55061.2022.9940862>
- Yang, F., Tang, Z., Shen, Y., Su, L., ve Yang, Z.** (2022). Parameter Determination Method of Cassie-Mayr Hybrid Arc Model Based on Magnetohydrodynamics Plasma Theory. *Frontiers in Energy Research*, 10, 808289. <https://doi.org/10.3389/FENRG.2022.808289/BIBTEX>
- Yoon, Y., Son, Y., Cho, J., Jang, S., Kim, Y. G., ve Choi, S.** (2021). High-Frequency Modeling of a Three-Winding Power Transformer Using Sweep Frequency Response Analysis. *Energies* 2021, Vol. 14, Page 4009, 14(13), 4009. <https://doi.org/10.3390/EN14134009>
- Yuan, L., Sun, L., Wu, H., Yuan, L., Sun, L., ve Wu, H.** (2013). Simulation of Fault Arc Using Conventional Arc Models. *Energy and Power Engineering*, 5(4), 833–837. <https://doi.org/10.4236/EPE.2013.54B160>
- Zacharias, D., ve Gokaraju, R.** (2016). Prototype of a Negative-Sequence Turn-to-Turn Fault Detection Scheme for Transformers. *IEEE Transactions on Power Delivery*, 31(1), 122–129. <https://doi.org/10.1109/TPWRD.2015.2483524>
- Zhang, C., He, Y., Du, B., Yuan, L., Li, B., ve Jiang, S.** (2020). Transformer fault diagnosis method using IoT based monitoring system and ensemble machine learning. *Future Generation Computer Systems*, 108, 533–545. <https://doi.org/10.1016/J.FUTURE.2020.03.008>
- Zhang, Z., Chen, W., Li, Z., Du, L., Jiang, T., Cai, N., Song, R., Li, M., Wang, J., ve Wang, Z.** (2023). Experimental study on the transition process from partial discharge to arc discharge of oil–paper insulation based on fibre-optic sensors. *IET Generation, Transmission & Distribution*, 17(2), 461–468. <https://doi.org/10.1049/GTD2.12689>
- Zhao, X., Yao, C., Zhou, Z., Li, C., Wang, X., Zhu, T., ve Abu-Siada, A.** (2020). Experimental Evaluation of Transformer Internal Fault Detection Based on V-I Characteristics. *IEEE Transactions on Industrial Electronics*, 67(5), 4108–4119. <https://doi.org/10.1109/TIE.2019.2917368>
- Zhao, Z., Tang, C., Yao, C., Zhou, Q., Xu, L., Gui, Y., ve Islam, S.** (2018). Improved Method to Obtain the Online Impulse Frequency Response Signature of a Power Transformer by Multi Scale Complex CWT. *IEEE Access*, 6, 48934–

48945. <https://doi.org/10.1109/ACCESS.2018.2868058>

Zhou, Z.-H. (2021). Ensemble Learning. İçinde *Machine Learning* (1. baskı, C. 1, ss. 181–210). Springer, Singapore. https://doi.org/10.1007/978-981-15-1967-3_8

Zhu, N., Li, J., Shao, L., Liu, H., Ren, L., ve Zhu, L. (2023). Analysis of Interturn Faults on Transformer Based on Electromagnetic-Mechanical Coupling. *Energies* 2023, Vol. 16, Page 512, 16(1), 512. <https://doi.org/10.3390/EN16010512>



EKLER

EK A: Simulink Ark modeli Kodu

EK B: FFT Kodu

EK C: Sargı Tahmin MÖ Kodu

EK D: Diskno Tahmin MÖ Kodu

EK E: MÖ Metrik Kodu

EK F: Filtreleme Kodu

EK A

```
component IdealArc
nodes
p = foundation.electrical.electrical; % +:top
n = foundation.electrical.electrical; % -:bottom
end
inputs
a = {3000 , 'V' }; % PS:bottom
end
parameters
b = { 2, '1' }; % Material Coefficient B
Rc = { 400, 'Ohm' }; % Resistance Rc
TauV = { 0.0001, 's' }; % Arc time constant for V
TauI = { 0.0001, 's' }; % Arc time constant for I
end
variables
i = { 0.001, 'A' }; % Current
v = { 0.001, 'V' }; % Voltage
it = { 0.001, 'A' }; % Polarization Current
end
function setup
%Initial conditions
v={ 0.0, 'V' };
i={ 0.0, 'A' };
it={ 0.0, 'A' };
end
branches
i : p.i -> n.i; % Through variable i from node p to node n
end
equations
v == p.v-n.v;
it == i + TauI*i.der;
v + TauV*v.der == a*Rc*(it)/(Rc*(it)*atan(b*(it)*{1, '1/A'})+a);
end
end
```

EK B

```
clear all;
close all;
filteringoption=1;
disp(' ')
disp('input the filename without extension for loading data')
filename=input(['datafilename',' :], 's'); %give
loadfile=[filename, '.m']; %to load data from a file has different
extension
                                %change hear. '.m' or '.dat' etc
eval(['load ', loadfile, ';']); %load data from dat file
fdata=eval(filename); %load data to fdata variable
clear(filename);

row_num=length(fdata(:,1));
column_num=length(fdata(1,:));
XTIME2=fdata(1:row_num,2);
XTIME2=XTIME2;
XRE2=fdata(1:row_num,3);
XRE2=XRE2/sqrt(3);
RI12=fdata(1:row_num,4);
RI12=RI12/sqrt(3);
DT=XTIME2(2)-XTIME2(1);
    y=XRE2;
    plotout(XTIME2,XRE2,RI12)
    [y_f]=filter1(DT,y);
    if filteringoption==0 y_f=y; end
    [y_fft,vf]=fftout2(DT,XTIME2,y_f);
    title('Voltage FFT-real value');
    % detectpeak(DT,y_fnor);
    [maxy,fmax]=dedectpeak4(DT,y_fft);
    disp('Gerilim');
    [y_f2]=filter1(DT,y);
    if filteringoption==0 y_f2=y; end
    [y_fft,ia1]=fftout2(DT,XTIME2,y_f2);
    fsampl=1/DT;
    m_sample=length(XTIME2)-1;
    m_sample_h=round(m_sample/2);
    f = fsampl*(0:m_sample_h)/m_sample;
    for i=1:m_sample_h
        hpower=vf(i)*ia1(i);
    end
    figure
    % plot(f,hpower)%power calculation
    title('Current FFT-real value');
    % detectpeak(DT,y_f2nor);
    [maxy,fmax]=dedectpeak4(DT,y_fft);
    aa=maxy
    bb=fmax;
    disp('Gerilim');
return
```

EK C

```
clc; clear; close all;
load('feyyaz.mat');

trainingData=Training;

inputTable = trainingData;
predictorNames = {'GirisA', 'GirisB', 'GirisC'};
predictors = inputTable(:, predictorNames);
response = inputTable.Sargi;
isCategoricalPredictor = [false, false, false];
classNames = {'AGA'; 'AGB'; 'AGC'; 'YGA'; 'YGB'; 'YGC'};
%Test Dataları
inputTable2 = Testing;
predictorNames = {'GirisA', 'GirisB', 'GirisC'};
predictors2 = inputTable2(:, predictorNames);
response2 = inputTable2.Sargi;
isCategoricalPredictor = [false, false, false];
classNames = {'AGA'; 'AGB'; 'AGC'; 'YGA'; 'YGB'; 'YGC'};

% Modelin Seçilmesi
% knn=1, ann=2, decision tree=3, svm=4, kernel, ensemble=6
ModelNumarasi=6;

if ModelNumarasi == 1

Mdl = fitcknn(...
    predictors, ...
    response, ...
    'Distance', 'Cityblock', ...
    'Exponent', [], ...
    'NumNeighbors', 1, ...
    'DistanceWeight', 'Inverse', ...
    'Standardize', true, ...
    'ClassNames', classNames);

elseif ModelNumarasi == 2

    Mdl = fitcnet(...
        predictors, ...
        response, ...
        'LayerSizes', 295, ...
        'Activations', 'sigmoid', ...
        'Lambda', 5.340808315327571e-07, ...
        'IterationLimit', 1000, ...
        'Standardize', false, ...
        'ClassNames', classNames);

elseif ModelNumarasi == 3

Mdl = fitctree(...
    predictors, ...
    response, ...
    'SplitCriterion', 'gdi', ...
    'MaxNumSplits', 18, ...
    'Surrogate', 'off', ...
    'ClassNames', classNames);
```

```

elseif ModelNumarasi == 4

template = templateSVM(...
    'KernelFunction', 'linear', ...
    'PolynomialOrder', [], ...
    'KernelScale', 1, ...
    'BoxConstraint', 0.5370134619635939, ...
    'Standardize', false);
Mdl = fitcecoc(...
    predictors, ...
    response, ...
    'Learners', template, ...
    'Coding', 'onevsall', ...
    'ClassNames', classNames);

elseif ModelNumarasi == 5

template = templateKernel(...
    'Learner', 'logistic', ...
    'NumExpansionDimensions', 'auto', ...
    'Lambda', 'auto', ...
    'KernelScale', 'auto', ...
    'Standardize', false, ...
    'IterationLimit', 1000);
Mdl = fitcecoc(...
    predictors, ...
    response, ...
    'Learners', template, ...
    'Coding', 'onevsone', ...
    'ClassNames', classNames);

elseif ModelNumarasi == 6

template = templateTree(...
    'MaxNumSplits', 89, ...
    'NumVariablesToSample', 2);
Mdl = fitcensemble(...
    predictors, ...
    response, ...
    'Method', 'Bag', ...
    'NumLearningCycles', 106, ...
    'Learners', template, ...
    'ClassNames', classNames);

end

% Create the result struct with predict function
predictorExtractionFcn = @(x) array2table(x, 'VariableNames', predictorNames);
MdlPredictFcn = @(x) predict(Mdl, x);
trainedModel.predictFcn = @(x) MdlPredictFcn(predictorExtractionFcn(x));
% Add additional fields to the result struct
trainedModel.Mdl = Mdl;
% Perform cross-validation
partitionedModel = crossval(trainedModel.Mdl, 'KFold', 5);

% Compute validation predictions
validationPredictions = kfoldPredict(partitionedModel);

% Eğitim verilerinin tahmini

```

```

[yfit1,scores1] = Mdl.predict(predictors)

% Test verilerinin tahmini
[yfit2,scores2] = Mdl.predict(predictors2)

C1 = confusionmat(response,validationPredictions)
confusionchart(C1)
figure;
C2 = confusionmat(response2,yfit2)
confusionchart(C2)

cp_egitim = classperf(response,validationPredictions);
cp_test = classperf(response2,yfit2);

cp_egitim = classperf(response,validationPredictions);
cp_test = classperf(response2,yfit2);
fprintf('%%%%%%%%%% \n');
fprintf('Eğitim sonuçları \n');
performance_measure(response,validationPredictions);
fprintf('%%%%%%%%%% \n');
fprintf('Test sonuçları \n');
performance_measure(response2,yfit2);

```

EK D

```
clc; clear; close all;
load('feyyaz.mat');

trainingData=Training;

inputTable = trainingData;
predictorNames = {'GirisA', 'GirisB', 'GirisC'};
predictors = inputTable(:, predictorNames);
response = inputTable.DiskNo;
isCategoricalPredictor = [false, false, false];
classNames = {'AGAD1'; 'AGAD10'; 'AGAD11'; 'AGAD2'; 'AGAD3'; 'AGAD4'; 'AGAD5';
'AGAD6'; 'AGAD7'; 'AGAD8'; 'AGAD9'; 'AGBD1'; 'AGBD10'; 'AGBD11'; 'AGBD2';
'AGBD3'; 'AGBD4'; 'AGBD5'; 'AGBD6'; 'AGBD7'; 'AGBD8'; 'AGBD9'; 'AGCD1';
'AGCD10'; 'AGCD11'; 'AGCD2'; 'AGCD3'; 'AGCD4'; 'AGCD5'; 'AGCD6'; 'AGCD7';
'AGCD8'; 'AGCD9'; 'YGAD1'; 'YGAD10'; 'YGAD11'; 'YGAD2'; 'YGAD3'; 'YGAD4';
'YGAD5'; 'YGAD6'; 'YGAD7'; 'YGAD8'; 'YGAD9'; 'YGBD1'; 'YGBD10'; 'YGBD11';
'YGBD2'; 'YGBD3'; 'YGBD4'; 'YGBD5'; 'YGBD6'; 'YGBD7'; 'YGBD8'; 'YGBD9';
'YGCD1'; 'YGCD10'; 'YGCD11'; 'YGCD2'; 'YGCD3'; 'YGCD4'; 'YGCD5'; 'YGCD6';
'YGCD7'; 'YGCD8'; 'YGCD9'};

%Test Dataları
inputTable2 = Testing;
predictorNames = {'GirisA', 'GirisB', 'GirisC'};
predictors2 = inputTable2(:, predictorNames);
response2 = inputTable2.DiskNo;
isCategoricalPredictor = [false, false, false];
classNames = {'AGAD1'; 'AGAD10'; 'AGAD11'; 'AGAD2'; 'AGAD3'; 'AGAD4'; 'AGAD5';
'AGAD6'; 'AGAD7'; 'AGAD8'; 'AGAD9'; 'AGBD1'; 'AGBD10'; 'AGBD11'; 'AGBD2';
'AGBD3'; 'AGBD4'; 'AGBD5'; 'AGBD6'; 'AGBD7'; 'AGBD8'; 'AGBD9'; 'AGCD1';
'AGCD10'; 'AGCD11'; 'AGCD2'; 'AGCD3'; 'AGCD4'; 'AGCD5'; 'AGCD6'; 'AGCD7';
'AGCD8'; 'AGCD9'; 'YGAD1'; 'YGAD10'; 'YGAD11'; 'YGAD2'; 'YGAD3'; 'YGAD4';
'YGAD5'; 'YGAD6'; 'YGAD7'; 'YGAD8'; 'YGAD9'; 'YGBD1'; 'YGBD10'; 'YGBD11';
'YGBD2'; 'YGBD3'; 'YGBD4'; 'YGBD5'; 'YGBD6'; 'YGBD7'; 'YGBD8'; 'YGBD9';
'YGCD1'; 'YGCD10'; 'YGCD11'; 'YGCD2'; 'YGCD3'; 'YGCD4'; 'YGCD5'; 'YGCD6';
'YGCD7'; 'YGCD8'; 'YGCD9'};

% Modelin Seçilmesi
% knn=1, ann=2, decision tree=3, svm=4, kernel=5, ensemble=6
ModelNumarasi=6;

if ModelNumarasi == 1

Mdl = fitcknn(...
predictors, ...
response, ...
'Distance', 'Cosine', ...
'Exponent', [], ...
'NumNeighbors', 15, ...
'DistanceWeight', 'SquaredInverse', ...
'Standardize', true, ...
'ClassNames', classNames);

elseif ModelNumarasi == 2

Mdl = fitcnet(...
predictors, ...
response, ...
```

```

        'LayerSizes', [75 232], ...
        'Activations', 'sigmoid', ...
        'Lambda', 5.591204605610023e-08, ...
        'IterationLimit', 1000, ...
        'Standardize', true, ...
        'ClassNames', classNames);

elseif ModelNumarasi == 3

    Md1 = fitctree(...
        predictors, ...
        response, ...
        'SplitCriterion', 'gdi', ...
        'MaxNumSplits', 101, ...
        'Surrogate', 'off', ...
        'ClassNames', classNames);

elseif ModelNumarasi == 4

    template = templateSVM(...
        'KernelFunction', 'gaussian', ...
        'PolynomialOrder', [], ...
        'KernelScale', 0.09377955945584614, ...
        'BoxConstraint', 840.3062562320941, ...
        'Standardize', true);
    Md1 = fitcecoc(...
        predictors, ...
        response, ...
        'Learners', template, ...
        'Coding', 'onevsall', ...
        'ClassNames', classNames);

elseif ModelNumarasi == 5

    template = templateKernel(...
        'Learner', 'svm', ...
        'NumExpansionDimensions', 'auto', ...
        'Lambda', 'auto', ...
        'KernelScale', 'auto', ...
        'Standardize', false, ...
        'IterationLimit', 1000);
    Md1 = fitcecoc(...
        predictors, ...
        response, ...
        'Learners', template, ...
        'Coding', 'onevsall', ...
        'ClassNames', classNames);

elseif ModelNumarasi == 6

    template = templateTree(...
        'MaxNumSplits', 223, ...
        'NumVariablesToSample', 'all');
    Md1 = fitcensemble(...
        predictors, ...
        response, ...
        'Method', 'RUSBoost', ...
        'NumLearningCycles', 13, ...
        'Learners', template, ...

```

```

    'LearnRate', 0.9611661986521883, ...
    'ClassNames', classNames);

end

% Create the result struct with predict function
predictorExtractionFcn = @(x) array2table(x, 'VariableNames', predictorNames);
MdlPredictFcn = @(x) predict(Mdl, x);
trainedModel.predictFcn = @(x) MdlPredictFcn(predictorExtractionFcn(x));
% Add additional fields to the result struct
trainedModel.Mdl = Mdl;
% Perform cross-validation
partitionedModel = crossval(trainedModel.Mdl, 'KFold', 5);

% Compute validation predictions
validationPredictions = kfoldPredict(partitionedModel);

% Eğitim verilerinin tahmini
[yfit1,scores1] = Mdl.predict(predictors)

% Test verilerinin tahmini
[yfit2,scores2] = Mdl.predict(predictors2)

C1 = confusionmat(response,validationPredictions)
confusionchart(C1)
figure;
C2 = confusionmat(response2,yfit2)
confusionchart(C2)

cp_egitim = classperf(response,validationPredictions);
cp_test = classperf(response2,yfit2);

```

EK E

```
function performance_measure(groundTruth, predictedLabels)

% Gerçek etiketler (GroundTruth)

% Tahmin edilen etiketler (PredictedLabels)

% Confusion matrix (karışıklık matrisi) hesaplama
confMat = confusionmat(groundTruth, predictedLabels);
% figure;
confusionchart(confMat)
% Performans metriklerini hesaplama
numClasses = size(confMat, 1);
TP = diag(confMat); % True Positives
FP = sum(confMat, 1)' - TP; % False Positives
FN = sum(confMat, 2) - TP; % False Negatives
TN = sum(confMat(:)) - (TP + FP + FN); % True Negatives

% Toplam doğru ve yanlış sınıflandırmalar
totalCorrect = sum(TP);
total = sum(confMat(:));
totalIncorrect = total - totalCorrect;

% Doğru sınıflandırma oranı
correctRate = totalCorrect / total;

% Hata oranı
errorRate = totalIncorrect / total;

% Duyarlılık (Sensitivity) ve Özgüllük (Specificity) ve
% Kesinlik(Precision) ve F1score
sensitivity = TP ./ (TP + FN);
recall=sensitivity;
specificity = TN ./ (TN + FP);
precision = TP ./ (TP + FP);

% Pozitif ve Negatif Öngörü Değerleri
PPV = TP ./ (TP + FP); % Positive Predictive Value
NPV = TN ./ (TN + FN); % Negative Predictive Value

% Pozitif ve Negatif Olasılık Oranları
positiveLikelihood = sensitivity ./ (1 - specificity);
negativeLikelihood = (1 - sensitivity) ./ specificity;
% F1soce değeri
f_measure = 2*((precision.*recall)./(precision + recall));

% Prevalans (Hedef sınıf oranı)
prevalence = sum(TP + FN) / total;

% Sonuçları yazdırma
fprintf('Doğru Sınıflandırma Oranı: %.4f\n', correctRate);
fprintf('Hata Oranı: %.4f\n', errorRate);
fprintf('Duyarlılık (Sensitivity): %.4f\n', mean(sensitivity));
fprintf('Özgüllük (Specificity): %.4f\n', mean(specificity));
fprintf('Kesinlik(Precision): %.4f\n', mean(precision));
```

```
fprintf('F1soce değeri: %.4f\n', mean(f_measure));
% fprintf('Pozitif Öngörü Değeri (PPV): %.4f\n', mean(PPV));
% fprintf('Negatif Öngörü Değeri (NPV): %.4f\n', mean(NPV));
% fprintf('Pozitif Olasılık Oranı: %.4f\n', mean(positiveLikelihood));
% fprintf('Negatif Olasılık Oranı: %.4f\n', mean(negativeLikelihood));
% fprintf('Prevalans: %.4f\n', prevalence);

% Tanı tablosunu görüntüleme
%disp('Confusion Matrix:');
%disp(confMat);
```



EKF

```
function [y_f]=filter1(DT,y)
fsamp1=1/DT;
Wp = 2000/(fsamp1/2); %Passband corner frequency
Ws = 500/(fsamp1/2); %Stopband corner frequency
Rp = 3; %Passband ripple, in decibels
Rs = 50; %Stopband attenuation, in decibels.
[n,Wn] = buttord(Wp,Ws,Rp,Rs);
[b,a] = butter(n,Wn,'high');

%fitter the signal
y_f=filter(b, a, y);
end
```



ÖZGEÇMİŞ

Ad-Soyad : Feyyaz ALPSALAZ

ÖĞRENİM DURUMU:

- **Lisans** : 2014, Cumhuriyet Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği
- **Yüksek Lisans** : 2018, Sivas Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Enerji Bilimi ve Teknolojisi
- **Doktora** : 2024, İnönü Üniversite, Fen Bilimleri Enstitüsü, Elektrik Tesisleri Anabilim Dalı

MESLEKİ DENEYİM:

- 2014 – 2016, TEİAŞ 11.Bölge Müdürlüğü Sivas İşletme Müdürlüğü, İşletme mühendisi
- 2016 – Halen, Yozgat Bozok Üniversitesi Akdağmadeni MYO, Öğretim Görevlisi

DOKTORA TEZİNDEN TÜRETİLEN ÇALIŞMALAR

Projelerde Yaptığı Görevler

- Transformatör iç arklarının geçici rejim uç gerilim ve akım sinyalleri ile yapay sinir ağları kullanılarak çevrimiçi erken tespiti. **Proje No: 123E658 (TUBİTAK 1001)**. Bursiyer: Feyyaz ALPSALAZ, Yürütücü: M. Salih MAMİŞ. 01.04.2024- Devam ediyor.

Uluslararası hakemli dergilerde yayımlanan makaleler:

- **Alpsalaz, F., ve Mamiş, M. S. (2024)**. Detection of Arc Faults in Transformer Windings via Transient Signal Analysis. *Applied Sciences*, 14(20), 9335. <https://doi.org/10.3390/APP14209335>.

Ulusal hakemli dergilerde yayımlanan makaleler:

- **Alpsalaz, F., ve Mamiş, M. S. (2023)**. Using Ansys 3D Electromagnetic Analysis for Investigation the Effect of Harmonics on Power Transformers. *Sivas Cumhuriyet Üniversitesi Mühendislik Fakültesi Dergisi*, 1(2), 89–93.

Ulusal/Uluslararası bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler:

- **Alpsalaz, F., Yalçınöz, Z., Kaygusuz, A., ve Mamiş, M. S. (2024).** Fault Location Prediction in Power Transmission Lines Using an Artificial Neural Network Model. 2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP), 1–6. <https://doi.org/10.1109/IDAP64064.2024.10710637>. IEEE
- **Alpsalaz, F., Mamiş, M. S., ve Mamiş, A. (2022).** Güç Transformatörünün Kısa Devre Durumundaki Elektromanyetik Kuvvetlerin 3D Analizi. Güç sistemleri Konferansı III. <https://doi.org/10.5281/zenodo.7267724>
- **Alpsalaz, F., Mamiş, M. S., ve Mamiş, A. (2022).** Harmonikli Sistemin Güç Transformatörü Üzerindeki Etkisinin İncelenmesi. Güç sistemleri Konferansı III. <https://doi.org/10.5281/zenodo.7267706>

