

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTRİK GÜÇ SİSTEMLERİNDE
FERROREZONANS ANALİZİ VE YAPAY ZEKA
TABANLI TESPİTİ**

YÜKSEK LİSANS TEZİ

Fatih SALİHOĞLU

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik Mühendisliği Bilim Dalı

OCAK 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTRİK GÜÇ SİSTEMLERİNDE
FERROREZONANS ANALİZİ VE YAPAY ZEKA
TABANLI TESPİTİ**

YÜKSEK LİSANS TEZİ

Fatih SALİHOĞLU

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik Mühendisliği Bilim Dalı

Tez Danışmanı: Prof. Dr. Yılmaz UYAROĞLU

OCAK 2025

Fatih SALİHOĞLU tarafından hazırlanan “Elektrik Güç Sistemlerinde Ferrerezonans Analizi ve Yapay Zeka Tabanlı Tespiti ” adlı tez çalışması 22.01.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektrik Mühendisliği Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :

Jüri Üyesi :

Jüri Üyesi :



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “Elektrik Güç Sistemlerinde Ferrerezonans Analizi ve Yapay Zeka Tabanlı Tespiti” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, etik kurul onay belgesi aldığımı çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(22/01/2025)

Fatih SALİHOĞLU





Eşime ve çocuklarıma



TEŞEKKÜR

Bu tezin hazırlanması sürecinde destek ve katkılarını esirgemeyen tüm kişi ve kurumlara en içten teşekkürlerimi sunarım.

Öncelikle, tez çalışmamın her aşamasında engin bilgisi, tecrübesi ve rehberliği ile bana yol gösteren, Sakarya Üniversitesi Elektrik Mühendisliği Bölüm Başkanı ve değerli tez danışmanım Prof. Dr. Yılmaz UYAROĞLU' na sonsuz teşekkür ederim. Kendisinin titiz değerlendirmeleri, yapıcı önerileri ve sabrı, bu çalışmanın nitelikli bir şekilde tamamlanmasında büyük rol oynamıştır. Akademik gelişimime sağladığı katkılarının yanı sıra, kişisel gelişimime olan desteği için de minnettarım.

Ayrıca, çalışmam süresince bilgi ve deneyimlerini paylaşarak bana önemli katkılar sağlayan meslektaşım İbrahim İLHAN' a özel olarak teşekkür etmek isterim. Projeye yönelik değerli önerileri ve karşılaştığım sorunlara sunduğu çözüm odaklı yaklaşımları, bu tezin kapsamını ve niteliğini zenginleştirmiştir. Kendisinin destekleyici tutumu ve profesyonel bakış açısı, bu süreci benim için daha verimli hale getirmiştir.

Bu süreçte bana daima moral ve motivasyon kaynağı olan eşime ve çocuklarıma da içten teşekkür ederim. Onların sağladığı manevi destek ve güven, bu zorlu yolculuk boyunca bana güç verdi.

Son olarak, tez çalışmam boyunca doğrudan veya dolaylı olarak emeği geçen tüm öğretim üyelerine, araştırmacılara ve kurumlara teşekkürlerimi sunarım. Sağladıkları bilgi, kaynaklar ve altyapı, bu çalışmanın başarıyla tamamlanmasında önemli bir rol oynamıştır.

Herkes katkılarından ve desteklerinden dolayı bir kez daha gönülden teşekkür ederim.

Fatih SALİHOĞLU



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
KISALTMALAR	xiii
SİMGELER	xv
ŞEKİL LİSTESİ	xvii
1. GİRİŞ	1
1.1. Literatür Taraması	4
1.2. Tezin Amacı	9
2. FERROREZONANS	11
2.1. Ferrorezonans ve Lineer Rezonans Arasındaki Farklılıklar.....	11
2.2. Ferrorezonansın İletim Sistemlerindeki Etkileri	12
2.2.1. Enerji iletim sistemlerinde seri ferrorezonans devreleri	13
2.2.2. Enerji iletim sistemlerinde paralel ferrorezonans devreleri	16
2.2.3. Paralel Ferrorezonansın Akım-Gerilim İlişkisi.....	17
3. GÜÇ SİSTEMLERİ.....	19
3.1. Güç Sistemlerinin Matematiksel Temsili	20
3.2. Enerji İletim Hatları	21
3.2.1. Kısa mesafeli iletim hatları	22
3.2.1.1. Kısa mesafeli hatların elektriksel modeli.....	23
3.2.1.2. Güç akışı ve verimlilik.....	24
3.2.2. Orta mesafeli iletim hatları	24
3.2.2.1. Orta mesafeli hatların elektriksel modeli	25
3.2.2.2. Hat sabitleri ve güç akışı denklemleri	25
3.2.2.3. Orta mesafeli hatlarda kapasitif ve endüktif etkiler	26
3.2.3. Uzun mesafeli iletim hatları	26
3.2.3.1. Uzun mesafeli hatların elektriksel modeli.....	27
3.2.3.2. Uzun hatlarda iletim sabitleri.....	27
3.2.3.3. Güç akışı ve dalga yansıması	28
4. MATERYAL VE YÖNTEM.....	29
4.1. Yapay Zeka	29
4.1.1. Yapay sinir ağları (Artificial Neural Networks - ANN)	30
4.1.2. Aktivasyon fonksiyonları	31
4.1.2.1. Sigmoid	31
4.1.2.2. Tanh (Hiperbolik Tanjant)	31
4.1.2.3. ReLU (Rectified Linear Unit)	32
4.1.3. Geri yayılım algoritması (Backpropagation)	32
4.1.4. Derin sinir ağları (Deep Neural Networks - DNN).....	33
4.1.4.1. Doğal dil işleme (NLP)	34
4.1.4.2. Görüntü işleme	34
4.1.4.3. Zaman serisi analizi	34
4.1.5. Öğrenme çeşitleri	34

4.1.5.1. Denetimli öğrenme (Supervised Learning).....	35
4.1.5.2. Denetimsiz öğrenme (Unsupervised Learning).....	35
4.1.5.3. Pekiştirmeli öğrenme (Reinforcement Learning).....	36
4.2. K-En yakın komşu (KNN) algoritması.....	36
4.2.1. Mesafe metrikleri ve matematiksel temeller	37
4.2.2. KNN algoritmasının işleyiş adımları.....	39
4.2.3. Parametre seçimi ve optimizasyon	39
4.3. Destek Vektör Makineleri (Support Vector Machines - SVM).....	40
4.3.1. Matematiksel temeller ve hedef fonksiyon	41
4.3.2. Lagrange çarpanları.....	41
4.3.3. Kernel fonksiyonları ve doğrusal olmayan ayrılabilirlik	42
4.3.4. Parametre optimizasyonu ve çapraz doğrulama.....	43
4.4. Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM).....	43
4.4.1. Matematiksel temeller ve model yapısı.....	43
4.4.1.1. Unutma kapısı	44
4.4.1.2. Giriş kapısı ve aday hücre durumu.....	44
4.4.1.3. Çıkış kapısı ve gizli durum.....	45
4.4.2. Kernel fonksiyonları.....	45
4.4.3. Hiperparametre seçimi ve model optimizasyonu	46
5. DENEYSEL ÇALIŞMALAR.....	47
5.1. Veri Setinin Hazırlanması	47
5.1.1. Normal durum için veriseti oluşturulması.....	47
5.1.2. Farklı ferorezonans durumu için veriseti oluşturulması	48
5.2. Model Performans Değerlendirilmesi	52
5.2.1. KNN modeli performans değerlendirilmesi.....	52
5.2.2. SVM modeli performans değerlendirilmesi.....	56
5.2.3. LSTM modeli performans değerlendirilmesi.....	58
5.3. Model Sonuçlarının Karşılaştırılması.....	62
6. SONUÇ VE ÖNERİLER.....	65
KAYNAKLAR.....	67
ÖZGEÇMİŞ.....	73

KISALTMALAR

C	: Kondansatör
CB	: Devre Kesici
CP	: Kritik Nokta
ES	: Enerji Depolama
FR	: Ferrerezonans
FRC	: Ferrerezonans Durumu
f₀	: Rezonans Frekansı
φ	: Faz Açısı
H	: Harmonikler
I	: Akım
L	: İndüktör
LF	: Yük Akışı
MF	: Manyetik Alan
OV	: Aşırı Gerilim
OC	: Aşırı Akım
PS	: Güç Sistemi
PF	: Güç Faktörü
P	: Gerçek Güç
PQ	: Güç Kalitesi
PV	: Zirve Gerilimi
Q	: Reaktif Güç
RMS	: Karekök Ortalama Kare
SC	: Kısa Devre
T	: Geçici Durumlar
TR	: Transformatör
V	: Gerilim
VS	: Gerilim Kararlılığı
VS	: Gerilim Dalgalanması
Z	: Empedans



SİMGELER

C_f	: Ferrerezonans kapasitesi [F]
E_f	: Ferrerezonans enerjisi [J]
f_f	: Ferrerezonans frekansı [Hz]
I_f	: Ferrerezonans akımı [A]
L_f	: Ferrerezonans indüktansı [H]
M_f	: Ferrerezonans manyetik alan gücü [A·m]
P_f	: Ferrerezonans gücü [W]
Q_f	: Ferrerezonans kalitesi (quality factor) [boyutsuz]
R_f	: Ferrerezonans direnç [Ω]
S_f	: Ferrerezonans şiddeti [W/m ²]
V_f	: Ferrerezonans gerilmesi [V]
Z_f	: Ferrerezonans empedansı [Ω]
ω	: Açısal frekans [rad/s]
θ_f	: Ferrerezonans faz açısı [radyan]
ΔV_f	: Ferrerezonans gerilim değişimi [V]



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Ferreazonans Devresi.....	14
Şekil 2.2. Seri Ferreazonans Devresinin Fazör Diyagramı.....	14
Şekil 2.3. Seri Ferreazonans Devresinin Devre Elemanlarının Karakteristikleri ve İşletme Noktaları.....	15
Şekil 2.4. Seri Ferreazonans Devresinin Doyma Eğrisi.....	16
Şekil 2.5. Paralel Ferreazonans Devresi.....	16
Şekil 2.6. Paralel Ferreazonans Devresinin Fazör Diyagramı.....	17
Şekil 2.7. Paralel Ferreazonans Devresinin Doyma Eğrisi.....	18
Şekil 4.1. Yapay Zeka Modeli Katmanları.....	29
Şekil 4.2. Yapay Sinir Ağı Benzetimi.....	30
Şekil 4.3. Sigmoid Fonksiyonu.....	31
Şekil 4.4. Tanh Fonksiyonu.....	32
Şekil 4.5. Relu Fonksiyonu.....	32
Şekil 4.6. Yapay Zeka Modelinde Geri Yayılım.....	33
Şekil 4.7. Örnek DNN Modeli.....	34
Şekil 4.8. KNN Modelinin Çalışma Prensipleri.....	37
Şekil 4.9. Mesafe Metriklerinin Görselleştirilmesi.....	38
Şekil 4.10. Manhattan Mesafesi.....	38
Şekil 4.11. Destek Vektör Makineleri.....	40
Şekil 4.12. Polinom Kernelin Görselleştirilmesi.....	42
Şekil 4.13. Çapraz Doğrulamanın Görselleştirilmesi.....	43
Şekil 4.14. LSTM Yapısı.....	44
Şekil 5.1. Ferreazonanssız Sinüsoidal Dalga.....	48
Şekil 5.2. 1 Numaralı Özelliklere Göre Ferreazonans.....	48
Şekil 5.3. 2 Numaralı Özelliklere Göre Ferreazonans.....	49
Şekil 5.4. 3 Numaralı Özelliklere Göre Ferreazonans.....	49
Şekil 5.5. 4 Numaralı Özelliklere Göre Ferreazonans.....	50
Şekil 5.6. 5 Numaralı Özelliklere Göre Ferreazonans.....	50
Şekil 5.7. 6 Numaralı Özelliklere Göre Ferreazonans.....	51
Şekil 5.8. 7 Numaralı Özelliklere Göre Ferreazonans.....	51
Şekil 5.9. 8 Numaralı Özelliklere Göre Ferreazonans.....	52
Şekil 5.10. KNN Modeli Sonrasında PCA.....	52
Şekil 5.11. KNN Modelinin Karmaşıklık Matrisi.....	53
Şekil 5.12. KNN Modelinin Sınıflandırma Raporu.....	54
Şekil 5.13. SVM Modeli Sonrası PCA.....	56
Şekil 5.14. SVM Modelinin Karmaşıklık Matrisi.....	56
Şekil 5.15. SVM Modelinin Sınıflandırma Raporu.....	57
Şekil 5.16. LSTM Modelinin Öğrenme ve Doğrulama Doğruluğu.....	58
Şekil 5.17. LSTM Modelinin Öğrenme ve Doğrulama Kaybı.....	59
Şekil 5.18. LSTM Modelinin 2 Etiketli Karmaşıklık Matrisi.....	60
Şekil 5.19. LSTM Modelinin 2 Etiketli Sınıflandırma Raporu.....	60

Şekil 5.20. LSTM Modelinin 7 Etiketeki Karmaşıklık Matrisi.	61
Şekil 5.21. LSTM Modelinin 7 Etiketeki Sınıflandırma Raporu.	62



ELEKTRİK GÜÇ SİSTEMLERİNDE FERROREZONANS ANALİZİ VE YAPAY ZEKA TABANLI TESPİTİ

ÖZET

Ferrorezonans, yüksek gerilimli elektrik güç sistemlerinde meydana gelebilecek karmaşık ve potansiyel olarak tehlikeli bir fenomendir. Genellikle, trafolar, kondansatörler ve anahtarlar gibi sistemin doğrusal olmayan bileşenlerinin etkileşimi ile ilişkilidir ve sistemin bileşenleri belirli frekansta rezonansa girdiğinde ortaya çıkar. Ferrorezonans, aniden yük değişiklikleri, arızalar veya anahtarlama işlemleri gibi belirli koşulların tetiklemesiyle başlar ve bunun sonucunda anormal gerilim ve akım salınımları meydana gelir. Bu salınımlar, elektrikli ekipmanlara ciddi zararlar verebilir, güç tedarikini kesebilir ve onarım maliyetleri, duruş süreleri ve sistem arızaları nedeniyle finansal kayıplara yol açabilir. Ferrorezonansın öngörülemezliği, geleneksel koruma sistemleri için bir zorluk oluşturur ve bu olayı gerçek zamanlı olarak tespit etmek ve önlemek zordur.

Ferrorezonansın etkileri, trafolar ve kondansatörler gibi önemli elektrikli bileşenlere kalıcı zararlar verebilecek yüksek gerilim zirveleri ve bozulmuş akım dalgaları olarak kendini gösterir. Bu etkiler genellikle öngörülemezdir ve uzun süre devam edebilir, bu da güç şebekesine yönelik riskleri daha da artırır. Ferrorezonans meydana geldiğinde, izolasyon arızaları, ekipman aşırı ısınması ve hatta trafoların ve diğer kritik altyapıların felakete uğraması gibi felaket sonuçları doğurabilir. Ferrorezonansın neden olduğu zararlı elektriksel dalgalanmalar, sistem genelinde yayılabilir ve yakınlardaki trafolarla etki ederek geniş çaplı elektrik kesintilerine yol açabilir. Böyle olaylar güç kaybı, ekipman arızası, uzun kurtarma süreleri ve büyük finansal kayıplara neden olabilir. Bu nedenle, ferrorezonansın doğru bir şekilde tespit edilmesi ve önlenmesi, güç sistemlerinin güvenilir bir şekilde çalışabilmesi için çok önemlidir. Gelişmiş tespit tekniklerinin geliştirilmesi, ferrorezonansın etkisini azaltmaya ve güç şebekelerinin dayanıklılığını artırmaya yardımcı olabilir.

Geleneksel ferrorezonans tespit yöntemleri genellikle frekans analizi, zaman alanı simülasyonları ve sistem modelleme gibi tekniklere dayanır. Ancak, bu yöntemler genellikle gerçek zamanlı tespit açısından yetersiz kalır, çünkü yüksek hesaplama gereksinimleri vardır ve güç sistemlerinin dinamik doğasını hesaba katmak için esneklikten yoksundurlar. Ayrıca, geleneksel yaklaşımlar zamanında uyarılar sağlamayabilir, bu da müdahale gecikmelerine ve ekipmanlara daha fazla zarar verilmesine yol açabilir. Buna karşılık, yapay zeka (YZ) tabanlı teknikler, makine öğrenmesi (ML), derin öğrenme ve zaman serisi analizi gibi yöntemler, ferrorezonansı daha doğru ve hızlı bir şekilde tespit etmek için umut verici alternatifler sunmaktadır. YZ tabanlı yöntemler, sistem verilerindeki desenleri ve anormallikleri analiz ederek ferrorezonansın başlangıcını tahmin edebilir ve potansiyel arızalar için erken uyarılar sağlayabilir. Bu yaklaşımlar, tespit hızını artırmanın yanı sıra, olaylara daha hızlı yanıt verilmesini sağlayarak maliyetleri ve duruş sürelerini de azaltır. Tespit sürecini

otomatikleştirerek, YZ tabanlı izleme sistemleri manuel müdahalelere olan bağımlılığı azaltır ve güç sistemlerinin genel verimliliğini ve güvenilirliğini artırır.

Bu çalışma, ferreazonans olaylarını tespit etmek ve analiz etmek için üç farklı YZ tabanlı tekniğin kullanımını incelemektedir: K-En Yakın Komşular (KNN), Destek Vektör Makineleri (SVM) ve Uzun Kısa Süreli Bellek (LSTM) ağıları. Bu teknikler, ferreazonans tespiti ile ilgili farklı yönleri ele almak ve zaman serisi verileri için uygunlukları nedeniyle seçilmiştir. Çalışmanın amacı, her makine öğrenmesi modelinin gerçek zamanlı gerilim ve akım ölçümleri temelinde ferreazonans olaylarını tespit etme performansını değerlendirmektir. Bu çalışmada kullanılan veri seti, normal ve ferreazonans koşullarını temsil eden simüle edilmiş güç sistemi verilerini içermektedir ve her model için eğitim ve test setlerine ayrılmıştır. Simüle edilmiş veri kullanımı, modellerin çeşitli ferreazonans senaryolarında eğitilmesi ve test edilmesi için kontrollü deneyler yapılmasını sağlamaktadır, bu da etkinliklerinin kapsamlı bir şekilde değerlendirilmesini garanti eder. Ayrıca, veri artırma teknikleri uygulanarak modellerin sağlamlığı artırılmış ve farklı senaryolarda genelleme yapma yetenekleri geliştirilmiştir.

KNN, küçük ve orta ölçekli veri setleri üzerinde etkili olan basit ancak güçlü bir sınıflandırma algoritması olduğu için seçilmiştir. KNN, veri noktalarını yakınlarındaki diğer veri noktalarına göre sınıflandırır, bu da onu güç sistemi verilerindeki desenleri tespit etmek için uygun hale getirir. Ancak, KNN'nin hesaplama karmaşıklığı veri setinin büyüklüğü arttıkça artar, bu da büyük veri setleri için ölçeklenebilirliğini sınırlayabilir. SVM ise, doğrusal olmayan verileri sınıflandırabilme yeteneği ve karmaşık sınıflandırma görevlerinde doğruluğu ile seçilmiştir. SVM, veri noktalarını ayırtıran hiper düzlemler oluşturur ve karmaşık ferreazonans desenlerinde doğrusal olmayan karar sınırlarını işlemek için özellikle etkilidir. SVM, doğrusal olmayan karar sınırlarını işleyebilmesi sayesinde zorlu senaryolarda bile ferreazonans olaylarını doğru bir şekilde sınıflandırmıştır. LSTM ağı ise, ferreazonans olaylarının dinamik ve sıralı doğasını modellemek için kullanılmıştır, özellikle zaman serisi verileri için idealdir. LSTM ağıları, sıralı verilerde uzun vadeli bağımlılıkları öğrenebilme yeteneğine sahip olup, ferreazonans olaylarının zaman içindeki dinamiklerini modelleyerek potansiyel arızaların erken uyarılarını sağlar.

Her modelin performansı, doğruluk, hassasiyet, hatırlama ve F1 puanı gibi çeşitli metriklerle değerlendirilmiştir. Sonuçlar, KNN'nin küçük veri setlerinde iyi performans gösterdiğini ve ferreazonans olaylarını yüksek doğrulukla tespit ettiğini göstermiştir. Ancak, veri seti büyüdükçe KNN'nin hesaplama karmaşıklığı bir sınırlama haline gelmiş ve verimliliğini azaltmıştır. SVM ise, daha büyük ve daha karmaşık veri setlerinde üstün performans sergileyerek yüksek doğruluk ve sağlam sınıflandırma yetenekleri sunmuştur. SVM, doğrusal olmayan karar sınırlarını işleme yeteneği sayesinde zorlu senaryolarda bile ferreazonans olaylarını doğru bir şekilde sınıflandırmıştır. LSTM ağıları ise, zaman serisi verilerinde ferreazonans olaylarını tespit etmede hem KNN hem de SVM'den daha iyi performans göstermiştir. LSTM, verilerdeki uzun vadeli bağımlılıkları ve desenleri yakalayıp, ferreazonans olayları kritik hale gelmeden önce erken uyarı sinyalleri sağlamıştır. Ferreazonansın zaman içindeki dinamiklerini modelleme yeteneği, LSTM'yi güç sistemlerinin gerçek zamanlı izlenmesi için değerli bir araç yapmıştır.

Bu bulgular, YZ tabanlı yaklaşımların, güç sistemlerinde ferreazonans tespitini iyileştirme potansiyelini doğrulamaktadır. Sonuçlar, özellikle LSTM'nin, geleneksel yöntemlere göre ferreazonans olaylarını daha doğru ve verimli bir şekilde tespit

edebileceğini ve operatörler için değerli gerçek zamanlı uyarılar sağlayabileceğini göstermektedir. Bu olayların erken tespiti, ekipman hasarını ve sistem kesintilerini önemli ölçüde azaltabilir. Gelecekteki araştırmalar, veri setini gerçek dünya ölçümleri ile genişletmeyi ve tespit doğruluğunu daha da artırmak için ek YZ modellerini keşfetmeyi hedefleyebilir. YZ teknikleri gelişmeye devam ettikçe, ferrezonans olaylarının güç sistemlerine olan etkilerini azaltmada kritik bir rol oynamaları, sistem güvenilirliğini artırmaları ve daha proaktif bakım stratejilerini mümkün kılmaları beklenmektedir.

YZ tabanlı izleme sistemlerinin güç şebekelerine entegrasyonu, tespit sürecini otomatikleştirerek manuel müdahalelere olan bağımlılığı azaltacak ve potansiyel ferrezonans olaylarına daha hızlı yanıt verilmesini sağlayacaktır. Ayrıca, bu sistemler yeni verilerden sürekli olarak öğrenebilir ve zamanla performanslarını iyileştirebilirler. YZ alanı ilerledikçe, daha sofistike modeller ve teknikler ortaya çıkacak, bu da ferrezonansı tespit etme ve hafifletme yeteneğini daha da geliştirecek ve nihayetinde daha dayanıklı ve verimli güç sistemlerine yol açacaktır.





FERRORESONANCE ANALYSIS AND ARTIFICIAL INTELLIGENCE- BASED DETECTION IN ELECTRICAL POWER SYSTEMS

SUMMARY

Ferroresonance is a complex and potentially hazardous phenomenon that can occur in high-voltage electrical power systems, often leading to significant equipment damage, prolonged outages, and safety risks. It is typically associated with the interaction between nonlinear components of the system, particularly transformers, capacitors, and circuit breakers, when the system's components resonate at certain frequencies. Ferroresonance is triggered by specific conditions such as sudden load changes, faults, or switching operations, leading to abnormal voltage and current oscillations. These oscillations can cause severe damage to electrical equipment, disrupt the power supply, and lead to financial losses due to repair costs, downtime, and system failure. The unpredictability of ferroresonance poses a challenge to traditional protection systems, making it difficult to detect and prevent in real-time.

The effects of ferroresonance manifest as high voltage spikes and distorted current waves that can cause permanent damage to key electrical components, including transformers and capacitors. These effects are often unpredictable and can last for extended periods, further exacerbating the risks to the power grid. When ferroresonance occurs, it can result in catastrophic consequences such as insulation failures, overheating of equipment, and even catastrophic failures of transformers and other critical infrastructure. The damaging electrical surges that result from ferroresonance can also propagate throughout the system, affecting nearby substations and potentially leading to widespread power outages. Such events can cause power loss, equipment failure, long recovery periods, and significant financial losses. As a result, accurate detection and prevention of ferroresonance are crucial for the reliable operation of power systems. The development of advanced detection techniques can help mitigate the impact of ferroresonance and improve the resilience of power networks.

Traditional methods for detecting ferroresonance typically rely on techniques such as frequency analysis, time-domain simulations, and system modeling. However, these methods often fall short in terms of real-time detection, as they tend to have high computational requirements and lack the flexibility needed to account for the dynamic nature of power systems. Furthermore, conventional approaches may not provide timely alerts, leading to delays in intervention and further damage to equipment. In contrast, artificial intelligence (AI)-based techniques, such as machine learning (ML), deep learning, and time-series analysis, offer promising alternatives for more accurate and faster detection of ferroresonance. AI-based methods can analyze patterns and anomalies in system data to predict the onset of ferroresonance and provide early warnings for potential failures. These approaches not only improve detection speed but also reduce costs and downtime by enabling quicker responses to incidents. By

automating the detection process, AI-based monitoring systems reduce reliance on manual interventions and improve the overall efficiency and reliability of power systems.

This study explores the use of three different AI-based techniques for detecting and analyzing ferroresonance events: K-Nearest Neighbors (KNN), Support Vector Machines (SVM), and Long Short-Term Memory (LSTM) networks. These techniques were chosen for their ability to address different aspects of ferroresonance detection and their suitability for time-series data. The goal of the study is to evaluate the performance of each machine learning model in detecting ferroresonance events based on real-time voltage and current measurements. The dataset used in this study consists of simulated power system data representing both normal and ferroresonance conditions, with the data split into training and testing sets for each model. The use of simulated data allows for controlled experiments where the models can be trained and tested under various ferroresonance scenarios, ensuring a comprehensive evaluation of their effectiveness. Additionally, data augmentation techniques were applied to increase the robustness of the models and enhance their ability to generalize across different scenarios.

KNN, a simple yet powerful classification algorithm, was selected as the first classifier due to its effectiveness on small to medium-sized datasets. KNN classifies data points based on their proximity to nearby data points, making it well-suited for detecting patterns in power system data. However, KNN's computational complexity increases as the dataset size grows, potentially limiting its scalability for large datasets. SVM, on the other hand, was chosen for its ability to classify nonlinear data and its proven accuracy in handling complex classification tasks. SVM creates hyperplanes that separate data points into distinct classes and is particularly effective at dealing with intricate decision boundaries. It performs well even with complex ferroresonance patterns, where nonlinearities are present. LSTM was employed to model the dynamic and sequential nature of ferroresonance events, particularly for time-series data. LSTM networks are capable of learning long-term dependencies in sequential data, making them ideal for capturing the temporal aspects of ferroresonance events and detecting early warning signs of potential failures.

The performance of each model was evaluated using various metrics, including accuracy, precision, recall, and F1-score. The results showed that KNN performed well on smaller datasets, achieving high accuracy rates in identifying ferroresonance events. However, as the dataset size increased, KNN's computational complexity became a limitation, reducing its efficiency. SVM, by contrast, demonstrated superior performance on larger, more complex datasets, with high accuracy and robust classification capabilities. SVM's ability to handle nonlinear decision boundaries allowed it to classify ferroresonance events accurately even in challenging scenarios. LSTM networks, however, outperformed both KNN and SVM in detecting ferroresonance events in time-series data. LSTM was able to capture long-term dependencies and patterns in the data, allowing it to provide early warning signals of ferroresonance events before they became critical. The ability of LSTM to model the temporal dynamics of ferroresonance made it an invaluable tool for real-time monitoring of power systems.

These findings confirm the potential of AI-based approaches for improving the detection of ferroresonance in power systems. The results show that AI models, especially LSTM, can detect ferroresonance events more accurately and efficiently

than traditional methods, providing valuable real-time alerts for operators. The ability to detect these events early can significantly reduce the risk of equipment damage and system outages. Future research could focus on expanding the dataset to include real-world measurements and exploring additional AI models to further enhance detection accuracy. As AI techniques continue to evolve, they are expected to play a critical role in reducing the impact of ferroresonance events on power systems, improving overall system reliability, and enabling more proactive maintenance strategies.

The integration of AI-based monitoring systems into power grids will automate the detection process, reducing the reliance on manual interventions and allowing for faster response times to potential ferroresonance events. Furthermore, these systems can continuously learn from new data, improving their performance over time. As the field of AI progresses, more sophisticated models and techniques will emerge, further enhancing the ability to detect and mitigate ferroresonance, ultimately leading to more resilient and efficient power systems.





1. GİRİŞ

Güç sistemleri, bir ülkenin ekonomik ve sosyal altyapısının temel taşlarını oluşturur ve bu sistemlerin güvenli, verimli ve kesintisiz bir şekilde çalışması, ulusal refah açısından kritik bir öneme sahiptir. Sistemdeki herhangi bir aksamaya, yalnızca büyük ekonomik kayıplara yol açmakla kalmaz, aynı zamanda toplumların günlük yaşamını derinden etkileyebilir. Elektrik kesintileri, endüstriyel faaliyetleri durdurabilir, sağlık hizmetlerini aksatabilir ve genel yaşam kalitesini olumsuz yönde etkileyebilir. Güç sistemlerinin doğru çalışabilmesi için jeneratörler, transformatörler, kesiciler ve iletim hatları gibi ekipmanların düzenli bir şekilde izlenmesi ve potansiyel arızaların önceden tespit edilmesi gerekir. Arızalar genellikle simetrik (dengeli) ve asimetrik (dengesiz) olarak ikiye ayrılır ve doğa olayları (deprem, yıldırım, vb.) ya da sistem ekipmanlarındaki bozulmalar nedeniyle meydana gelir. Bu tür arızaların hızla ve etkili bir şekilde giderilmesi, sistemin güvenliği ve verimliliği açısından büyük bir öneme sahiptir.

Ferrorezonans, güç sistemlerinde nadiren karşılaşılan, ancak oldukça yıkıcı olabilen bir olaydır. Bu olay, doğrusal olmayan endüktans ile kapasitans arasındaki etkileşimin bir sonucu olarak ortaya çıkar ve sistemdeki küçük bir gerilim veya frekans değişikliği bile büyük ve ani salınımlar yaratabilir. Ferrorezonansın meydana gelmesi için düşük omik kayıplar ve uygun bir gerilim kaynağı gereklidir. Sistem içindeki doğrusal olmayan endüktans genellikle transformatörlerin manyetik çekirdeklerinden kaynaklanırken, kapasite iletim hatlarının uzunluğundan ve kesicilerin topraklama dirençlerinden etkilenir. Bu fenomen, kısa devreler, transformatör ve kondansatör anahtarlama, yalıtım arızaları, yıldırım düşmesi, yük kaybı ve iletim hatlarının kopması gibi durumlarla tetiklenebilir.

Ferrorezonansın etkileri, aşırı gerilimler, aşırı akımlar ve harmonik frekans bileşenleri şeklinde kendini gösterir. Bu etkiler, sistemdeki ekipmanlara ciddi zararlar verebilir ve sistemin verimli çalışmasını engelleyebilir. Ferrorezonansın süreklilik arz eden etkileri ise genellikle dört farklı kategoride sınıflandırılır: temel durum, alt harmonikler, yarı periyodikler ve kaotik durumlar. Hangi durumun ortaya çıkacağı,

sistemin parametrelerine ve başlangıç koşullarına bağlıdır. Diğer doğrusal olmayan olaylarda olduğu gibi, ferreazonans da başlangıç koşullarına ve sistem parametrelerindeki değişimlere oldukça duyarlıdır.

Ferreazonans olayı, ilk olarak 1900'lü yılların başında incelenmeye başlanmış ve başlangıçta grafiksel yöntemlerle ele alınmıştır. Zamanla, bu olgunun daha derinlemesine anlaşılabilmesi için analitik yöntemler geliştirilmiş, güç sistemleri daha basit RLC devreleri ile modellenmiştir. Bu tür analizler genellikle transformatörlerin mıknatıslanma akımları ve besleme gerilimleri gibi parametrelerin değiştirilmesiyle yapılmış ve diferansiyel denklemler kullanılarak sistemin dinamik özellikleri incelenmiştir. Son yıllarda ise, veri toplama sistemlerindeki gelişmeler ve işaret işleme tekniklerindeki ilerlemeler sayesinde, ferreazonansın tespitine yönelik daha hızlı ve etkili yöntemler ortaya çıkmıştır. Bu gelişmeler, güç sistemlerinin güvenliğini artırarak, arıza durumlarını daha erken aşamalarda tespit etmeye ve etkili müdahalede bulunmaya olanak sağlamaktadır.

Elektrik enerjisi, modern toplumların temel gereksinimlerinden biri haline gelmiş ve bu bağımlılık her geçen gün artmaktadır. Elektrik enerjisinin sunduğu avantajlar, artan dünya nüfusu, sanayileşme ve dijitalleşme gibi faktörlerle pekişmektedir. Elektrik talebindeki bu artış, mevcut enerji tesislerinin genişletilmesi ve yeni tesislerin inşa edilmesini zorunlu kılmaktadır. Ancak, bu büyüyen sistemler, beraberinde yeni ve karmaşık sorunları da getirmektedir. Bu sorunlar, hem teknik hem de ekonomik açıdan büyük zorluklar yaratmakta ve güç sistemlerinin güvenli ve kesintisiz bir şekilde çalışabilmesi için çözülmesi gereken engeller oluşturur.

Büyüyen güç sistemlerinde daha önce göz ardı edilen bazı önemli sorunlar da gün yüzüne çıkmaktadır. Bu sorunlardan biri de, özellikle transformatörlerin doğrusal olmayan mıknatıslanma özelliklerinden kaynaklanan ferreazonans olayıdır. Ferreazonans, elektrik devrelerinde, özellikle ferromanyetik çekirdek içeren devrelerde meydana gelen doğrusal olmayan bir rezonans olayıdır. Küçük bir frekans veya genlik değişikliği, sistemde ani ve yıkıcı salınımlar yaratabilir. Ferreazonans, özellikle yüksek gerilimli iletim hatlarında büyük zararlara yol açabilir ve güç sisteminin kararlı çalışmasını tehdit edebilir.

Yüksek gerilimli iletim hatlarında, çift devreli sistemler yaygın olarak kullanılır. Bu tür sistemlerde, bir hat devre dışı bırakıldığında diğer hat üzerinden enerji iletimi

devam edebilir. Ancak, devre dışı bırakılan hattın transformatöründeki manyetik alan ve hattın kapasitesindeki depolanan enerji, sistemde salınımlara yol açabilir. Bu salınımlar, demir kayıpları ve diğer devre kayıpları nedeniyle zamanla sönse de, başka iletim hatları tarafından karşılanan bu kayıplar kalıcı salınımlara yol açarak, transformatör terminallerinde aşırı gerilimlere neden olabilir. Sonuç olarak, ferrerezonans, iletim sistemlerinde ciddi güvenlik açıkları ve ekipman hasarları yaratabilir.

Ferrerezonans, yüksek gerilimli güç sistemlerinde karşılaşılan ve büyük arızalara yol açabilen karmaşık bir olgudur. Bu fenomen, gerilim ve akım dalgalanmalarına, ekipman hasarlarına, enerji kayıplarına ve sistem kesintilerine neden olabilir. Ferrerezonansın oluşumu, ferromanyetik çekirdeklerin manyetik doygunluğa ulaşması ve sistemdeki rezonans frekansına yaklaşan bileşenlerin etkisiyle tetiklenir. Bu durum, özellikle transformatörler ve kondansatörler gibi kritik ekipmanlarda büyük zararlara yol açabilir ve sistemin verimli çalışmasını engelleyebilir. Bu bağlamda, ferrerezonansın erken tespiti ve etkilerinin önlenmesi, güç sistemlerinin güvenliği açısından kritik bir öneme sahiptir.

Geleneksel yöntemler, ferrerezonansın tespiti konusunda yetersiz kalırken, yapay zeka tabanlı yaklaşımlar bu soruna etkin çözümler sunmaktadır. Makine öğrenmesi, derin öğrenme ve zaman serisi analizi gibi yapay zeka teknikleri, ferrerezonans olaylarını erken teşhis etmek ve sistemdeki anormallikleri analiz ederek potansiyel arızaları önceden tespit etmek için kullanılmaktadır. Bu çalışma, ferrerezonans olaylarını tespit etmek ve analiz etmek amacıyla üç farklı yapay zeka tabanlı yaklaşımı incelemektedir: K-En Yakın Komşu (KNN), Destek Vektör Makineleri (SVM) ve Long Short-Term Memory (LSTM) ağları.

Bu modeller, gerçek zamanlı voltaj ve akım verilerine dayanarak ferrerezonansın etkin bir şekilde tespit edilmesini sağlar. KNN, küçük ve orta büyüklükteki veri setlerinde yüksek doğrulukla sınıflandırma yapabilmesi nedeniyle tercih edilmiştir. SVM, doğrusal olmayan verileri başarılı bir şekilde sınıflandırarak ferrerezonansın karmaşık durumlarını ele almak için kullanılmıştır. LSTM ise, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenme yeteneğiyle, dinamik ve gelişen ferrerezonans olaylarını tahmin etmek için uygulanmıştır. Bu çalışma, güç sistemlerinde ferrerezonansın erken teşhisi ve etkili yönetimi için yapay zeka tabanlı yaklaşımların etkinliğini ortaya koymayı amaçlamaktadır.

1.1. Literatür Taraması

Anderson, ferrorezonans olayını ilk kez yüksek gerilimli güç sistemlerinde tanımlamıştır. Çalışmasında, transformatörlerde ve diğer elektriksel bileşenlerde aşırı gerilim dalgalanmalarının meydana geldiğini vurgulamış ve sistemde büyük enerji kayıpları ve ekipman arızalarına yol açabileceğini ifade etmiştir. Ferrorezonansın enerjinin verimli bir şekilde taşınmasını engelleyebileceği üzerinde durmuş ve bu fenomenin dikkatli yönetilmesi gerektiğini belirtmiştir [1].

Hughes, F. ferrorezonansın potansiyel tehlikelerini ele aldığı çalışmasında, bu fenomenin güvenlik riski oluşturduğunu ve özellikle güç sistemlerinde daha büyük arızaların yaşanmasına yol açabileceğini belirtmiştir. Ferrorezonansın transformatörlerde aşırı gerilimlere neden olabileceği ve bu durumun sistemdeki dengeyi bozabileceği üzerinde durmuş, güç sistemlerinin tasarımında bu fenomenin göz önünde bulundurulması gerektiğine işaret etmiştir [2].

Kessel, C.A., ve McRae, J.R. güç sistemlerinde ferrorezonansın dinamik etkilerini inceledikleri çalışmalarında, özellikle uzun mesafeli iletim hatlarında bu fenomenin büyük arızalara yol açabileceğini araştırmışlardır. Ferrorezonansın, sistemdeki elektriksel bileşenlerdeki gerilim dalgalanmalarını tetikleyebileceğini ortaya koymuş ve bu konuda daha fazla araştırma yapılması gerektiğini savunmuşlardır [3].

Pekárová ve arkadaşları ferrorezonansın transformatörler üzerindeki etkilerini derinlemesine inceledikleri çalışmalarında, aşırı gerilimlerin transformatörlerde büyük enerji kayıplarına neden olabileceğini vurgulamışlardır. Transformatörlerin ferrorezonans sırasında nasıl etkilendiği ve bu olayların sistemdeki güvenlik risklerini artırabileceği üzerinde durmuşlar, bu nedenle ferrorezonansa karşı önleyici tedbirlerin alınması gerektiğini belirtmişlerdir [4].

Amin ve Chan ferrorezonansın önlenmesi için mühendislik çözümleri sundukları çalışmalarında, bu fenomeni engellemek için kullanılan gelişmiş sistemlerin nasıl verimli çalışabileceğini açıklamışlardır. Çalışmada, ferrorezonansı engellemek için güç şebekelerinde kullanılan yeni yöntemler üzerinde yoğunlaşmış ve bu yöntemlerin sistem performansını nasıl artırabileceği tartışılmıştır [5].

Miller ferrorezonansın güç sistemlerinde yarattığı tehditleri ele aldığı çalışmasında, özellikle yüksek gerilimli transformatörlerde bu fenomenin tespitine yönelik koruma sistemlerinin geliştirilmesi gerektiğini savunmuştur. Çalışmada, ferrorezonansın

koruma röleleri ve güvenlik sistemleri üzerinde nasıl etkileşime girdiği tartışılmış ve güvenlik önlemlerinin önemine vurgu yapılmıştır [6].

García ve arkadaşları ferrerezonansın tespitine yönelik yeni teknikler geliştirdikleri çalışmalarında, güç sistemlerinde ferrerezonansın algılanmasında kullanılan sensörlerin etkinliğini incelemişlerdir. Sensörlerin, ferrerezonansı erken tespit etmede nasıl yardımcı olabileceği ve sistemdeki güvenlik risklerini azaltmadaki rolü üzerinde durmuşlardır [7]

Jadidi ve Dufour ferrerezonansın tespitini ve önlenmesini sağlayan gelişmiş koruma rölelerinin etkinliğini inceledikleri çalışmalarında, bu tür rölelerin doğru şekilde tasarlandığında sistemdeki güvenlik açıklarını ortadan kaldıracak şekilde ortaya koymuşlardır. Bu, ferrerezonansın engellenmesi için kritik bir adım olarak değerlendirilmiştir [8].

Yildirim ve arkadaşları ferrerezonansın farklı koşullar altında nasıl davrandığını modelledikleri sayısal simülasyon çalışmalarında, bu fenomenin elektrik şebekelerindeki dinamik etkilerini incelemişlerdir. Simülasyonların, ferrerezonansın anlaşılmasında ve engellenmesinde önemli bir araç olduğunu göstermişlerdir [9].

Liu ve arkadaşları karmaşık güç ağlarında ferrerezonansın modellenmesini inceledikleri çalışmalarında, bu tür ağlarda ferrerezonansın nasıl ortaya çıktığını ve sistem dinamiklerini nasıl etkileyebileceğini araştırmışlardır. Karmaşık ağlarda ferrerezonansın daha doğru şekilde modellenmesi için önerilerde bulunmuşlardır [10].

Zhao ve arkadaşları ferrerezonansın gerilim trafoları üzerindeki etkilerini inceledikleri çalışmalarında, bu tür olayların özellikle gerilim trafolarında ciddi güvenlik tehditlerine yol açabileceğini belirtmişlerdir. Gerilim trafolarının ferrerezonans sırasında nasıl davrandığına ve bu etkilerin önlenmesi için alınması gereken önlemlere odaklanmışlardır [11]

Pinho ve arkadaşları güç şebekelerinde ferrerezonansın tespitini sağlayacak yeni algoritmalar geliştirdikleri çalışmalarında, bu algoritmaların verimliliğini test etmiş ve sistemdeki ferrerezonansın daha erken tespit edilmesini sağlamışlardır [12].

Rodríguez ve arkadaşları ferrerezonansın iletim hatlarında oluşturduğu enerji kayıplarını ve gerilim dalgalanmalarını inceledikleri çalışmada, bu tür olayların önlenmesi için kullanılabilecek yenilikçi mühendislik çözümleri üzerinde

durmuşlardır. Ayrıca, güç iletim hatlarında ferrerezonansı tespit etmenin önemi üzerinde durmuşlardır [13].

Wang ve arkadaşları yüksek gerilimli iletim hatlarında ferrerezonansın etkilerini inceledikleri çalışmalarında, bu tür olayların gerilim dalgalanmalarına ve büyük arızalara yol açabileceğini belirtmişlerdir. Çalışma, yüksek gerilimli hatlarda ferrerezonansın engellenmesi için çözüm önerileri sunmaktadır [14].

Chen ve arkadaşları güç şebekelerinde ferrerezonansın zamanla nasıl evrildiğini inceledikleri çalışmalarında, bu fenomenin büyük enerji kayıplarına yol açabileceğini ve sistemin güvenliğini tehlikeye atabileceğini ortaya koymuşlardır. Çalışmalarında, ferrerezonansın güç iletim hatlarında nasıl engellenebileceği üzerine önerilerde bulunmuşlardır [15].

Kang ve arkadaşları ferrerezonansın yüksek gerilimli güç iletim hatlarında yarattığı etkileri inceledikleri çalışmalarında, bu tür fenomenlerin neden olduğu arızaların büyük enerji kayıplarına yol açabileceğini belirtmişlerdir. Çalışmalarında, ferrerezonansın sistemdeki bileşenler üzerinde oluşturduğu etkileri ve alınması gereken önlemleri ele almışlardır [16].

Miao ve arkadaşları güç sistemlerinde ferrerezonansın algılanmasına yönelik geliştirdikleri algoritmaların etkinliğini inceledikleri çalışmalarında, algılama algoritmalarının güç şebekelerinde güvenliğini artırmada önemli bir rol oynadığını ortaya koymuşlardır [17].

Zhang ve arkadaşları ferrerezonansın modellenmesi üzerine yaptıkları çalışmada, bu tür bir olayın güç sistemindeki bileşenlerde çok ciddi hasarlara yol açabileceğini ve buna karşı çeşitli koruma stratejileri geliştirilmesi gerektiğini belirtmişlerdir. Ayrıca, güç şebekelerinde güvenliğini sağlamada karşılaşılan zorlukları ele almışlardır [11].

Wang ve arkadaşları ferrerezonansın statik ve dinamik etkilerini modelledikleri çalışmalarında, özellikle sistemdeki enerji kayıplarının nasıl minimize edilebileceği ve ferrerezonansın etkilerinin önlenmesi için hangi mühendislik çözümlerinin kullanılabileceği üzerine yoğunlaşmışlardır [18].

Li ve Zhang gerilim trafolarındaki ferrerezonansı modelledikleri çalışmalarında, ferrerezonansın bu tür ekipmanlarda enerji kayıplarına neden olabileceğini ortaya koymuşlardır. Çalışma, ferrerezonansın engellenmesi için mühendislik çözümleri önermektedir [19].

Chen ve arkadaşları transformatörlerin ferreazonans sırasında nasıl etkilendiğini inceledikleri çalışmalarında, özellikle yüksek gerilimli sistemlerde bu tür olayların çok büyük güvenlik risklerine yol açabileceğini ve sistemin bütünlüğünü tehdit edebileceğini belirtmişlerdir [15].

Lee ve arkadaşları kondansatör bankalarında ferreazonansın engellenmesi için bir çözüm önerisi sundukları çalışmalarında, bu tür durumların nasıl önlenebileceğini ve kondansatör bankalarının ferreazonansa karşı nasıl dayanıklı hale getirilebileceğini tartışmışlardır [20].

Wang ve arkadaşları ferreazonansın tespitine yönelik yapay zeka tabanlı bir yaklaşım geliştirdikleri çalışmalarında, yapay zeka algoritmalarının ferreazonansın erken tespiti için önemli bir araç olduğunu vurgulamışlardır. Bu algoritmalar, güç sistemlerinde daha hızlı ve doğru tespit yapmayı mümkün kılmaktadır [21].

Li ve arkadaşları yapay zeka tabanlı güç şebekesi güvenlik sistemlerinin ferreazonansı nasıl tespit edebileceğini tartıştıkları çalışmalarında, yapay zeka teknolojilerinin bu alanda kullanılabilirliğini vurgulamışlardır [22].

Kim ve arkadaşları ferreazonansın tespitine yönelik gerçek zamanlı simülasyonlarla geliştirdikleri algoritmaların etkinliğini inceledikleri çalışmada, bu algoritmaların güç sistemlerinde ferreazonansın erken tespiti için önemli bir araç olduğunu ortaya koymuşlardır. Bu yöntem, sistemdeki güvenlik açıklarını azaltmak ve daha hızlı tespit yapmak için kullanılmıştır [23].

Yang ve arkadaşları uzun mesafeli iletim hatlarında ferreazonansın etkilerini inceledikleri çalışmalarında, ferreazonansın, özellikle gerilim trafolarında büyük kayıplara yol açabileceğini vurgulamışlardır. Ayrıca, iletim hattı tasarımında bu fenomenin önlenmesi için kullanılması gereken mühendislik tekniklerine yer vermişlerdir [24].

Xu ve arkadaşları yapay zeka tabanlı tekniklerle ferreazonansın tespitini sağlamak amacıyla geliştirdikleri sistemin etkinliğini test etmişlerdir. Çalışmalarında, yapay zeka algoritmalarının güç şebekelerinde güvenliği sağlamak için büyük potansiyel taşıdığını ve ferreazonansı tespit etmek için çok etkili bir çözüm sunduğunu açıklamışlardır [25].

Zhang ve arkadaşları güç sistemlerinde ferreazonansı engellemeye yönelik yeni yöntemler geliştirdikleri çalışmalarında, sistemdeki ekipmanların tasarımında

kullanılan yeni malzemelerin ferrerezonansı engellemeye yönelik potansiyel taşıdığını keşfetmişlerdir [26].

Liu ve Yu hibrit güç sistemlerinde ferrerezonansın önlenmesi üzerine yaptıkları çalışmada, bu tür sistemlerin ferrerezonansa karşı daha dayanıklı hale getirilmesi için önerilerde bulunmuşlardır. [27].

Wang ve arkadaşları güneş enerjisi santrallerindeki ferrerezonansın etkilerini inceledikleri çalışmalarında, güneş enerjisi sistemlerinin bu fenomenin etkilerinden nasıl korunabileceğine dair çözümler geliştirmişlerdir [28].

Tian ve arkadaşları iletim hattı izolasyonunun ferrerezonans üzerindeki etkilerini inceledikleri çalışmalarında, izolasyonun bu fenomenin risklerini nasıl azaltabileceğini açıklamışlardır. Çalışma, iletim hatlarında izolasyon tekniklerinin kullanılması gerektiğini vurgulamaktadır [29].

Zhao ve arkadaşları yapay zeka ve makine öğrenimi tabanlı koruma sistemlerinin ferrerezonansın tespitindeki potansiyelini inceledikleri çalışmalarında, bu tür teknolojilerin yüksek verimlilik sağladığını ve ferrerezonansı daha hızlı tespit edebileceğini göstermişlerdir [30].

Xia ve arkadaşları karmaşık güç şebekelerinde ferrerezonans için geliştirdikleri koruma şemalarını inceledikleri çalışmalarında, bu şemaların sistemde ferrerezonansın etkilerini nasıl azaltabileceğini ve daha güvenli hale getirebileceğini tartışmışlardır [31].

Patel ve arkadaşları güç sistemlerinde ferrerezonansın potansiyel risklerini inceledikleri çalışmalarında, transformatörler ve kondansatör bankaları gibi bileşenlerin ferrerezonans sonucu büyük arızalarla karşılaşabileceğini belirtmişlerdir. Ayrıca, bu fenomenin tespiti ve önlenmesi için geliştirilmiş sensörlerin ve algoritmaların önemini vurgulamışlardır [32].

Liu ve arkadaşları ferrerezonansın transformatörlerde yarattığı etkilere yönelik yaptıkları deneysel çalışmada, bu tür olayların transformatörler üzerinde nasıl büyük enerji kayıplarına yol açtığını göstermişlerdir. Çalışma, transformatörlerde bu kayıpların azaltılmasına yönelik çeşitli çözümler sunmaktadır [10]

1.2. Tezin Amacı

Bu çalışmanın temel amacı, enerji iletim ve dağıtım sistemlerinde önemli bir tehdit oluşturan ferrerezonans fenomenini daha iyi anlamak, bu olayı etkili bir şekilde modellemek ve sınıflandırmaktır. Ferrerezonans, enerji sistemlerinde hem ekipman arızalarına hem de sistem performansında ciddi düşüslere yol açabilen karmaşık bir fenomen olup, doğru bir şekilde tespit edilmesi ve yönetilmesi kritik bir öneme sahiptir. Bu bağlamda, yapay zeka tabanlı yaklaşımların, ferrerezonans olaylarının sınıflandırılması ve karakterize edilmesindeki etkinliğini araştırmak, çalışmanın ana odağını oluşturmaktadır.

Tezin birincil hedefi, MATLAB ortamında simüle edilen ferrerezonans olaylarından elde edilen verilere dayalı olarak, bu olayların farklı sınıflandırma yöntemleri kullanılarak analiz edilmesi ve modellenmesidir. Bu süreçte, KNN, SVM ve LSTM gibi farklı yapay zeka modelleri kullanılarak elde edilen sonuçların kıyaslanması ve bu modellerin performansları üzerine detaylı bir değerlendirme yapılmıştır. Özellikle zamansal veri analizi ve karmaşık sinyallerin anlaşılması konularında LSTM gibi derin öğrenme yaklaşımlarının sunduğu avantajların incelenmesi, çalışmanın özgün bir katkısını oluşturmaktadır.

Tezin diğer bir hedefi ise, ferrerezonans gibi sistemik problemlerin çözümünde yapay zeka uygulamalarının enerji sistemlerine entegrasyonunun potansiyelini değerlendirmek ve bu entegrasyonun sahadaki pratik uygulamalarını teşvik etmektir. Bu doğrultuda, çalışmada kullanılan yöntemlerin genel enerji sistemleri uygulamalarına uyarlanabilirliği ve ölçeklenebilirliği üzerine öneriler sunulmuştur. Ayrıca, modelleme sürecinde karşılaşılan zorluklar ve bu zorlukların üstesinden gelmek için önerilen iyileştirmeler, enerji sistemleri mühendisliğine katkı sağlayabilecek bir perspektif sunmaktadır.

Bu tez, enerji sistemleri güvenilirliği ve sürdürülebilirliği açısından ferrerezonansın erken tespiti ve etkili yönetimi için yapay zeka temelli çözümlerin önemini vurgulamaktadır. Çalışma, yalnızca mevcut bilgi birikimine katkıda bulunmakla kalmayıp, aynı zamanda enerji sistemlerinin gelecekteki tasarım ve yönetim süreçlerine ışık tutmayı amaçlamaktadır.



2. FERROREZONANS

Ferrorezonans, güç sistemlerinde manyetik doymunluk etkilerinin rol oynadığı özel bir rezonans türü olarak tanımlanır. Bu fenomen, indüktif elemanlar (örneğin transformatörler) ve kapasitif elemanlar arasındaki enerji alışverişinin sistem parametrelerinin doğrusal olmayan özelliklerinden etkilenmesi sonucu ortaya çıkar. İlk olarak elektrik güç sistemlerinde rastlanan ferrorezonans, genellikle transformatörlerin manyetik akıyı dengelemeye çalıştığı anlarda ortaya çıkmakta ve kontrolsüz durumlarda ekipman arızalarına, enerji kayıplarına ve sistem kararsızlıklarına neden olmaktadır [33].

Bu fenomen, klasik lineer rezonans olaylarından köklü biçimde farklıdır. Lineer rezonans durumunda akım ve gerilim dalga şekilleri sinüzoidal ve düzenliken, ferrorezonans durumunda bu dalgalar kaotik, periyodik olmayan veya düzensiz bir yapıya bürünebilir. Literatürde, ferrorezonansın özellikle transformatörler, kapasitör bankaları ve kablo sistemleri üzerinde önemli etkiler yarattığı belirtilmiştir [34].

2.1. Ferrorezonans ve Lineer Rezonans Arasındaki Farklılıklar

Ferrorezonans ve lineer rezonans arasındaki temel farklılıklar şu şekilde özetlenebilir:

Rezonansın Oluştığı Parametre Alanı: Ferrorezonans, sistem parametrelerinin geniş bir aralıkta değişmesi durumunda ortaya çıkabilir. Özellikle indüktans ve kapasitans arasındaki ilişki doğrusal olmadığından, küçük parametre değişiklikleri dahi ferrorezonansın başlamasına yol açabilir. Bu durum, literatürde sıklıkla kontrolsüz rezonans fenomeni olarak tanımlanmaktadır [35].

Frekans Bağımsızlığı: Ferrorezonans olayında akım ve gerilim dalga şekillerinin frekansı, genellikle enerji kaynağının frekansından bağımsızdır. Bu, rezonansın yalnızca kaynak frekansı ile ilişkilendirildiği klasik rezonans tanımından önemli bir sapma göstermektedir [36].

Çoklu Kararlı Durumlar: Bir sistemde ferrorezonans ortaya çıktığında, aynı parametre seti altında birden fazla kararlı çözüm mevcut olabilir. Bu, sistemin belirli bir durumda

kalmasının, başlangıç koşullarına ve ani değişimlere bağlı olduğu anlamına gelir. Örneğin, transformatörlerde doygunluk bölgesine girildiğinde bu durum daha belirgin hale gelir [37].

Tek Faz ve Üç Faz Yapılar: Ferrorezonans, tek fazlı sistemlerde meydana gelebileceği gibi, üç fazlı sistemlerde de doğrusal olmayan manyetik bağlar aracılığıyla ortaya çıkabilir. Üç fazlı bir sistemde, fazlar arasında manyetik bağlantı yoksa her faz bağımsız olarak tek fazlı ferrorezonans sergileyebilir [15].

Konfigürasyon Tipleri: Ferrorezonans, seri veya paralel konfigürasyonlarda ortaya çıkabilir. Seri ferrorezonans genellikle bir indüktör ve kapasitörün seri bağlandığı sistemlerde gözlemlenirken, paralel ferrorezonans, bu elemanların paralel bağlanması ile oluşur. Her iki durumda da rezonansın dinamik davranışı farklı mekanizmalarla açıklanmaktadır [33].

2.2. Ferrorezonansın İletim Sistemlerindeki Etkileri

Enerji iletim sistemlerinde, ferrorezonans olayları özel bir rezonans durumu olarak, genellikle yıldız noktası yalıtılmış şebekelerde çalışan güç transformatörlerinin boşa çalıştığı durumlarda ortaya çıkabilmektedir. Bu fenomen, sistemde yüksek genlikli aşırı gerilimlerin oluşmasına yol açar ve bu gerilimler enerji sistemleri için ciddi bir tehdit oluşturur [2] , [38]. Aşırı gerilimlerin meydana gelmesi, ferrorezonansın doğrudan bir sonucu olup, genellikle sistemdeki nonlineer manyetik ve kapasitif elemanlar arasındaki etkileşimle ilişkilidir [4].

Orta gerilim şebekelerinde ise ferrorezonans olayları daha sık gözlemlenebilir. Bu tür durumlar, aşağıdaki olaylarla tetiklenebilir:

Gerilim transformatörüne bağlı sigortaların erimesi,

Transformatörlerin kutuplarından birinin gerilim kesilmesi veya yeniden bağlanması gibi simetri bozuklukları,

Tek fazlı anahtarlama işlemleri veya sistemde meydana gelen harmonik etkiler ([39], [11]).

Ferrerezonansın oluşum mekanizması, sistemin topolojisi, elemanların özellikleri ve çalışma koşulları ile yakından ilişkilidir. Örneğin, yıldız noktası yalıtılmış şebekelerde, transformatörlerin mıknatıslanma karakteristiği ve devreye bağlı

kapasitif elemanlar, ferreazonans olasılığını artırabilir [6]. Simetrisizlik nedeniyle oluşan dengesizlikler, sistemde harmonik bozulmalar yaratabilir ve bu durum ferreazonans olaylarını daha da karmaşık hale getirebilir [13].

Yapılan araştırmalar, özellikle enerji iletim sistemlerinde ferreazonansın sadece aşırı gerilimlere değil, aynı zamanda ekipmanların izolasyon hasarlarına, manyetik doyuma ve enerji kayıplarına yol açabileceğini ortaya koymaktadır ([40], [41]). Ayrıca, kontrolsüz ferreazonans olaylarının elektrik sistemlerinde güç kalitesini düşürdüğü ve koruma rölelerinin yanlış çalışmasına sebep olduğu belirtilmiştir [8].

Bu tür olayların önlenmesi için uygun analiz ve koruma yöntemlerinin uygulanması gerekmektedir. Modern enerji sistemlerinde, ferreazonansın önlenmesi için akıllı koruma röleleri ve simetriyi sağlayan düzenleyiciler önerilmektedir ([7], [20]). Bununla birlikte, enerji iletim sistemlerindeki farklı durumlar için ferreazonans analizi yapılırken, sistemin tüm dinamik ve statik özelliklerinin dikkate alınması gerektiği vurgulanmaktadır [25].


2.2.1. Enerji iletim sistemlerinde seri ferreazonans devreleri

Seri ferreazonans devreleri, enerji iletim sistemlerinde karşılaşılan karmaşık fenomenlerden biridir. Basit bir seri ferreazonans devresi, bir gerilim kaynağı, bir kondansatör ve demir çekirdekli bir endüktansın seri bağlanması ile oluşturulur. Lineer bir endüktans ile seri bağlı bir kondansatörün oluşturduğu devrede, belirli bir frekansta endüktansın endüktif reaktansı ile kondansatörün kapasitif reaktansının eşit olduğu durum "seri rezonans" olarak adlandırılır ve bu frekans tek bir rezonans frekansı olarak tanımlanır [42].

Bununla birlikte, demir çekirdekli bir endüktans ile seri bağlı lineer bir kondansatör içeren devrelerde, lineer devrelerden farklı olarak frekansa bağımlı olmayan bir rezonans mekanizması ortaya çıkar. Bu durumda, uygulanan sinüzoidal gerilimin belirli bir değerinde, endüktif reaktans ve kapasitif reaktans eşit hale gelir ve "seri ferreazonans" meydana gelir [43].


Bu tür devrelerde, demir çekirdeğin manyetik doyma karakteristiği nedeniyle gerçek anlamda bir rezonans oluşmaz. Bunun yerine, devrenin çalışma noktası belirli bir işletme noktasından diğerine sıçrar. Bu sıçrama, uygulanan gerilimin doğal frekansa yakın bir değer alması durumunda devredeki akımın artması ve devrenin doğal

frekansının deęiřmesiyle açıklanabilir. Bu durum, devrenin rezonans dıřında kalmasına neden olur ve dolayısıyla tehlikeli bir rezonans frekansı oluřmaz [44].




řekil 2.1. Ferrerezonans Devresi.

Demir çekirdekli endüktans ve lineer bir kondansatör içeren devrelerin temel fazör diyagramı řekil 2.2' de gösterilmektedir. Bu diyagram, devredeki akım ve gerilim bileřenlerinin nasıl etkileřimde bulunduęunu açıklamak için kullanılır [4]. Ayrıca, demir çekirdekli endüktansın gerilim-akım karakteristięi, doyma eęrisi ile řekil 2.4 'de detaylandırılmıřtır. Kondansatörün lineer karakteristięi, akım ile gerilim arasındaki doğrusal iliřkiyi temsil ederken, endüktansın doğrusal olmayan karakteristięi, manyetik doymanın etkilerini gösterir [5].




řekil 2.2. Seri Ferrerezonans Devresinin Fazör Diyagramı.

Doyma eğrisine göre, üç çalışma noktası (1, 2, ve 3) gözlemlenir. 1 ve 3 noktaları kararlı, 2 noktası ise kararsız çalışma noktasını temsil eder. Kararsız çalışma noktasında, devrenin doğal frekansı değişerek sistem, bu noktadan uzaklaşır. Devrenin kararlı veya kararsız bir noktada çalışması, uygulanan gerilimin faz açısına bağlıdır [6].



Şekil 2.3. Seri Ferrerezonans Devresinin Devre Elemanlarının Karakteristikleri ve İşletme Noktaları.


Şekil 4.8'de ferrerezonansın meydana geldiği bir durum gösterilmiştir. Eğri üzerindeki B noktası, ferrerezonansın başladığı kritik noktadır. Bu noktadan itibaren, devredeki akım ve gerilim değerleri hızla artış gösterir ve devre elemanları üzerinde yüksek gerilim ve akım değerleri oluşur [7].



Şekil 2.4. Seri Ferrerezonans Devresinin Doyma Eğrisi.


2.2.2. Enerji iletim sistemlerinde paralel ferrerezonans devreleri

Paralel ferrerezonans devreleri, enerji iletim sistemlerinde, demir çekirdekli bir endüktansın paralel bağlandığı bir kondansatör ve dirençten oluşan devrelerde gözlemlenir. Bu tür bir devrede, frekansa bağımlı olmaksızın uygulanan sinüzoidal gerilimin belirli bir değerinde, devrenin endüktif reaktansı ile kapasitif reaktansı eşit hale gelir. Böyle bir devre, paralel ferrerezonans devresi olarak adlandırılır. Paralel ferrerezonans devresinin temel şeması Şekil 2.5 'de verilmiştir [42].



Şekil 2.5. Paralel Ferrerezonans Devresi.

Bu tür bir devredeki akım ve gerilim bileşenlerinin faz ilişkisini açıklamak amacıyla oluşturulan fazör diyagramı, Şekil 2.6 'da gösterilmiştir. Fazör diyagramı, devredeki akım, gerilim ve reaktans arasındaki ilişkileri görselleştirmek için kullanılır [44].




Şekil 2.6. Paralel Ferrerezonans Devresinin Fazör Diyagramı.

2.2.3. Paralel Ferrerezonansın Akım-Gerilim İlişkisi

Paralel ferrerezonans devresinde, devredeki endüktans akımı ile kondansatör akımı arasındaki fark akımının gerilimin bir fonksiyonu olarak değişimi Şekil 2.7'de gösterilmiştir. Şekilde, devre akımı ile kondansatör ve endüktansın fark akımının eşit olduğu üç farklı nokta bulunur. Bu noktalar M, N ve P olarak etiketlenmiştir [43].

- **M ve P noktaları:** Bu noktalar, sistemin kararlı çalışma bölgelerini temsil eder.
- **N noktası:** Bu nokta ise kararsız bir çalışma bölgesine işaret eder.



Şekil 2.7. Paralel Ferrerezonans Devresinin Doyma Eğrisi

Grafikte ayrıca, endüktans akımı (i_L) ile kondansatör akımının (i_C) eşit olduğu rezonans noktası (B noktası) belirtilmiştir. Bu noktada, devrede rezonans meydana gelir. Şekil, ayrıca gerilim artışıyla birlikte fark akımının ters orantılı olarak değiştiği AB aralığını göstermektedir. Bu aralık, endüktans akımının doğrusal olmayan bir özellik sergilediği bölgeyi ifade eder [45].

Sistemdeki herhangi bir değişiklik, fark akımının A noktasında bulunduğu U_1 gerilim seviyesinden U_2 gerilim seviyesine yükselmesine neden olduğunda, devredeki fark akımı P noktasına gelir. Bu durum, gerilim ve akım değerlerinin tehlikeli seviyelere ulaşmasına yol açar. Bununla birlikte, paralel ferrerezonans devrelerinde, devredeki direnç değerinin düşük seçilmesi, devre akımlarını sınırlamak için etkili bir yöntemdir [46].

3. GÜÇ SİSTEMLERİ

Güç sistemleri, elektrik enerjisinin üretiminden son tüketiciye kadar olan süreçte enerji akışını sağlayan ve birçok teknik disiplini bir araya getiren kapsamlı bir yapıdan oluşur. Bu sistemler, enerji kaynaklarının etkili bir şekilde kullanılması, güvenliğin sağlanması ve enerji talebinin kesintisiz olarak karşılanması amacıyla tasarlanmıştır [45]. Güç sistemleri genellikle enerji üretimi, iletimi, dağıtımı ve tüketimi olmak üzere dört temel aşamadan oluşur. Her bir aşama, sistemin genel performansı ve verimliliği üzerinde kritik bir etkiye sahiptir.

Enerji üretimi, güç sistemlerinin ilk ve en önemli adımını oluşturur. Elektrik enerjisi, fosil yakıtlar (kömür, doğalgaz, petrol), nükleer enerji ve yenilenebilir enerji kaynakları (güneş, rüzgar, biyokütle, hidroelektrik) kullanılarak üretilir. Elektrik üretiminde kullanılan jeneratörler, Faraday'ın elektromanyetik indüksiyon yasasına dayanarak mekanik enerjiyi elektrik enerjisine dönüştürür. Yenilenebilir enerji kaynaklarının entegrasyonu, güç sistemlerinin çevresel sürdürülebilirlik ve enerji güvenliği açısından önemini artırmaktadır. Bununla birlikte, yenilenebilir kaynakların üretimindeki değişkenlik, sistem kararlılığı ve güvenilirliği açısından çeşitli zorluklar yaratmaktadır [47].

Üretilen elektrik enerjisinin iletim hatları üzerinden uzun mesafelere taşınması, enerji kayıplarını en aza indirmek için yüksek voltaj seviyelerinde gerçekleştirilir. İletim hatlarında genellikle 110 kV ve üzeri gerilim seviyeleri kullanılır. Yüksek gerilim, akım değerlerini düşürerek iletim hatlarındaki güç kayıplarını minimize eder ve sistemin ekonomik verimliliğini artırır. İletim hatları boyunca kullanılan transformatörler, enerjinin farklı voltaj seviyelerine uyum sağlamasını kolaylaştırır. Bununla birlikte, iletim hatlarında meydana gelebilecek arızalar, güç sisteminin genel güvenliği ve sürekliliği üzerinde ciddi etkilere neden olabileceğinden, koruma sistemlerinin etkinliği hayati önem taşır [5].

Enerji iletim hatlarından dağıtım sistemlerine geçen elektrik, son kullanıcılar için uygun voltaj seviyelerine düşürülerek kullanıma hazır hale getirilir. Dağıtım sistemlerinde transformatörler ve dağıtım panoları gibi cihazlar, gerilim seviyelerinin

optimize edilmesinde önemli bir rol oynar. Son yıllarda, akıllı şebeke teknolojilerinin gelişimi, dağıtım sistemlerinin esnekliğini ve verimliliğini artırmış, enerji yönetimini daha dinamik hale getirmiştir. Akıllı sayaçlar ve uzaktan izleme sistemleri, dağıtım sisteminin performansını gerçek zamanlı olarak izlemeyi ve olası arızaları önlemeyi mümkün kılar.

Son kullanıcılar tarafından tüketilen elektrik enerjisi, evsel, ticari ve endüstriyel ihtiyaçların karşılanmasında önemli bir rol oynar. Evsel tüketimde enerji verimliliğini artırmak için yenilikçi cihazlar ve enerji yönetim sistemleri geliştirilirken, endüstriyel tüketimde verimli motorlar ve üretim süreçlerinin optimizasyonu ön plana çıkmaktadır [47]. Ticari sektörde ise enerji talep yönetimi, işletmelerin enerji maliyetlerini azaltırken, çevresel sürdürülebilirlik hedeflerine ulaşmalarına katkı sağlamaktadır.

Güç sistemleri, modern toplumların enerji ihtiyaçlarını karşılamada hayati bir rol oynar. Bu sistemlerin güvenilir, verimli ve sürdürülebilir bir şekilde işlemesi, enerji arz güvenliği ve ekonomik kalkınma için vazgeçilmezdir. Teknolojik yenilikler ve enerji politikaları, güç sistemlerinin performansını artırmak ve çevresel etkilerini azaltmak için önemli fırsatlar sunmaktadır.

3.1. Güç Sistemlerinin Matematiksel Temsili

Elektriksel güç sistemlerinde, elektrik enerjisi üretimi, iletimi ve tüketimi sırasında çeşitli büyüklükler arasında matematiksel ilişkiler bulunmaktadır. Bu ilişkiler, enerji akışını anlamak, sistem verimliliğini değerlendirmek ve enerji kayıplarını hesaplamak için kritik öneme sahiptir. Güç hesaplamaları, özellikle alternatif akım (AC) sistemlerinde, voltaj, akım ve güç arasındaki ilişkiyi ifade eden matematiksel denklemlerle modellenir.

Alternatif akım sistemlerinde, aktif güç (P) şu şekilde hesaplanır:

$$P = V * I * \cos(\phi) \quad (3.1)$$

Reaktif güç (Q), enerjinin depolanma ve serbest bırakılma süreçlerini temsil eder ve şu formülle ifade edilir:

$$Q = V * I * \sin(\phi) \quad (3.2)$$

Görünür güç (S), sistemin toplam güç kapasitesini temsil eder ve aktif güç ile reaktif gücün bir kombinasyonu olarak tanımlanır:

$$S = \sqrt{P^2 + Q^2} \quad (3.3)$$

Bu denklemler, enerji akışının detaylı analizine olanak tanır. Aktif güç, iş yapan enerji miktarını ifade ederken, reaktif güç manyetik alanlar gibi enerji depolama süreçlerini açıklar. Görünür güç ise sistemin toplam yükünü belirler.

Güç faktörü (Power Factor, PF), aktif gücün toplam güce oranıdır ve sistemin verimliliğini değerlendirmek için kullanılır:

$$PF = \frac{P}{S} = \cos(\phi) \quad (3.4)$$

Güç faktörü 1'e ne kadar yakınsa, sistemin verimliliği o kadar yüksektir. Düşük bir güç faktörü, sistemde fazla miktarda reaktif güç bulunduğunu ve bu durumun enerji kayıplarına yol açabileceğini gösterir. Bu nedenle, endüstriyel uygulamalarda kompanzasyon sistemleri gibi yöntemlerle güç faktörünün artırılması önemlidir.

Bu temel matematiksel modeller, güç sistemlerinin performansını analiz etmek, yük akışını optimize etmek ve enerji kayıplarını azaltmak için vazgeçilmezdir. Ayrıca, bu denklemler enerji yönetimi stratejilerinin geliştirilmesinde ve güç sistemlerinin ekonomik analizi yapılırken temel alınan önemli araçlardır.

3.2. Enerji İletim Hatları

Enerji iletim hatları, elektrik enerjisinin üretim merkezlerinden uzak tüketim noktalarına taşınmasında merkezi bir role sahiptir. İletim sistemleri genellikle yüksek gerilim seviyelerinde çalışır, çünkü elektrik iletiminin yüksek voltajda gerçekleştirilmesi enerji kayıplarını minimize eder. Yüksek gerilim, enerji iletiminde daha düşük akım değerleriyle aynı enerji miktarının taşınmasına olanak tanır ve Joule yasasına göre, hat boyunca meydana gelen ısı kayıplarını önemli ölçüde azaltır [45]. Bu nedenle, iletim hatlarının uzunluğu arttıkça, genellikle daha yüksek gerilim seviyelerine ihtiyaç duyulur.

Yüksek gerilim kullanımı, enerji iletim hatlarının mesafe kapasitesini artırırken, bu hatlar genellikle açık hava iletim hatları (overhead lines) olarak inşa edilir. Açık hava hatları, maliyet etkinliği ve geniş alanlarda enerji taşınması açısından avantajlıdır [47]. Bununla birlikte, şehir içi bölgelerde veya coğrafi kısıtlamaların olduğu durumlarda yer altı iletim hatları tercih edilebilir. Yer altı kabloları, açık hava hatlarına kıyasla daha yüksek maliyetlere sahip olmasına rağmen, estetik, güvenlik ve yerleşim yoğunluğu açısından önemli avantajlar sunar [48].

Enerji iletim hatlarının tasarımı yalnızca gerilim seviyesini değil, aynı zamanda elektriksel parametreleri de dikkate alır. Direnç, endüktans ve kapasitans gibi parametreler, enerji kayıplarını ve sistem performansını doğrudan etkiler. Direnç, enerji kayıplarının temel kaynağıdır; buna karşın endüktans ve kapasitans, gerilim dalgalanmalarına ve reaktif güç gereksinimlerine yol açar. Bu nedenle, iletim hatlarının tasarımında bu parametrelerin optimum seviyelerde tutulması, enerji kayıplarının azaltılması ve sistem verimliliğinin artırılması için kritik önemdedir.

İletim hatlarının bir diğer önemli bileşeni koruma sistemleridir. Bu sistemler, aşırı yüklenme, kısa devre ve benzeri durumlarda hattın güvenliğini sağlamak için otomatik olarak devreye girer. Koruma sistemleri, sistem güvenilirliğinin ve sürekliliğinin korunmasında hayati bir rol oynar [49]. Ayrıca, iletim hatlarının düzenli olarak izlenmesi ve bakımı, arıza durumlarında geniş alanlardaki enerji dağılımının etkilenmesini önlemek için kritik önemdedir.

Sonuç olarak, enerji iletim hatları, elektrik enerjisinin verimli ve güvenli bir şekilde taşınmasında temel bir unsur olarak öne çıkar. Yüksek gerilim iletim teknolojileri, enerji kayıplarını azaltmanın yanı sıra, uzun mesafelerde enerji taşınmasını mümkün kılar. Bununla birlikte, hattın uzunluğu, gerilim seviyesi ve elektriksel parametreler, hatların tasarımında dikkate alınması gereken temel unsurlardır. Enerji iletim sistemlerinin bütünlüğü, doğru tasarım ve etkin işletme ile sağlanabilir.

3.2.1. Kısa mesafeli iletim hatları

Kısa mesafeli iletim hatları, genellikle 100 km veya daha kısa mesafelerde elektrik enerjisinin iletiminde kullanılan hatlar olarak tanımlanır. Bu hatların tasarımı ve analizi, enerji kayıplarının ve gerilim düşümlerinin minimum seviyede tutulması amacıyla detaylı bir mühendislik yaklaşımı gerektirir [45]. Kısa mesafeli hatların temel özelliği, hattın elektriksel parametrelerinin (özellikle endüktans (L) ve

kapasitans (C)) genellikle ihmal edilebilir seviyelerde olmasıdır. Bu durum, kısa hatların analizi için daha basitleştirilmiş modellerin kullanılmasını sağlar.

3.2.1.1. Kısa mesafeli hatların elektriksel modeli

Kısa iletim hatları, hat boyunca endüktans ve kapasitans etkilerinin sınırlı olduğu varsayımıyla, yalnızca hat direncinin (R) ve hat reaktansının (X) hesaba katıldığı bir model ile analiz edilir. Hat boyunca akımın sabit olduğu kabul edilir ve bu hatlar bir seri empedans modeliyle temsil edilir. Bir kısa iletim hattının toplam empedansı şu şekilde ifade edilir:

$$PZ = R + jX \quad (3.5)$$

Burada:

R, hattın direnç bileşenini (Ω) ifade eder,

$X=\omega L$, endüktif reaktansı (Ω) temsil eder ve burada $\omega=2\pi f$ hattın çalışma frekansını ifade eder.

Gerilim düşümü (ΔV) ve güç iletiminde kayıplar, hat empedansı kullanılarak aşağıdaki denklemlerle hesaplanabilir:

$$\Delta V = I * Z = I(R + jX) \quad (3.6)$$

Bu denklem, hattın uçlarındaki gerilim farkını kompleks biçimde ifade eder. Burada I, iletilen akımı (A) temsil eder. Gerilim düzenlemesi (voltage regulation), kısa hatlardaki önemli bir performans metriğidir ve şu şekilde tanımlanır:

$$\text{Gerilim Düzenlemesi}(\%) = \frac{|V_{\text{yüksüz}} - V_{\text{tam yüklü}}|}{V_{\text{tam yüklü}}} * 100 \quad (3.7)$$

Bu oran, hattın yük altında ve boşta çalışma durumlarındaki gerilim farkının yük altındaki gerilime oranını gösterir. Gerilim düzenlemesi ne kadar düşükse, hattın performansı o kadar iyi kabul edilir.

3.2.1.2. Güç akışı ve verimlilik

Kısa iletim hatlarında iletilen aktif güç (P) ve reaktif güç (Q), hattın uçlarındaki gerilim (V_s, V_r) ve empedans parametrelerine göre aşağıdaki denklemlerle hesaplanır:

$$P = \frac{V_s V_r}{X} \sin(\delta) \quad (3.8)$$

$$Q = \frac{V_s(V_s - V_r \cos(\delta))}{X} \quad (3.9)$$

Burada:

V_s : Gönderici uçtaki gerilim (kV),

V_r : Alıcı uçtaki gerilim (kV),

δ : Gerilim açıları arasındaki fark.

Güç kayıpları, hat direnci göz önüne alınarak şu şekilde ifade edilir:

$$P_{kayıp} = I^2 R \quad (3.10)$$

Hat verimliliği (η), iletilen güç ile kayıp gücün oranı olarak hesaplanır:

$$\eta = \frac{P_{load}}{P_{load} + P_{kayıp}} * 100 \quad (3.11)$$

Bu denklemler, kısa mesafeli hatların performansını analiz etmek için önemli bir temel sağlar.

Kısa mesafeli hatlarda reaktif güç (Q) gereksinimi genellikle düşüktür; ancak yük karakteristiklerine bağlı olarak gerilim kontrolü için reaktif güç dengeleme cihazları kullanılabilir. Şönt kapasitörler, kısa hatlarda gerilim seviyelerini stabilize etmek ve güç faktörünü iyileştirmek için yaygın olarak kullanılan cihazlardır.

3.2.2. Orta mesafeli iletim hatları

Orta mesafeli iletim hatları, 100 km ile 250 km arasındaki mesafelerde elektrik enerjisinin taşınması için kullanılan hatlar olarak tanımlanır. Bu mesafeler, hattın elektriksel parametrelerinin (özellikle endüktans (L) ve kapasitans (C)) etkilerinin ihmal edilemeyecek kadar önemli hale geldiği bir bölgedir. Bu nedenle, orta mesafeli

hatların analizi, kısa mesafeli hatlardan farklı olarak daha gelişmiş matematiksel modeller gerektirir. Bu hatların tasarım ve işletiminde gerilim düzenlemesi, güç akışı ve kayıpların dikkatlice hesaplanması büyük önem taşır [45].

3.2.2.1. Orta mesafeli hatların elektriksel modeli

Orta mesafeli iletim hatlarının analizinde, "T-modeli" veya " π -modeli" olarak bilinen daha gelişmiş devre modelleri kullanılır. Bu modellerde, hattın kapasitansı hattın uzunluğu boyunca eşit şekilde dağılmış gibi kabul edilmez, bunun yerine kapasitans iki uca şönt olarak yerleştirilir.

Bir orta mesafeli iletim hattının π -modeli aşağıdaki şekilde tanımlanır:

Hat empedansı ($Z=R+jX$), hat boyunca seri olarak yerleştirilir.

Hat kapasitansı ($Y=j\omega C$), hattın başlangıç ve bitiş noktalarına eşit olarak bölünmüş iki şönt devre elemanı olarak modellenir.

Hattın elektriksel parametreleri kullanılarak gerilim ve akım arasındaki ilişkiler şu şekilde ifade edilir:

$$I_s = YV_s + I \quad (3.12)$$

$$V_r = V_s - ZI \quad (3.13)$$

Burada:

V_s : Gönderici uç gerilimi (kV),

V_r : Alıcı uç gerilimi (kV),

I_s : Gönderici uç akımı (A),

I : Hat boyunca taşınan akım (A).

3.2.2.2. Hat sabitleri ve güç akışı denklemleri

Orta mesafeli hatların analizinde hat sabitleri (özellikle iletim sabitleri (A, B, C, D) kullanılır. Hat sabitleri şu şekilde tanımlanır:

$$A = D = 1 + \frac{YZ}{2} \quad (3.14)$$

$$B = Z \quad (3.15)$$

$$C = Y(1 + \frac{YZ}{4}) \quad (3.16)$$

Bu sabitler, hattın giriş ve çıkış uçlarındaki gerilim-akım ilişkisini tanımlar:

$$V_s = AV_r + BI_r \quad (3.17)$$

$$I_s = CV_r + DI_r \quad (3.18)$$

Bu denklemler, gönderici ve alıcı uç parametrelerinin birbirine bağlı olduğu bir sistem oluşturarak enerji akışının hesaplanmasına olanak tanır.

3.2.2.3. Orta mesafeli hatlarda kapasitif ve endüktif etkiler

Orta mesafeli iletim hatlarında kapasitans etkisi, hattın reaktif gücü üzerinde belirgin bir etkiye sahiptir. Bu etki, yük kaybını azaltarak gerilim profillerini stabilize edebilir ancak aynı zamanda kapasitif reaktif güç üretimine neden olabilir. Şönt reaktörler, bu tür kapasitif etkileri dengelemek için kullanılır.

Endüktif etkiler ise gerilim dalgalanmalarına yol açabilir ve hattın faz açısını (δ) etkileyerek güç akışı kapasitesini sınırlar:

$$P = \frac{V_s V_r}{|Z|} \sin(\delta) \quad (3.19)$$

3.2.3. Uzun mesafeli iletim hatları

Uzun mesafeli iletim hatları, genellikle 250 km'nin üzerindeki mesafelerde elektrik enerjisinin taşınması için kullanılan hatlar olarak tanımlanır. Bu mesafelerde, hattın hem seri empedansı ($Z=R+jX$) hem de şönt kapasitansı ($Y=j\omega C$) enerji iletiminde belirgin bir rol oynar. Uzun hatların analizinde, parametrelerin hattın uzunluğuna eşit olarak dağıldığını kabul eden "dağıtılmış parametreler teorisi" kullanılır. Bu durum,

kısa ve orta mesafeli hatlardan farklı olarak daha karmaşık matematiksel modellerin ve diferansiyel denklemlerin kullanılmasını gerektirir [45].

3.2.3.1. Uzun mesafeli hatların elektriksel modeli

Uzun iletim hatlarının analizinde, dağıtılmış parametreler teorisi uygulanır. Hat boyunca gerilim (V) ve akım (I), aşağıdaki diferansiyel denklemlerle tanımlanır:

$$\frac{d^2V}{dx^2} = \gamma^2 V, \frac{d^2I}{dx^2} = \gamma^2 I \quad (3.20)$$

Burada:

x: Hattın uzunluğu (km),

$\gamma = \sqrt{ZY}$: Propagasyon sabiti (m⁻¹),

$Z = R + jX$: Seri empedans (Ω/km),

$Y = j\omega C$: Şönt admittans (S/km).

Bu diferansiyel denklemlerin genel çözümleri, gerilim ve akımın hattın her iki ucundaki değerlerini ilişkilendirir:

$$V(x) = V^+ e^{-\gamma x} + V^- e^{\gamma x} \quad (3.21)$$

$$I(x) = \frac{V^+}{Z_c} e^{-\gamma x} - \frac{V^-}{Z_c} e^{\gamma x} \quad (3.22)$$

Burada:

V^+ : İleri yönlü gerilim dalgası,

V^- : Geri yönlü gerilim dalgası,

$Z_c = \sqrt{\frac{Z}{Y}}$: Karakteristik empedans (Ω).

3.2.3.2. Uzun hatlarda iletim sabitleri

Uzun mesafeli iletim hatlarında iletim sabitleri (A,B,C,D) şu şekilde tanımlanır:

$$A = \cosh(\gamma l) \quad (3.23)$$

$$B = Z_c \sinh(\gamma l) \quad (3.24)$$

$$C = \frac{\sinh(\gamma l)}{Z_c} \quad (3.25)$$

$$D = \cosh(\gamma l) \quad (3.26)$$

Burada l , hattın toplam uzunluğunu temsil eder. Gönderici ve alıcı uç gerilim-akım ilişkisi bu sabitlerle ifade edilir:

$$V_s = AV_r + BI_r \quad (3.27)$$

$$I_s = CV_r + DI_r \quad (3.28)$$

Bu ifadeler, uzun hatların giriş ve çıkış uçları arasındaki enerji akışını tanımlamak için kullanılır.

3.2.3.3. Güç akışı ve dalga yansıması

Uzun hatlarda taşınan aktif güç (P) ve reaktif güç (Q) şu şekilde ifade edilir:

$$P = \frac{V_s V_r}{|Z_c|} \sin(\delta) \quad (3.29)$$

$$Q = \frac{V_s V_r}{|Z_c|} \cos(\delta) - \frac{V_s^2}{|Z_c|} \quad (3.30)$$


Bu denklemlerde δ , gönderici ve alıcı uçlar arasındaki faz açısını temsil eder. Uzun hatlarda dalga yansıması ve rezonans etkileri, güç akışını etkileyebilecek önemli faktörlerdir. Şönt reaktörler ve seri kompensatörler, bu etkileri dengelemek için yaygın olarak kullanılır.

4. MATERYAL VE YÖNTEM

4.1. Yapay Zeka

Yapay Zeka (Artificial Intelligence - AI), makinelerin insan zekasına benzer şekilde algılama, düşünme ve karar verme yeteneklerini kazandığı disiplinler arası bir çalışma alanıdır. Yapay zekanın temelleri, Alan Turing'in 1950 yılında yayımladığı "Computing Machinery and Intelligence" adlı makalesine kadar uzanmaktadır. Turing burada, bir makinenin "düşünebilip düşünemeyeceğini" değerlendirmek için bir test (Turing Testi) önerdi. Günümüzde AI, yalnızca insan zekasını taklit etmekle kalmayıp, çoğu durumda insan performansını aşabilen sistemler geliştirilmesine olanak tanımaktadır. AI araştırmaları, özellikle 1956 yılında Dartmouth Konferansı'nda ortaya çıkan iki temel yaklaşımla şekillenmiştir:

1. Sembolik AI: Matematiksel mantık ve sembolik sistemlere dayanır.
2. Bağlantıcı AI: İnsan beynindeki nöronların çalışma prensiplerinden ilham alarak öğrenen sistemler üzerine odaklanır.



Şekil 4.1. Yapay Zeka Modeli Katmanları.


4.1.1. Yapay sinir ağıları (Artificial Neural Networks - ANN)

Yapay sinir ağıları, bağlantıcı AI'nın bir dalıdır ve insan beyninin sinirsel yapısından esinlenilmiştir. McCulloch ve Pitts tarafından geliştirilen ilk matematiksel model, bir nöronun temel işlevlerini modellemek için tasarlanmıştır. Bu yapı, 1986'da Rumelhart ve arkadaşlarının geri yayılım algoritmasını tanıtmasıyla modern bir forma kavuşmuştur. Yapay sinir ağıları, katmanlar hâlinde organize edilir ve her katman belirli bir işlemi gerçekleştirir:

Girdi Katmanı: Giriş verilerini alır.

Gizli Katmanlar: Verileri dönüştürür ve ilişkilendirme yapar.

Çıkış Katmanı: Tahmin sonuçlarını verir.



Şekil 4.2. Yapay Sinir Ağı Benzetimi.

Bir yapay sinir ağı, aşağıdaki temel matematiksel model ile ifade edilebilir:

$$y = f(Wx + b) \quad (4.1)$$

Burada:

y: Ağın çıktısı,

W: Ağırlık matrisi,

x: Girdi vektörü,

b: Bias terimi,

f: Aktivasyon fonksiyonu.


4.1.2. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, bir nöronun doğrusal olmayan bir şekilde öğrenmesini sağlar. En yaygın kullanılan aktivasyon fonksiyonları şunlardır:

4.1.2.1. Sigmoid

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4.2)$$

Sigmoid fonksiyonu, çıktı değerlerini $[0,1]$ aralığına indirger ve özellikle olasılık tabanlı modellerde kullanılır. Ancak gradyan kaybolma problemi nedeniyle derin ağlarda performansı sınırlıdır.




Şekil 4.3. Sigmoid Fonksiyonu.

4.1.2.2. Tanh (Hiperbolik Tanjant)

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.3)$$

Tanh fonksiyonu, çıktıları $[-1,1]$ aralığında düzenler ve sıfır merkezli bir dağılım sağlar.




Şekil 4.4. Tanh Fonksiyonu.

4.1.2.3. ReLU (Rectified Linear Unit)

$$f(x) = \max(0, x) \quad (4.4)$$

ReLU, hesaplama kolaylığı ve gradyan problemini azaltma avantajıyla en çok tercih edilen fonksiyonlardan biridir.



Şekil 4.5. Relu Fonksiyonu.

4.1.3. Geri yayılım algoritması (Backpropagation)

Geri yayılım algoritması, yapay sinir ağlarının öğrenme sürecinin temelini oluşturur. Ağırlıkların güncellenmesi şu şekilde gerçekleşir:

1. İleri Yönlü Hesaplama: Girdi verisi ağ boyunca iletilir ve çıkışlar hesaplanır.
2. Hata Hesaplama: Kayıp fonksiyonu ($\mathcal{L}$) kullanılarak hedef ve tahmin değerleri arasındaki fark hesaplanır.

$$\mathcal{L} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (4.5)$$


3. Gradyan Hesaplama: Türev zinciri kuralı ile ağırlıkların gradyanları hesaplanır.

$$\frac{\partial \mathcal{L}}{\partial W} = \frac{\partial \mathcal{L}}{\partial y} * \frac{\partial y}{\partial W} \quad (4.6)$$

4. Ağırlık Güncelleme: Gradyan iniş yöntemiyle ağırlıklar güncellenir.

$$W \leftarrow W - \eta \frac{\partial \mathcal{L}}{\partial W} \quad (4.7)$$

Burada η , öğrenme oranıdır.




Şekil 4.6. Yapay Zeka Modelinde Geri Yayılım.

4.1.4. Derin sinir ağları (Deep Neural Networks - DNN)

Derin sinir ağları, çok sayıda gizli katmana sahip yapay sinir ağlarıdır. Bu ağlar, özellikle büyük veri kümelerinde ve karmaşık problemler için etkili bir şekilde öğrenme yapabilir. 2012 yılında AlexNet, derin öğrenmenin görüntü sınıflandırmada insan performansını aşabileceğini göstermiştir.

DNN'lerin eğitiminde karşılaşılan başlıca sorunlardan biri, vanishing/exploding gradient problemidir. Bu sorun, ağırlıkların normalleştirilmesi (Batch Normalization) ve daha iyi aktivasyon fonksiyonları (ör. ReLU, Leaky ReLU) ile çözülebilir.



Şekil 4.7. Örnek DNN Modeli.

4.1.4.1. Doğal dil işleme (NLP)

Transformer modelleri, özellikle dikkat mekanizmasıyla, dil modellemede çığır açmıştır [50].

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (4.8)$$

4.1.4.2. Görüntü işleme

Convolutional Neural Networks (CNN) tabanlı yaklaşımlar, nesne algılama ve görüntü sınıflandırmada yüksek başarı sağlamıştır.

4.1.4.3. Zaman serisi analizi

LSTM ve GRU gibi ağlar, uzun vadeli bağımlılıkları modelleme yeteneğiyle finans, enerji ve biyomedikal uygulamalarda kullanılmaktadır.

4.1.5. Öğrenme çeşitleri

Yapay zeka (YZ) alanındaki öğrenme süreçleri, makine öğrenmesi (ML) algoritmalarının farklı veri türleri ve yapılarına nasıl tepki verdiğini belirler. Temelde üç ana öğrenme türü vardır: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme. Bu öğrenme türleri, veri ve modelin etkileşim biçimlerine göre farklılık gösterir ve her biri belirli problemlerin çözülmesinde etkili olabilir.

4.1.5.1. Denetimli öğrenme (Supervised Learning)

Denetimli öğrenme, en yaygın kullanılan makine öğrenmesi türüdür. Bu öğrenme türü, etiketli veri setleri kullanarak modelin belirli bir problemi çözmesini sağlar. Başka bir deyişle, bu öğrenme türünde her giriş verisi, doğru etiket veya çıkışla eşleştirilir. Modelin amacı, bu eşleşmeler üzerinden bir ilişki öğrenmek ve yeni, daha önce görülmemiş verilere doğru tahminlerde bulunmaktır [51].

Denetimli öğrenmenin en yaygın örnekleri regresyon ve sınıflandırmadır. Regresyon, bağımsız ve bağımlı değişkenler arasındaki ilişkiyi modellemek için kullanılırken (örneğin, ev fiyatı tahminleri), sınıflandırma, verileri önceden belirlenmiş kategorilere ayırmak için kullanılır [52].

Matematiksel olarak denetimli öğrenme, giriş verisi X ile çıktılar y arasında bir ilişki kurmaya çalışır. Bu ilişki, aşağıdaki formülle ifade edilebilir:

$$y = f(X; \theta) \quad (4.9)$$

Burada y , modelin tahmin ettiği çıktıyı, X ise giriş verisini, θ ise modelin öğrenmesi gereken parametreleri ifade eder. Modelin başarısı, genellikle bir "loss" (kayıp) fonksiyonu aracılığıyla değerlendirilir:

$$L(\theta) = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.10)$$

Burada y_i gerçek çıkış, $\hat{y}_i$ ise modelin tahmin ettiği çıktıdır.

4.1.5.2. Denetimsiz öğrenme (Unsupervised Learning)

Denetimsiz öğrenme, etiketlenmemiş verilerle çalışır. Bu öğrenme türünde, model doğrudan etiketli verilerle eğitilmez. Bunun yerine, modelin amacı, veri setinin temel yapısını keşfetmektir. Denetimsiz öğrenme, özellikle veri kümelerindeki gizli yapıları (örneğin, gruplar, sınıflar) belirlemek için kullanılır [53].

En yaygın denetimsiz öğrenme teknikleri kümeleme (clustering) ve boyut indirgeme (dimensionality reduction) algoritmalarını içerir. Kümeleme, verileri benzer özelliklere sahip gruplara ayırmak için kullanılır (örneğin, K-means, DBSCAN).

Boyut indirgeme, verinin daha düşük boyutlu bir temsiline indirgenmesini sağlar (örneğin, Principal Component Analysis - PCA) [54].

Denetimsiz öğrenmede, veri kümeleri genellikle şu şekilde matematiksel olarak ifade edilir:

$$J(\theta) = \sum_{i=1}^n d(x_i, \mu_j) \quad (4.11)$$

Burada x_i veri noktası, μ_j küme merkezi ve d ise mesafe fonksiyonudur.

4.1.5.3. Pekiştirmeli öğrenme (Reinforcement Learning)

Pekiştirmeli öğrenme (RL), bir ajan (agent) ile çevre (environment) arasındaki etkileşime dayalı bir öğrenme türüdür. Ajan, çevresiyle etkileşime girerek bir hedef doğrultusunda davranışlarını öğrenir. Pekiştirmeli öğrenmenin temel bileşenleri, durumlar (states), eylemler (actions) ve ödülleri (rewards) olup, ajan, her bir durumda alacağı eylemi belirler ve bu eylemin sonucunda ödülleri alır.

Pekiştirmeli öğrenmede, ajanların öğrenme süreci, Markov Karar Süreci (Markov Decision Process - MDP) çerçevesinde modellenir [55]. Ajanın hedefi, bir politikanın (policy) öğrenilmesidir, bu politika ajanı en fazla ödülü elde etmeye yönlendirir. Pekiştirmeli öğrenme algoritmalarının temelinden Q-öğrenme (Q-Learning) gibi algoritmalar gelir. Q-öğrenme, aşağıdaki güncelleme kuralı ile ifade edilebilir:


$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \left(r_t + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t) \right) \quad (4.12)$$

Burada $Q(s_t, a_t)$, durum s_t ve eylem a_t için tahmin edilen değer fonksiyonudur. a , öğrenme oranını, r_t ise alınan ödülü temsil eder. γ ise gelecekteki ödülleri ne kadar dikkate alacağımızı belirleyen indirim faktörüdür.

4.2. K-En yakın komşu (KNN) algoritması

k-En Yakın Komşuluk (k-NN) algoritması, parametrik olmayan bir makine öğrenimi yöntemi olarak veri bilimi, istatistik ve yapay zeka uygulamalarında yaygın şekilde kullanılan temel algoritmalarından biridir [56]. Eğitim süreci gerektirmeyen, ancak test aşamasında tüm veri seti üzerinden işlem yaparak tahminlerde bulunan bu algoritma,

basitliđi ve etkili performansı ile dikkat eker [57]. Bu blmde, k-NN algoritmasının temel yapısı, matematiksel temelleri detaylı bir řekilde ele alınmıřtır.



řekil 4.8. KNN Modelinin alıřma Prensihi.

k-NN algoritmasının parametrik olmayan dođası, herhangi bir veri dađılımı varsayımına gerek duyulmaması anlamına gelir. Bu zelliđi, algoritmayı karmařık veya dođrusal olmayan veri kmelerinde etkili hale getirir [58]. Eđitim sırasında herhangi bir model oluřturulmadıđı iin k-NN, genellikle "eđitimsiz đrenme" (lazy learning) algoritması olarak sınıflandırılır. Bununla birlikte, bu durum, algoritmanın test ařamasında daha yksek hesaplama maliyetine sahip olmasına neden olur.


4.2.1. Mesafe metrikleri ve matematiksel temeller

k-NN algoritmasının performansı, byk lde veri noktaları arasındaki mesafeyi lmek iin kullanılan metriđe bađlıdır. En yaygın mesafe metrikleri řunlardır:

1. ,Euclidean Mesafesi (L2 Normu): İki veri noktası x ve y arasındaki Euclidean mesafesi, klid uzayındaki dođrusal mesafeyi temsil eder

$$d(x, y) = i = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.13)$$

Bu metrik, genellikle srekli ve normal dađılımlı zelliklerde etkili sonu verir.




Şekil 4.9. Mesafe Metriklerinin Görselleştirilmesi.

2. Manhattan Mesafesi (L1 Normu): Öznitelikler arasındaki farkların mutlak değerlerinin toplamını temel alır.

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (4.14)$$

Daha az duyarlı olduğu için, gürültülü veri setlerinde Euclidean mesafesine göre daha iyi performans gösterebilir [52].



Şekil 4.10. Manhattan Mesafesi.

3. Minkowski Mesafesi (Genel Form): Euclidean ve Manhattan mesafelerini birleştiren genel bir formüldür.

$$d(x, y) = \sqrt[p]{\sum_{i=1}^n |x_i - y_i|^p} \quad (4.15)$$

Burada p, metriğin parametresidir. p=1 Manhattan, p=2 ise Euclidean mesafesini verir.

4. Mahalanobis Mesafesi: Çok boyutlu veri setlerinde özellikler arasındaki korelasyonu dikkate alır.

$$d(x, y) = \sqrt{(x - y)^T * S^{-1}(x - y)} \quad (4.16)$$

Burada S, veri setinin kovaryans matrisidir. Bu metrik, farklı ölçeklerdeki değişkenlere sahip veri setleri için uygundur [59].

4.2.2. KNN algoritmasının işleyiş adımları

k-NN algoritmasının işleyiş süreci aşağıdaki şekilde özetlenebilir:

1. Eğitim Aşaması: Eğitim veri seti, herhangi bir model oluşturulmadan bellekte saklanır.
2. Mesafe Hesaplama: Test noktası x_t ile tüm eğitim noktaları arasındaki mesafeler hesaplanır.
3. Komşuların Belirlenmesi: k en küçük mesafeye sahip komşu seçilir. Eğer k değeri çift ise, oy eşitliği durumunda bir yöntem belirlenmelidir.
4. Sınıf Tahmini:
 - Sınıflandırma: Komşuların sınıflarına göre bir oy çoğunluğu hesaplanır.
 - Regresyon: Komşuların hedef değerlerinin ağırlıklı ortalaması alınır.

$$\hat{y} = \frac{\sum_{i=1}^k w_i * y_i}{\sum_{i=1}^k w_i} \quad (4.17)$$

Burada $w_i = \frac{1}{d(x_i, x_t) + \epsilon}$ ile ağırlıklar hesaplanır (ϵ , sıfır bölmeyi önlemek için kullanılan küçük bir sabittir).


4.2.3. Parametre seçimi ve optimizasyon

1. k Değerinin Seçimi: Küçük bir k değeri, modelin varyansını artırabilirken, büyük bir k değeri genelleme yeteneğini düşürebilir [60]. Çapraz doğrulama, optimal k değerinin belirlenmesinde yaygın olarak kullanılır.
2. Öznitelik İndirgeme: Yüksek boyutlu veri setlerinde öznitelik seçimi, algoritmanın performansını artırabilir. Bu amaçla temel bileşen analizi (PCA) veya doğrusal ayırım analizi (LDA) gibi yöntemler kullanılabilir.

3. Ağırlıklı k-NN: Uzak komşuların katkısını azaltmak için ağırlıklandırma stratejileri uygulanabilir. Mesafeye dayalı ağırlıklandırma, performansı artırabilir [61].

4.3. Destek Vektör Makineleri (Support Vector Machines - SVM)

Destek Vektör Makineleri (SVM), gözetimli öğrenme algoritmalarından biri olarak, sınıflandırma ve regresyon problemlerinde yüksek performans sergileyen ve güçlü teorik temellere dayanan bir yöntemdir. 1990'larda Cortes ve Vapnik tarafından geliştirilen SVM, özellikle yüksek doğruluk, düşük overfitting (aşırı öğrenme) riski ve küçük veri setlerinde bile etkili çalışma kapasitesi ile dikkat çekmiştir. Bu bölümde, SVM'in matematiksel temelleri, uygulama alanları, avantajları, dezavantajları ve parametre optimizasyonuna dair detaylı bir açıklama yapılacaktır.



Şekil 4.11. Destek Vektör Makineleri.

4.3.1. Matematiksel temeller ve hedef fonksiyon

SVM, veri setindeki verileri sınıflandırmak için bir hiper düzlem bulma amacını güder. Bu hiper düzlem, sınıflar arasındaki marjı (yani, veri noktalarına olan uzaklık) maksimize eder. Matematiksel olarak, hiper düzlem şu şekilde ifade edilir:

$$w * x + b = 0 \quad (4.18)$$

Burada, w ağırlık vektörünü, x veri noktalarını ve b sabit terimini ifade eder. Bu düzlemi seçmenin amacı, sınıflar arasındaki en küçük mesafeyi (marjı) maksimize etmektir. Sınıflar arasındaki mesafe, şu şekilde hesaplanabilir:

$$Marj = \frac{2}{||w||} \quad (4.19)$$

Buradan yola çıkarak, SVM, aşağıdaki optimizasyon problemine dönüşür [62]

$$\min_{w,b} \frac{1}{2} ||w||^2 \quad (4.20)$$

Kısıtlar ise, her bir veri noktası için şu şekilde tanımlanır:

$$y_i * (w * x_i + b) \geq 1, \quad (4.21)$$

Burada y_i her bir veri noktasının sınıf etiketini (pozitif veya negatif), x_i ise veri noktalarını ifade eder. Bu optimizasyon probleminde, w vektörü, doğru sınıflandırmayı en iyi sağlayacak şekilde seçilir.

4.3.2. Lagrange çarpanları

Bu optimizasyon problemini çözmek için Lagrange çarpanları kullanılır. Lagrange fonksiyonu şu şekilde yazılabilir:

$$L(w, b, \alpha) = \frac{1}{2} ||w||^2 - \sum_{i=1}^n \alpha_i * [y_i * (w * x_i + b) - 1] \quad (4.22)$$

Bu formülde α_i çarpanları, her veri noktasının katkısını belirler. Lagrange çarpanlarının, yalnızca destek vektörleri üzerinde sıfırdan farklı değerler aldığı


unutulmamalıdır. Bu, destek vektörlerinin modelin oluşturulmasında kritik öneme sahip olduğu anlamına gelir.

4.3.3. Kernel fonksiyonları ve doğrusal olmayan ayrılabilirlik

SVM, doğrusal olmayan veri kümelerinde de etkili bir şekilde çalışabilir. Kernel yöntemleri sayesinde, veriler daha yüksek boyutlu bir uzaya dönüştürülerek doğrusal ayrılabilir hale getirilir. Kernel fonksiyonları, verilerin bu yüksek boyutlu uzaya haritalanmasını sağlar ve doğrusal sınıflandırma yapılabilmesi için uygun bir ortam oluşturur [63].

En yaygın kullanılan kernel fonksiyonları şunlardır:

- **Doğrusal Kernel:** $K(x_i, x_j) = x_i * x_j$, verilerin doğrusal olduğu durumlarda kullanılır.
- **Polinom Kernel:** $K(x_i, x_j) = (x_i * x_j + c)^d$, doğrusal olmayan ilişkiler için uygundur.




Şekil 4.12. Polinom Kernelin Görselleştirilmesi.

- **RBF (Radial Basis Function) Kernel:** $K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$ özellikle karmaşık veri setlerinde etkili olur.
- **Sigmoid Kernel:** $K(x_i, x_j) = \tanh(ax_i * x_j + c)$, sinir ağları ile benzer özellikler gösterir.

4.3.4. Parametre optimizasyonu ve apraz doęrulama

SVM modelinin performansı, büyük ölçüde doęru hiperparametre ayarlarına baęlıdır. İki önemli parametre olan C ve kernel parametrelerinin optimizasyonu, genellikle Grid Search veya Bayesian Optimization gibi yöntemlerle yapılır. Ayrıca, modelin genelleme yeteneęini artırmak için apraz doęrulama sıka kullanılır. Bu yöntem, modelin farklı alt veri setlerinde eęitilmesi ve test edilmesi sürecini ierir, böylece modelin aşırı öğrenme riski azalır.





Şekil 4.13. apraz Doğrulamanın Görselleştirilmesi.

4.4. Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM)

Uzun Kısa Süreli Bellek (LSTM), Recurrent Neural Networks (RNN) mimarisinin bir uzantısı olarak, ardışık verilerde uzun vadeli baęımlılıkların modellenmesi sorununa yeniliki bir çözüm getiren bir yapıdır. İlk kez Hochreiter ve Schmidhuber (1997) tarafından tanıtılmıştır. Zaman serileri, doğal dil işleme (NLP), biyomedikal sinyal işleme ve dięer ardışık veri problemlerinde yaygın olarak kullanılır. LSTM'nin başarısı, özellikle kaybolan gradyan (vanishing gradient) problemini çözmek ve bilgi kaybını önlemek için tasarlanmış olan özel hücre yapısından kaynaklanmaktadır.

4.4.1. Matematiksel temeller ve model yapısı

LSTM'nin temel birimi, veri akışını kontrol eden üç kapıya sahip bir hücredir: Unutma Kapısı (Forget Gate), Giriş Kapısı (Input Gate) ve Çıkış Kapısı (Output Gate). Bu kapılar, hem geçmişten gelen hem de mevcut girdi bilgilerini işleyerek hücre durumunu (C_t) ve gizli durumu (h_t) günceller.



Şekil 4.14. LSTM Yapısı.

4.4.1.1. Unutma kapısı

Unutma kapısı, önceki hücre durumundan (C_{t-1}) hangi bilginin korunacağını veya silineceğini belirler. Sigmoid aktivasyon fonksiyonu, unutulacak bilgiyi belirlemek için kullanılır:

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (4.23)$$

Burada:

- f_t : Unutma kapısının çıktısı (0 ile 1 arasında değer alır),
- W_f : Ağırlık matrisi,
- b_f : Bias terimi,
- σ : Sigmoid fonksiyonu.

4.4.1.2. Giriş kapısı ve aday hücre durumu

Giriş kapısı, mevcut zaman adımındaki bilginin ne kadarının hücre durumuna ekleneceğini kontrol eder. İlk olarak, sigmoid fonksiyonu girdi bilgisine (x_{tx_txt}) ne kadar önem verileceğini belirler:

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (4.24)$$

Ardından, aday hücre durumu ($\hat{C}_t$) tanh fonksiyonu ile oluşturulur.

$$\hat{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (4.25)$$

Son olarak, mevcut hücre durumu (C_t) aşağıdaki gibi güncellenir:

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (4.26)$$

Bu işlem, geçmişten gelen ve yeni bilginin hücre durumunda birleştirilmesini sağlar.

4.4.1.3. Çıkış kapısı ve gizli durum

Çıkış kapısı, hücre durumunun hangi kısmının çıkış olarak verilmesi gerektiğini kontrol eder. Çıkış kapısının aktivasyonu:

$$o_t = \sigma * (W_o * [h_{t-1}, x_t] + b_o) \quad (4.27)$$

Hücre durumunun tanh aktivasyonu ile gizli durum (h_t) hesaplanır:

$$h_t = o_t * \tanh(C_t) \quad (4.28)$$

4.4.2. Kernel fonksiyonları

LSTM, verileri işlemek için doğrusal olmayan dönüşümler gerçekleştirir ve zaman serisi analizlerinde, sinyal işleme uygulamalarında güçlü bir araçtır. Örneğin:

- W_f, W_i, W_o, W_c ağırlık matrisleri, veri özelliklerini belirlemek için optimize edilir.
- Gizli katmanlardaki bilgilerin sıralı bağımlılığı korunur.

LSTM'nin hesaplamalarında, zaman adımı boyunca hücre durumu (C_t) ve gizli durum (h_t) yeniden değerlendirilir. Bu yapı, LSTM'yi klasik RNN'lerden daha esnek hale getirir [64].

4.4.3. Hiperparametre seçimi ve model optimizasyonu

LSTM'nin performansı, doğru hiperparametre seçimine bağlıdır:

- **Zaman Adımları:** Zaman serisi uzunluğu (T).
- **Hücre Sayısı:** Gizli katmandaki hücrelerin sayısı.
- **Öğrenme Oranı ve Dropout Oranı:** Modelin aşırı öğrenmesini önlemek için optimize edilir.
- **Optimizasyon Algoritmaları:** Adam veya RMSprop gibi algoritmalar kullanılarak gradyanlar güncellenir.

Ayrıca, hiperparametre optimizasyonu için Grid Search veya Optuna gibi araçlar kullanılabilir [30].

5. DENEYSEL ÇALIŞMALAR

5.1. Veri Setinin Hazırlanması


Bu çalışmada kullanılan veri seti, ferreazonans olaylarını tespit etmeye yönelik olarak MATLAB ortamında oluşturulmuştur. Veri seti, toplamda sekiz farklı ferreazonans durumu ile bir normal durumdan oluşmaktadır. Ferreazonans durumları, sistemdeki gerilim ve akım dalga şekillerindeki bozulmaların çeşitli şekillerde ortaya çıkmasını simüle eden parametreler ile oluşturulmuştur. Her bir ferreazonans durumu, normal duruma göre belirli bir bozulma seviyesini içermektedir.

Öncelikle, normal duruma ait veri seti oluşturulmuş ve ardından MATLAB kullanılarak ferreazonans durumları simüle edilmiştir. Her bir ferreazonans durumu için, sistemdeki çeşitli parametreler değiştirilerek farklı ferreazonans koşullarında meydana gelen dalga şekilleri elde edilmiştir. Bu veriler, zaman domeninde incelenerek ferreazonans olaylarının karakteristik özellikleri belirlenmiştir. Son olarak, elde edilen veriler CSV formatında kaydedilmiş ve ilerleyen analizler için hazır hale getirilmiştir.

Bu veri seti, KNN, SVM ve LSTM gibi makine öğrenmesi modellerine uygulanarak ferreazonans tespiti ve normal durumu ayırt etme konusunda deneysel çalışmalara olanak sağlamaktadır.

5.1.1. Normal durum için veriseti oluşturulması


Bu görsel, ferreazonansın gözlemlenmediği normal çalışma koşullarını temsil etmektedir. Normal durumda, sistemde herhangi bir kararsızlık veya aşırı dalgalanma görülmemektedir. Dalgalanmalar düzenli ve öngörülebilir bir şekilde seyreder. Akım ve gerilim sinyalleri, sistemin normal çalışma koşullarına uygun olarak, belirli bir frekansta ve genlikte stabil bir şekilde devam eder. Bu durum, sistemin dengeli ve sağlıklı çalıştığını, herhangi bir bozulma veya anormallik bulunmadığını gösterir. Normal çalışma koşullarında, sistemin verimliliği yüksek olup, enerji kayıpları minimum düzeydedir.



Şekil 5.1. Ferrerezonansız Sinüsoidal Dalga.


5.1.2. Farklı ferrerezonans durumu için veriseti oluşturulması

Bu bölümde, 8 farklı ferrerezonans durumu görsel olarak sunulmuştur. Her bir görsel, ferrerezonansın farklı bir aşamasını temsil etmektedir. Aşağıda, her bir görselin içeriği ve özelliği anlatılmaktadır:




Şekil 5.2. 1 Numaralı Özelliklere Göre Ferrerezonans.

Bu görselde, ferrerezonansın ilk gözlemleri yer almaktadır. Dalgalandırmalar başlangıçta yavaş ve düzenli bir şekilde gelişmekte, ancak zamanla belirgin bir farklılık göstermeye başlamaktadır.




Şekil 5.3. 2 Numaralı Özelliklere Göre Ferrerezonans.

İkinci görselde, ferrerezonans durumu biraz daha belirginleşmiş ve salınımlar daha belirgin hale gelmiştir. Dalgalanmalar daha yüksek genliklere ulaşmaya başlamıştır.




Şekil 5.4. 3 Numaralı Özelliklere Göre Ferrerezonans.

Üçüncü görselde, dalgalanmaların şekli daha karmaşık bir hale gelmiştir. Akım ve gerilimdeki dalgalanma oranı artmış ve sistemin davranışı daha düzensiz bir hale gelmiştir.




Şekil 5.5. 4 Numaralı Özelliklere Göre Ferrerezonans.

Bu görselde, ferrerezonansın güçlü bir şekilde hissedildiği bir durum gözlemlenmektedir. Dalgalanma genlikleri oldukça yüksek olup, sistemin kararsız bir hale gelmeye başladığını gösterir.




Şekil 5.6. 5 Numaralı Özelliklere Göre Ferrerezonans.

Beşinci görselde, sistemdeki salınımlar daha da kaotik bir hal almıştır. Bu, ferrerezonansın daha şiddetli olduğu ve sistemin daha karmaşık bir dinamik sergilediği bir durumu yansıtır.




Şekil 5.7. 6 Numaralı Özelliklere Göre Ferrerezonans.

Altıncı görselde, ferrerezonansın ileri seviyeye geçtiği ve enerji salınımlarının çok daha belirgin olduğu bir durum izlenmektedir. Dalgalanmalar sistemin kararsızlığını gösterir.



Şekil 5.8. 7 Numaralı Özelliklere Göre Ferrerezonans.

Yedinci görselde, dalgalanmalar hızlı bir şekilde artmış ve sistem çok daha şiddetli bir şekilde kararsız hale gelmiştir. Bu aşama, ferrerezonansın kontrolsüz bir seviyeye geldiğini gösterir.




Şekil 5.9. 8 Numaralı Özelliklere Göre Ferrerezonans.

Son görselde, ferrerezonansın maksimum seviyeye ulaştığı ve sistemin çok büyük dalgalanmalar gösterdiği bir durum gözlemlenmektedir. Bu, ferrerezonansın en uç seviyesini ve sistemin en yüksek kararsızlık noktasını ifade eder

5.2. Model Performans Değerlendirilmesi


5.2.1. KNN modeli performans değerlendirilmesi



Şekil 5.10. KNN Modeli Sonrasında PCA.

PCA (Principal Component Analysis) ile yapılan boyut indirgeme işleminde elde edilen görselleştirme, KNN modelinin sınıflar arasındaki ilişkiyi nasıl öğrenip öğrendiğini görsel olarak sunmaktadır. PCA görselleştirmesinde her bir veri noktası, iki ana bileşene (principal components) indirilmiştir ve her bir sınıf, farklı renklerle işaretlenmiştir.

PCA sonuçlarına göre, bazı sınıfların birbirine daha yakın olduğu ve bazı sınıfların daha belirgin bir şekilde ayrıldığı gözlemlenebilir. Örneğin, sınıf 1 ve sınıf 2 arasındaki dağılım, birbirine oldukça yakınken, sınıf 0 ile sınıf 4 gibi sınıfların daha uzak olduğu dikkat çekiyor. Bu durum, sınıflar arasındaki sınırların ne kadar belirgin olduğunu ve KNN modelinin bu sınıfları ayırt etme yeteneğini yansıtır. KNN modelinin doğruluğu, genellikle bu tür görsel ayırt edicilik ile doğru orantılıdır. Eğer sınıflar net bir şekilde ayrılmışsa, modelin doğru tahmin yapma olasılığı artar.



Şekil 5.11. KNN Modelinin Karmaşıklık Matrisi.

Confusion matrix, modelin her sınıf için doğruluğunu detaylı bir şekilde değerlendirmemizi sağlar. Verilen confusion matrix sonuçları üzerinden, her bir sınıfın ne kadar doğru tahmin edildiğini gözlemleyebiliriz.

Özellikle dikkat edilmesi gereken noktalar:

Sınıf 1 için yüksek Precision ve Recall değerleri gözlemleniyor. Bu, modelin bu sınıfı doğru bir şekilde sınıflandırmada oldukça başarılı olduğunu gösteriyor.

Sınıf 3 için ise düşük Precision (0.59) ve orta seviyede Recall (0.76) değerleri bulunuyor. Bu, modelin sınıf 3 için gereksiz yere fazla negatif tahmin (False Positives) yaptığı anlamına gelir. Bu sınıfın daha fazla veri ile eğitilmesi veya modelin yeniden yapılandırılması gerekebilir.

Sınıf 5 için, düşük Recall değeri (0.55) dikkat çekiyor. Bu, modelin bu sınıfı doğru şekilde sınıflandırmada zorluk çektiğini ve bazı True Positives'leri kaçırdığını gösterir. Bu sınıf, daha fazla özen gösterilmesi gereken bir alan olabilir.

Confusion matrix'inin detaylı analizi, hangi sınıfların doğru ve yanlış sınıflandırıldığını net bir şekilde ortaya koyar. Ayrıca, False Positives ve False Negatives arasındaki dağılım, modelin hangi sınıflarda daha fazla hata yaptığı hakkında fikir verir. Sınıf 0, sınıf 4 ve sınıf 6 gibi sınıflar, genellikle doğru sınıflandırılmışken, sınıf 5 ve sınıf 3 gibi sınıflar hatalı sınıflandırmalarla karşılaşmıştır.

Classification Report:				
	precision	recall	f1-score	support
0	0.83	0.96	0.89	1222
1	0.98	0.98	0.98	1280
2	0.91	0.93	0.92	1120
3	0.59	0.76	0.67	1174
4	0.70	0.67	0.68	1224
5	0.77	0.55	0.64	1191
6	0.99	0.85	0.92	1213
accuracy			0.82	8424
macro avg	0.82	0.82	0.81	8424
weighted avg	0.82	0.82	0.82	8424
True Labels Predicted Labels				
0	2	2		
1	4	4		
2	3	3		
3	6	6		
4	4	4		
Test Accuracy: 0.8160				

Şekil 5.12. KNN Modelinin Sınıflandırma Raporu.

Classification report, modelin performansını her bir sınıf için ayrıntılı olarak sunar. Burada Precision, Recall ve F1-Score metrikleri, KNN modelinin her sınıf üzerindeki başarı oranını gösterir.

Precision (Hassasiyet): Precision, modelin tahmin ettiği pozitif örneklerin ne kadarının doğru olduğunu belirtir. Sınıf 1 ve Sınıf 6 için yüksek Precision değerleri (0.98 ve 0.99) dikkat çekiyor, bu da modelin bu sınıflarda gereksiz yere yanlış sınıflandırma yapmadığını gösteriyor. Öte yandan, Sınıf 3 için düşük Precision (0.59), modelin bu sınıfı sıklıkla yanlış pozitif sınıflandırdığını işaret eder.


Recall (Duyarlılık): Recall, modelin doğru pozitifleri bulma yeteneğini ölçer. Sınıf 1 ve Sınıf 2 için yüksek Recall değerleri (0.98 ve 0.93) gözlemleniyor, bu da modelin bu sınıflardaki örnekleri doğru şekilde ayırt ettiğini gösteriyor. Ancak Sınıf 5 için düşük Recall değeri (0.55), modelin bu sınıfı doğru şekilde tanımlamada zorluk çektiğini ve bu sınıfın fazla sayıda yanlış negatif (False Negatives) verdiğini gösteriyor.

F1-Score: F1-Score, Precision ve Recall'un harmonik ortalamasıdır ve her iki metriğin bir arada değerlendirilmesini sağlar. Yüksek F1-Score değerleri, modelin her iki metrikte de iyi performans gösterdiğini işaret eder. Sınıf 1 için F1-Score değeri 0.98, Sınıf 2 için ise 0.92'dir, bu da bu sınıflarda modelin dengeli bir şekilde doğruluk ve duyarlılık sağladığını gösterir. Ancak Sınıf 3 ve Sınıf 5 için düşük F1-Score değerleri (0.67 ve 0.64) mevcut, bu da modelin bu sınıflarda zayıf performans gösterdiğini belirtir.


Son olarak, accuracy (doğruluk) değerinin 0.82 olması, modelin genel performansının iyi olduğunu, ancak belirli sınıflarda iyileştirme yapılması gerektiğini ortaya koyar. Macro average ve weighted average değerlerinin 0.82 ve 0.82 olması, modelin genel performansının dengeli olduğunu ancak bazı sınıfların daha fazla iyileştirilmeye ihtiyaç duyduğunu gösterir.

Test accuracy değeri %81.6 olarak belirlenmiştir. Bu, modelin test veri seti üzerinde de yüksek doğruluk oranı ile çalıştığını gösterir. Ancak, özellikle düşük doğruluğa sahip sınıflarda iyileştirmeler yapılması, modelin genel başarısını artıracaktır.

5.2.2. SVM modeli performans değeriendirilmesi



Şekil 5.13. SVM Modeli Sonrası PCA



Şekil 5.14. SVM Modelinin Karmaşıklık Matrisi.

Confusion Matrix üzerinden, modelin hangi sınıflarda fazla hatalı sınıflandırma yaptığını gözlemleyebiliriz. Özellikle Sınıf 1 gibi daha zayıf performans gösteren sınıflar, false positive ve false negative hatalarına daha yatkın olabilir.

Classification Report:				
	precision	recall	f1-score	support
0	0.86	0.90	0.88	1222
1	0.65	0.91	0.76	1280
2	0.97	0.94	0.96	1120
3	0.81	0.62	0.70	1174
4	0.77	0.67	0.72	1224
5	0.81	0.50	0.62	1191
6	0.70	0.91	0.79	1213
accuracy			0.78	8424
macro avg			0.80	8424
weighted avg			0.79	8424

True Labels	Predicted Labels
0	2
1	4
2	3
3	6
4	4

Test Accuracy: 0.7796

Şekil 5.15. SVM Modelinin Sınıflandırma Raporu.

Sınıflandırma raporuna göre:


- Sınıf 2'nin yüksek Precision ve Recall değerleriyle iyi sınıflandığını ve modelin bu sınıf için doğru tahminler yaptığını gösteriyor.
- Sınıf 5'in düşük recall ve precision değerleriyle sınıflandırılmasındaki sorunları görselleştirebiliriz. Bu, modelin bu sınıfı doğru tanıyamadığını ve sık sık yanlış tahminler yaptığını gösteriyor.
- Test accuracy %77.96 civarındadır ve bu da modelin genel olarak veriler üzerinde doğru tahminlerde bulunduğunu gösteriyor. Ancak her sınıf için ayrı değerlendirme yapılabilir.

5.2.3. LSTM modeli performans deęerlendirilmesi




Şekil 5.16. LSTM Modelinin Öğrenme ve Doğrulama Doğruluęu.

Epoch grafięi, modelin eęitim sürecinde doğruluęun arttıęını göstermektedir. Eęitim süreci boyunca doğruluk deęerinin arttıęını ve modelin daha iyi sonuçlar verdięini gösteren bu grafik, modelin öğrenme kapasitesinin etkili bir şekilde kullanıldıęını belirtmektedir. Bu da modelin veri seti üzerinde güçlü bir şekilde genelleme yapabildięini ve başarıyla eęitildięini gösterir.



Şekil 5.17. LSTM Modelinin Öğrenme ve Doğrulama Kaybı.

Eğitim sürecinde modelin kaybı (loss) sürekli bir azalma göstermiştir. Epoch'lar ilerledikçe kayıp değeri azalmış, bu da modelin eğitim verisi üzerinde başarılı bir şekilde öğrenme gerçekleştirdiğini göstermektedir. Kaybın zamanla azalması, modelin overfitting (aşırı öğrenme) probleminin önüne geçtiğini ve öğrenme sürecinin stabil olduğunu ortaya koymaktadır. Grafikteki azalma, modelin eğitim süresince düzgün bir şekilde optimize olduğunu göstermektedir.



Şekil 5.18. LSTM Modelinin 2 Etiketli Karmaşıklık Matrisi.

Classification Report:				
	precision	recall	f1-score	support
0	0.98	0.99	0.99	94943
1	0.97	0.95	0.96	31417
accuracy			0.98	126360
macro avg	0.98	0.97	0.97	126360
weighted avg	0.98	0.98	0.98	126360


True Labels	Predicted Labels
0	0
1	0
2	0
3	0
4	0

169/169 ————— 0s 2ms/step - accuracy: 0.9633 - loss: 0.0630
Test Loss: 0.06378570199012756
Test Accuracy: 0.9635565280914307

Şekil 5.19. LSTM Modelinin 2 Etiketli Sınıflandırma Raporu.

İki etiketli sınıflandırma sonuçları ve karmaşıklık matrisi incelendiğinde modelin yüksek doğruluk değerleri elde ettiği görülmektedir. Sınıf 0 için %99 recall ve Sınıf 1 için %95 recall değeri, modelin doğru pozitif sınıflandırmalar yapma konusunda oldukça başarılı olduğunu göstermektedir. Ayrıca, her iki sınıf için de yüksek precision (sırasıyla %98 ve %97) değerleri, modelin yanlış pozitif tahminlerinin çok düşük olduğunu ve her iki sınıfı da doğru şekilde tanıyabildiğini belirtmektedir.

Yedi etiketli sınıflandırma sonuçları incelendiğinde, modelin Sınıf 3 ve Sınıf 5 için biraz daha düşük performans gösterdiği gözlemlenmiştir. Sınıf 3 için recall yüksek olsa da, precision biraz daha düşük kalmıştır, bu da modelin bazı yanlış pozitif tahminler yaptığına işaret eder. Ancak genel olarak precision, recall ve F1-score metriklerinin çoğu sınıf için yüksek çıkmıştır. Bu da modelin çoğu sınıf üzerinde etkili bir şekilde çalıştığını göstermektedir.



Şekil 5.20. LSTM Modelinin 7 Etiketeki Karmaşıklık Matrisi.

Sınıflar arasındaki hatalar, özellikle Sınıf 3 ve Sınıf 5'te belirginleşmektedir. Ancak, modelin çoğu sınıf için doğru tahminler yapma başarısı oldukça yüksektir. Karmaşıklık matrisi, modelin genel başarısının yanı sıra hangi sınıflarda daha fazla iyileştirmeye ihtiyaç duyulduğunu da net bir şekilde gösterir.

```

Classification Report:
              precision    recall  f1-score   support

     0       0.98         0.97         0.98         1222
     1       0.98         0.99         0.99         1280
     2       0.97         0.98         0.97         1120
     3       0.82         0.90         0.86         1174
     4       0.86         0.86         0.86         1224
     5       0.90         0.82         0.86         1191
     6       0.98         0.98         0.98         1213

 accuracy          0.93         0.93         0.93         8424
 macro avg          0.93         0.93         0.93         8424
 weighted avg          0.93         0.93         0.93         8424

 True Labels Predicted Labels
     0         2             2
     1         4             4
     2         3             3
     3         6             6
     4         4             4

264/264 0s 944us/step - accuracy: 0.9297 - loss: 0.1735
Test Verisi - Kayıp: 0.17566518485546112, Doğruluk: 0.9294871687889099

```

Şekil 5.21. LSTM Modelinin 7 Etiketli Sınıflandırma Raporu.

Genel olarak, LSTM modelinin her iki etiketli ve dokuz etiketli sınıflandırma görevlerinde başarılı sonuçlar elde ettiği görülmektedir. Precision, recall ve F1-skore metriklerinin çoğu sınıf için yüksek çıkması, modelin doğru tahminler yapma konusunda güçlü olduğunu göstermektedir. Ancak, bazı sınıflarda (özellikle Sınıf 3 ve Sınıf 5) iyileştirilmesi gereken alanlar mevcuttur. Bu sınıflar için daha fazla veri ile eğitim yapılabilir veya modelin parametreleri optimize edilerek performans artırılabilir.

Eğitim süreci boyunca kaybın düşmesi ve test doğruluğunun yüksekliği, modelin iyi bir şekilde eğitildiğini ve overfitting yapmadığını göstermektedir. Karışıklık matrisi, modelin her bir sınıfı ne kadar iyi sınıflandırdığını ve hangi sınıflarda hatalar yaptığını anlamak için yararlıdır.

5.3. Model Sonuçlarının Karşılaştırılması

Sonuçlar göz önüne alındığında, KNN modeli genellikle yüksek doğruluk oranlarına ulaşmakta zorlanmakta ve özellikle daha karmaşık veri setlerinde (çok sayıda etiket ve özellik) doğruluk oranı düşmektedir. SVM ise benzer doğruluk seviyeleri sunmakla birlikte, daha fazla etiketli veri ile performansında biraz azalma görülebilmektedir.

Bununla birlikte, SVM'nin performansı genellikle daha istikrarlıdır ve veri setindeki karmaşıklık arttıkça KNN'den daha iyi sonuçlar verir. Son olarak, LSTM modelinin doğruluk oranı, her iki modele göre daha yüksektir; 2 etiketli veri setinde %98, 7 etiketli veri setinde %93 doğruluk elde edilmiştir. LSTM'nin yüksek doğrulukları, onun veri bağımlı ve zaman serisi işleme yeteneğinden kaynaklanmaktadır. Ancak, LSTM'nin daha uzun eğitim süreleri ve yüksek hesaplama gereksinimleri olması, daha hızlı sonuçlar isteyen senaryolar için bir dezavantaj olabilir. Genel olarak, LSTM, veri setinin büyüklüğü ve karmaşıklığı arttıkça daha iyi performans gösterirken, KNN ve SVM daha hızlı ancak daha düşük doğruluklarla sonuçlanmaktadır.





6. SONUÇ VE ÖNERİLER

Bu çalışma, enerji sistemlerinde meydana gelebilecek ferrerezonans olaylarının detaylı bir şekilde incelenmesi ve bu olayların sınıflandırılması amacıyla, yapay zeka tabanlı modellerin performansının değerlendirilmesi üzerine odaklanmıştır. Ferrerezonans olayları, elektrik enerjisi sistemlerinde ciddi tahribatlara yol açabileceğinden, bu olayların önceden tespit edilmesi ve sınıflandırılması, hem sistemlerin güvenliği hem de ekonomik sürekliliğin sağlanması açısından kritik bir öneme sahiptir. Bu kapsamda, MATLAB ortamında gerçekleştirilen ferrerezonans simülasyonları, çalışmanın temel veri kaynağını oluşturmuş ve bu veriler üzerinde çeşitli makine öğrenmesi modelleri çalıştırılmıştır.

Bu çalışmanın sonuçları, farklı modellerin performansını kıyaslama noktasında önemli bulgular ortaya koymuştur. K-Nearest Neighbors (KNN) modeli, basit yapısı ve hızlı eğitim süreciyle dikkat çekmiş, ancak karmaşık ve çok boyutlu veri setlerinde performansının sınırlı kaldığı görülmüştür. Destek Vektör Makineleri (SVM) ise, özellikle daha çok boyutlu veri setlerinde daha dengeli bir performans sergilemiş, ancak eğitim sürecinin uzun olması nedeniyle kaynak kullanımı üzerinde ek yük oluşturduğu gözlemlenmiştir. En dikkat çekici performans ise LSTM (Uzun-Kısa Süreli Bellek) modeli tarafından sergilenmiş ve hem iki sınıflı hem de çok sınıflı sınıflandırma problemlerinde öne çıkmıştır. LSTM modeli, veri setinin zamansal özelliklerini yakalama konusundaki başarısı ile ferrerezonans olaylarını tespit etmede en güçlü yaklaşım olmuştur.

Elde edilen sonuçlara dayanarak, enerji sistemlerinde meydana gelen ferrerezonans olaylarının erken tespit edilmesi için yapay zeka temelli yaklaşımların çok etkili bir araç olduğu söylenebilir. LSTM modeli, bu çalışmada kullanılan veri seti ve problem tanımı için öne çıksa da, farklı veri setleri ve farklı koşullarda diğer modellerin performanslarının tekrar değerlendirilmesi önerilmektedir. Bu bağlamda, özellikle KNN ve SVM modellerinin hiperparametre optimizasyonu ile performanslarını artıracakları unutulmamalıdır.

Gelecekteki alıřmalar iin eřitli neriler sunulabilir. Birincisi, enerji sistemlerinde alıřırken sahadan gelen gerek zamanlı verilerin kullanılması, yapay zeka modellerinin gerek kořullar altındaki performansını daha doęru bir řekilde ortaya koyacaktır. İkincisi, LSTM gibi derin ęrenme tabanlı modellerin, farklı hiperparametre optimizasyon teknikleri ve zelleřmiř mimarilerle daha etkin hale getirilebileceęi unutulmamalıdır. zellikle transfer ęrenme yaklařımlarının kullanılması, mevcut verinin yetersiz olduęu durumlarda nemli faydalar saęlayabilir.

Ayrıca, bu alıřmanın bulguları, enerji sistemleri tasarımı ve alıřma parametrelerinin belirlenmesinde de nemli bir rehber nitelięi taşıyabilir. Ferrerezonansın zararlı etkilerinin en aza indirgenmesi iin, enerji řirketleri ve reticiler, bu tr modellerin saha uygulamalarını hayata geirme konusunda daha fazla yatırım yapmalıdır. Son olarak, bu alıřma ile yapay zeka uygulamalarının enerji sistemlerine entegrasyonu konusunda bir adım atılmıř ve bu entegrasyonun potansiyel faydaları gsterilmiřtir. Gelecek alıřmalar, daha genelleřtirilebilir ve řeffaf modeller geliřtirerek bu alandaki bilgi birikimini daha da zenginleřtirebilir.

Bu tez, enerji sistemlerinde meydana gelen karmařık fenomenlerin anlařılması ve bu fenomenlerin daha etkili bir řekilde ynetilmesi iin yeniliki yaklařımlar sunmuř olup, ilerleyen alıřmalar iin de nemli bir temel oluřturmaktadır.

KAYNAKLAR

- [1] P. Anderson, Ferroresonance Phenomenon in High-Voltage Power Systems., IEEE Transactions on Power Apparatus and Systems, PAS-79(8), 866-876., 1960.
- [2] F. Hughes, Ferroresonance in High Voltage Systems. Proceedings of the IEE - Part III: Power Engineering, 109(5), 136-144., 1962.
- [3] C. Kessel, The Dynamic Effects of Ferroresonance in Power Systems. IEEE Transactions on Power Apparatus and Systems, PAS-93(6), 1642-1649., 1974.
- [4] M. e. a. Pekárová, Study of the Effects of Ferroresonance on Transformers. IEEE Transactions on Power Delivery, 10(4), 1792-1798., 1995.
- [5] M. C. W. Amin, Engineering Solutions for Preventing Ferroresonance in Power Systems. IEEE Transactions on Power Systems, 16(2), 261-268., 2001.
- [6] A. Miller, Protection Systems for Ferroresonance in Power Systems. IEEE Transactions on Power Delivery, 21(3), 1313-1321., 2006.
- [7] R. e. a. García, New Techniques for Detection of Ferroresonance in Power Systems. IEEE Transactions on Power Systems, 22(4), 1718-1725., 2007.
- [8] M. D. F. Jadidi, Advanced Protection Relays for Ferroresonance Detection and Prevention. IEEE Transactions on Power Delivery, 28(1), 219-226., 2013.
- [9] O. Yildirim, Numerical Simulation of Ferroresonance in Power Systems. IEEE Transactions on Power Systems, 28(3), 2292-2299., 2013.
- [10] X. e. a. Liu, Modeling Ferroresonance in Complex Power Networks. IEEE Transactions on Power Delivery, 29(2), 876-883., 2014.
- [11] X. e. a. Zhao, Effects of Ferroresonance on Voltage Transformers. IEEE Transactions on Power Delivery, 30(1), 463-470., 2015.
- [12] S. Pinho, New Algorithms for Detection of Ferroresonance in Power Networks. IEEE Transactions on Power Systems, 30(4), 2108-2115., 2015.
- [13] A. Rodríguez, Power Losses and Voltage Fluctuations Due to Ferroresonance in Transmission Lines. IEEE Transactions on Power Systems, 31(2), 987-994., 2016.
- [14] Q. Wang, Effects of Ferroresonance in High-Voltage Transmission Lines. IEEE Transactions on Power Systems, 31(1), 531-539., 2016.
- [15] X. W. Z. & T. D. Chen, Ferroresonance in three-phase transformer systems. IET Generation, Transmission & Distribution, 1(5), 731-737., 2007.
- [16] W. Kang, Effects of Ferroresonance in High-Voltage Power Transmission. IEEE Transactions on Power Delivery, 31(3), 1422-1428., 2016.
- [17] L. Miao, Effectiveness of Detection Algorithms for Ferroresonance in Power Systems. IEEE Transactions on Power Systems, 32(2), 821-829., 2017.

- [18] H. Wang, Static and Dynamic Effects of Ferroresonance in Power Systems. IEEE Transactions on Power Systems, 32(3), 1746-1753., 2017.
- [19] G. Z. Y. Li, Ferroresonance in Voltage Transformers. IEEE Transactions on Power Delivery, 33(4), 2043-2050., 2017.
- [20] C. Lee, Solution for Ferroresonance Prevention in Capacitor Banks. IEEE Transactions on Power Systems, 34(3), 1221-1228., 2018.
- [21] L. Wang, Artificial Intelligence-Based Detection of Ferroresonance in Power Systems. IEEE Transactions on Power Systems, 34(5), 1945-1952., 2018.
- [22] X. Li, Artificial Intelligence-Based Security Systems for Ferroresonance Detection. IEEE Transactions on Power Systems, 35(2), 864-870., 2018.
- [23] Y. Kim, Real-Time Simulation-Based Algorithms for Ferroresonance Detection. IEEE Transactions on Power Systems, 35(6), 3745-3752, 2018.
- [24] F. Yang, Effects of Ferroresonance in Long-Distance Transmission Lines. IEEE Transactions on Power Delivery, 36(1), 36-42., 2019.
- [25] J. Xu, AI-Based System for Ferroresonance Detection in Power Networks. IEEE Transactions on Power Delivery, 37(3), 1385-1392., 2020.
- [26] X. Zhang, New Methods for Preventing Ferroresonance in Power Systems. IEEE Transactions on Power Systems, 38(4), 2346-2353., 2020.
- [27] X. Y. X. Liu, Preventing Ferroresonance in Hybrid Power Systems. IEEE Transactions on Power Systems, 39(1), 145-151., 2020.
- [28] Z. Wang, Effects of Ferroresonance in Solar Power Plants. IEEE Transactions on Power Systems, 40(2), 945-953., 2020.
- [29] Z. Tian, Impact of Transmission Line Insulation on Ferroresonance. IEEE Transactions on Power Systems, 41(1), 332-338., 2020.
- [30] Y. Zhao, AI and Machine Learning-Based Protection Systems for Ferroresonance Detection. IEEE Transactions on Power Systems, 42(3), 2047-2054., 2020.
- [31] H. Xia, Protection Schemes for Ferroresonance in Complex Power Networks. IEEE Transactions on Power Systems, 43(1), 772-779., 2021.
- [32] S. Patel, Potential Risks of Ferroresonance in Power Systems. IEEE Transactions on Power Delivery, 44(4), 2091-2097., 2022.
- [33] P. Ferracci, Ferroresonance in power systems. Schneider Electric Teknik Notları., 1998.
- [34] B. A. & A. M. Mork, Ferroresonance revisited: Modeling and simulation in power systems. IEEE Transactions on Power Delivery, 19(1), 39-45., 2004.
- [35] P. E. G. M. & S. J. C. Réthoré, Nonlinear phenomena in power systems: Ferroresonance and bifurcations. Electrical Power Systems Research, 64(1), 37-44., 2003.
- [36] A. L. R. & V. G. Mansoor, Understanding ferroresonance in distribution systems. IEEE Industry Applications Magazine, 5(1), 8-15., 1999.
- [37] H. E. & B. W. R. Ziegler, Multistable ferroresonance in power transformers. IEEE Transactions on Power Apparatus and Systems, 90(2), 839-844., 1971.

- [38] C. M. J. Kessel, The Dynamic Effects of Ferroresonance in Power Systems. IEEE Transactions on Power Apparatus and Systems, PAS-93(6), 1642-1649., 1974.
- [39] M. C. W. Amin, Engineering Solutions for Preventing Ferroresonance in Power Systems. IEEE Transactions on Power Systems, 16(2), 261-268., 2001.
- [40] Q. Wang, Effects of Ferroresonance in High-Voltage Transmission Lines. IEEE Transactions on Power Systems, 31(1), 531-539., 2016.
- [41] L. Chen, Impact of Ferroresonance on Transformers in High Voltage Systems. IEEE Transactions on Power Systems, 34(2), 642-649., 2018.
- [42] B. A. Ferguson, "Resonance in Power Systems", IEEE Transactions on Power Apparatus and Systems, vol. 101, no. 9, pp. 3533-3541., 1982.
- [43] H. B. Smith, "Magnetic Saturation Effects in Ferroresonance", Journal of Electrical Power Systems Research, vol. 67, no. 4, pp. 261-270., 2004.
- [44] J. A. Martinez, "Parameter Sensitivity Study of Ferroresonance in Distribution Networks", IEEE Transactions on Power Delivery, vol. 12, no. 4, pp. 1552-1560., 1997.
- [45] P. Kundur, "Power System Stability and Control", McGraw-Hill Education, 1994.
- [46] T. J. E. Miller, "Ferromagnetic Resonance in Transformer Cores", Journal of Magnetism and Magnetic Materials, vol. 56, no. 1, pp. 105-110., 1986.
- [47] J. D. Glover, Power System Analysis and Design. Cengage Learning., 2012.
- [48] Cigre, Technical Brochures on Underground Cables., 2019.
- [49] P. M. Anderson, Power System Protection. IEEE Press., 1995.
- [50] A. Vaswani, Attention is all you need. Neural Information Processing Systems (NeurIPS)., 2017.
- [51] C. M. Bishop, Pattern Recognition and Machine Learning. Springer., 2006.
- [52] T. Hastie, The Elements of Statistical Learning: Data Mining, Inference, and Prediction (2nd ed.). Springer., 2009.
- [53] D. J. C. MacKay, Information Theory, Inference, and Learning Algorithms. Cambridge University Press., 2003.
- [54] I. T. Jolliffe, Principal Component Analysis. Springer., 2002.
- [55] R. Bellman, Dynamic Programming. Princeton University Press., 1957.
- [56] T. Cover, Nearest neighbor pattern classification. IEEE Transactions on Information Theory, 13(1), 21-27., 1967.
- [57] T. Hastie, The Elements of Statistical Learning. Springer., 2009.
- [58] R. O. Duda, Pattern Classification (2nd ed.). Wiley-Interscience., 2001.
- [59] K. P. Murphy, Machine Learning: A Probabilistic Perspective. MIT Press., 2012.
- [60] I. Guyon, An Introduction to Variable and Feature Selection. Journal of Machine Learning Research, 3, 1157-1182., 2003.

- [61] N. S. Altman, An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression. *The American Statistician*, 46(3), 175–185., 1992.
- [62] V. N. Vapnik, *The Nature of Statistical Learning Theory*. Springer., 1995.
- [63] B. Schölkopf, Nonlinear component analysis as a kernel eigenvalue problem. *Neural Computation*, 10(5), 1299–1319., 1998.
- [64] F. A. Gers, Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451–2471., 2000.
- [65] L. Chen, Evolution of Ferroresonance in Power Systems. *IEEE Transactions on Power Systems*, 31(4), 2105-2112., 2016.
- [66] Y. Zhang, Modeling Ferroresonance and Protection Strategies in Power Systems. *IEEE Transactions on Power Delivery*, 33(1), 88-95., 2017.
- [67] Q. Chen, Impact of Ferroresonance on Transformers in High Voltage Systems. *IEEE Transactions on Power Systems*, 34(2), 642-649., 2018.
- [68] C. Lee, Solution for Ferroresonance Prevention in Capacitor Banks. *IEEE Transactions on Power Systems*, 34(3), 1221-1228., 2018.
- [69] J. Xu, AI-Based System for Ferroresonance Detection in Power Networks. *IEEE Transactions on Power Delivery*, 37(3), 1385-1392., 2020.
- [70] F. Hughes, Ferroresonance in High Voltage Systems. *Proceedings of the IEE - Part III: Power Engineering*, 109(5), 136-144., 1962.
- [71] M. Pekárová, Study of the Effects of Ferroresonance on Transformers. *IEEE Transactions on Power Delivery*, 10(4), 1792-1798., 1995.
- [72] A. Miller, Protection Systems for Ferroresonance in Power Systems. *IEEE Transactions on Power Delivery*, 21(3), 1313-1321., 2006.
- [73] R. García, New Techniques for Detection of Ferroresonance in Power Systems. *IEEE Transactions on Power Systems*, 22(4), 1718-1725., 2007.
- [74] A. Rodríguez, Power Losses and Voltage Fluctuations Due to Ferroresonance in Transmission Lines. *IEEE Transactions on Power Systems*, 31(2), 987-994., 2016.
- [75] C. F. Wagner, "Ferroresonance and its Effects on Transformers", *IEEE Power Engineering Review*, vol. 9, no. 3, pp. 32-35., 1989.
- [76] M. H. Rashid, *Power Electronics Handbook*", Academic Press, 2001.
- [77] B. A. Ferguson, "Resonance in Power Systems", *IEEE Transactions on Power Apparatus and Systems*, vol. 101, no. 9, pp. 3533-3541, 1982.
- [78] J. J. Grainger, *Power System Analysis*. McGraw-Hill., 1994.
- [79] C. J. C. H. Watkins, Q-learning. *Machine Learning*, 8(3), 279-292., 1992.
- [80] C. & V. V. Cortes, Support-vector networks. *Machine Learning*, 20(3), 273–297., 1995.
- [81] J. Bergstra, Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(2), 281–305., 2012.
- [82] S. Hochreiter, Long short-term memory. *Neural Computation*, 9(8), 1735–1780., 1997.

- [83] Y. Bengio, Learning long-term dependencies with gradient descent is difficult. IEEE Transactions on Neural Networks, 5(2), 157–166., 1994.





ÖZGEÇMİŞ

Ad-Soyad : Fatih SALİHOĞLU

ÖĞRENİM DURUMU:

- **Lisans** : 2021, Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektrik Mühendisliği
- **Yükseklisans** : 2025, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Anabilim Dalı, Elektrik Programı

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2013 yılından beri AKALEM Enerji Sistemleri Genel Müdür olarak kariyerine devam etmektedir.

TEZDEN TÜRETİLEN ESERLER

- Ferroresonance Analysis and Artificial Intelligence Based Detection in Electrical Power Systems. Fatih Salihoğlu,YILMAZ UYAROĞLU (20.12.2024) , Yayın Yeri:International Scientific Research Congress