

isrAcademy

international
scientific
research
academy

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

FATİH SALİHOĞLU

isrAcademy

Publishing

isbn: 978-625-95570-4-5



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

Fatih SALİHOĞLU

isrAcademy | international
scientific
research
academy

© 2025, isrAcademy Yayınları

Tüm hakları saklıdır. Yayıncının yazılı izni olmaksızın hiçbir şekilde kopya edilemez, elektronik veya başka bir yolla çoğaltılamaz, yayımlanamaz ve dağıtılamaz.

© 2025, isrAcademy Publishing

All rights reserved. This publication may not be copied, published or distributed in any form or by any means, electronic or otherwise, without the written permission of the publisher.

Yazar: Fatih SALİHOĞLU

ISBN: 978-625-95570-4-5

Istanbul, 2025

Kapak/Mizanpaj: isrAcademy

isrAcademy | international
scientific
research
academy

Fındıklı Mah. Hancıoğlu Sokak
46-48 Maltepe / Istanbul

Kütüphanler için Bilgi Kartı

Salihoğlu, Fatih (2025). *Elektrik Güç Sistemlerinde Ferrerezonans Analizi ve Yapay Zeka Tabanlı Tespiti*, Istanbul: isrAcademy Publishing, 66 s.

Alan: Mühendislik Bilimleri, Elektrik-Elektronik Mühendisliği

Library Cataloging-in-Publication Data (CIP)

Salihoğlu, Fatih (2025). *Elektrik Güç Sistemlerinde Ferrerezonans Analizi ve Yapay Zeka Tabanlı Tespiti*, Istanbul: isrAcademy Publishing, 66 p.

Field: Engineering, Electrical-Electronics Engineering

İÇİNDEKİLER

1. GİRİŞ	5
2. FERROREZONANS	8
2.1. Ferrorezonans ve Lineer Rezonans Arasındaki Farklılıklar	8
2.2. Ferrorezonansın İletim Sistemlerindeki Etkileri.....	9
2.2.1. Enerji İletim Sistemlerinde Seri Ferrorezonans Devreleri	10
2.2.2. Enerji İletim Sistemlerinde Paralel Ferrorezonans Devreleri.....	13
3. GÜÇ SİSTEMLERİ	15
3.1. Güç Sistemlerinin Matematiksel Temsili	16
3.2. Enerji İletim Hatları	17
3.2.1. Kısa Mesafeli İletim Hatları	18
3.2.1.1. Kısa Mesafeli Hatların Elektriksel Modeli.....	18
3.2.1.2. Güç Akışı ve Verimlilik	19
3.2.2. Orta Mesafeli İletim Hatları	20
3.2.2.1. Orta Mesafeli Hatların Elektriksel Modeli.....	20
3.2.2.2. Hat Sabitleri ve Güç Akışı Denklemleri.....	20
3.2.2.3. Orta Mesafeli Hatlarda Kapasitif ve Endüktif Etkiler	21
3.2.3. Uzun Mesafeli İletim Hatları	21
3.2.3.1. Uzun Mesafeli Hatların Elektriksel Modeli.....	22
3.2.3.2. Uzun Hatlarda İletim Sabitleri	22
3.2.3.3. Güç Akışı ve Dalga Yansıması	23
4. MATERYAL VE YÖNTEM	24
4.1. Yapay Zeka	24
4.1.1. Yapay Sinir Ağları (Artificial Neural Networks - ANN).....	25
4.1.2. Aktivasyon Fonksiyonları	25
4.1.2.1. Sigmoid.....	26
4.1.2.2. Tanh (Hiperbolik Tanjant)	26
4.1.2.3. ReLU (Rectified Linear Unit).....	27
4.1.3. Geri Yayılım Algoritması (Backpropagation).....	27
4.1.4. Derin Sinir Ağları (Deep Neural Networks - DNN)	28
4.1.4.1. Doğal Dil İşleme (NLP)	29
4.1.4.2. Görüntü İşleme.....	29
4.1.4.3. Zaman Serisi Analizi.....	29

4.1.5. Öğrenme Çeşitleri.....	29
4.1.5.1. Denetimli Öğrenme (Supervised Learning)	30
4.1.5.2. Denetimsiz Öğrenme (Unsupervised Learning).....	30
4.1.5.3. Pekıştirmeli Öğrenme (Reinforcement Learning)	31
4.2. K-En Yakın Komşu (KNN) Algoritması	31
4.2.1. Mesafe Metrikleri ve Matematiksel Temeller	32
4.2.2. KNN Algoritmasının İşleyiş Adımları	34
4.2.3. Parametre Seçimi ve Optimizasyon.....	34
4.3. Destek Vektör Makineleri (Support Vector Machines - SVM).....	35
4.3.1. Matematiksel Temeller ve Hedef Fonksiyon.....	35
4.3.2. Lagrange Çarpanları	36
4.3.3. Kernel Fonksiyonları ve Doğrusal Olmayan Ayrılabilirlik.....	36
4.3.4. Parametre Optimizasyonu ve Çapraz Doğrulama	37
4.4. Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM).....	38
4.4.1. Matematiksel Temeller ve Model Yapısı.....	38
4.4.1.1. Unutma Kapısı.....	39
4.4.1.2. Giriş Kapısı ve Aday Hücre Durumu	39
4.4.1.3. Çıkış Kapısı ve Gizli Durum.....	40
4.4.2. Kernel Fonksiyonları.....	40
4.4.3. Hiperparametre Seçimi ve Model Optimizasyonu.....	40
5. DENEYSEL ÇALIŞMALAR	42
5.1. Veri Setinin Hazırlanması.....	42
5.1.1. Normal Durum İçin Veriseti Oluşturulması	42
5.1.2. Farklı Ferrezonans Durumu İçin Veriseti Oluşturulması	43
5.2. Model Performans Değerlendirilmesi.....	48
5.2.1. KNN Modeli Performans Değerlendirilmesi	48
5.2.2. SVM Modeli Performans Değerlendirilmesi	51
5.2.3. LSTM Modeli Performans Değerlendirilmesi	54
5.3. Model Sonuçlarının Karşılaştırılması.....	58
6. SONUÇLAR VE ÖNERİLER	60
7. KAYNAKÇA	62

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 aksama, 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.

Ferrerezonans, 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. Ferrerezonansın 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.

Ferrerezonansın etkileri, aşırı gerilimler, aşırı akımlar ve harmonik frekans bileşenleri şeklinde kendini gösterir. Bu etkiler, sistemdeki ekipmanlara ciddi zararlar verebilir ve sistemin verimli çalışmasını engelleyebilir. Ferrerezonansın 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,

ferrerezonans da başlangıç koşullarına ve sistem parametrelerindeki değişimlere oldukça duyarlıdır.

Ferrerezonans 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, ferrerezonansın 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 ferrerezonans olayıdır. Ferrerezonans, 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. Ferrerezonans, 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 sönsen 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.

2. FERROREZONANS

Ferrorezonans, güç sistemlerinde manyetik doygunluk 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:

1. 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].
2. 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].
3. 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].
4. 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].

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

2.2. Ferrerezonansın İletim Sistemlerindeki Etkileri

Enerji iletim sistemlerinde, ferrerezonans 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, ferrerezonansın doğrudan bir sonucu olup, genellikle sistemdeki nonlineer manyetik ve kapasitif elemanlar arasındaki etkileşimle ilişkilidir [4].

Orta gerilim şebekelerinde ise ferrerezonans 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, ferrerezonans olasılığını artırabilir [6]. Simetrisizlik nedeniyle oluşan dengesizlikler, sistemde harmonik bozulmalar yaratabilir ve bu durum ferrerezonans olaylarını daha da karmaşık hale getirebilir [13].

Yapılan araştırmalar, özellikle enerji iletim sistemlerinde ferrerezonansın sadece aşırı gerilimlere değil, aynı zamanda ekipmanların izolasyon hasarlarına, manyetik doyuma ve enerji kayıplarına yol açabileceğini ortaya koymaktadır ([40], [41]). Ayrıca, kontrolsüz ferrerezonans 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, ferrerezonansın önlenmesi için akıllı koruma röleleri ve simetriyi sağlayan düzenleyiciler önerilmektedir ([7], [20]). Bununla birlikte, enerji iletim sistemlerindeki farklı durumlar için ferrerezonans analizi yapılırken, sistemin tüm dinamik ve statik özelliklerinin dikkate alınması gerektiği vurgulanmaktadır [25].

2.2.1. Enerji İletim Sistemlerinde Seri Ferrerezonans Devreleri

Seri ferrerezonans devreleri, enerji iletim sistemlerinde karşılaşılan karmaşık fenomenlerden biridir. Basit bir seri ferrerezonans 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 ferrerezonans" 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 değişmesiyle açıklanabilir. Bu durum, devrenin rezonans dışında kalmasına neden olur ve dolayısıyla tehlikeli bir rezonans frekansı oluşmaz [44].



Şekil 2.1 Ferrerezonans Devresi


Demir çekirdekli endüktans ve lineer bir kondansatör içeren devrelerin temel fazör diyagramı Şekil 2.2' de gösterilmektedir. Bu diyagram, devredeki akım ve gerilim bileşenlerinin nasıl etkileşimde bulunduğunu açıklamak için kullanılır [4]. Ayrıca, demir çekirdekli endüktansın gerilim-akım karakteristiği, doyma eğrisi ile Şekil 2.4 'de detaylandırılmıştır. Kondansatörün lineer karakteristiği, akım ile gerilim arasındaki doğrusal ilişkiyi temsil ederken,

endüktansın doğrusal olmayan karakteristiği, manyetik doymanın etkilerini gösterir [5].




Şekil 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 İletim 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

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 İletim 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:

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

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:

$$P_{\text{kayıp}} = I^2 R \quad (3.10)$$

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

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

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 İletim 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:

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

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

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

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 İletim 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 İletim 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 I , 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 "düşünebilir 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 Ağları (Artificial Neural Networks - ANN)

Yapay sinir ağları, 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 tanıtmalarıyla modern bir forma kavuşmuştur. Yapay sinir ağları, 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)

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

(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 İşleme (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 İşleme

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 ödüller (rewards) olup, ajan, her bir durumda alacağı eylemi belirler ve bu eylemin sonucunda ödüller 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, basitliği ve etkili performansı ile dikkat çeker [57]. Bu bölümde, k-NN algoritmasının temel yapısı, matematiksel temelleri detaylı bir şekilde ele alınmıştır.



Şekil 4.8 KNN Modelinin Çalışma Prensibi

k-NN algoritmasının parametrik olmayan doğası, herhangi bir veri dağılımı varsayımına gerek duyulmaması anlamına gelir. Bu özelliği, algoritmayı karmaşık veya doğrusal olmayan veri kümelerinde etkili hale getirir [58]. Eğitim sırasında herhangi bir model oluşturulmadığı için k-NN, genellikle "eğitimsiz öğrenme" (lazy learning) algoritması olarak sınıflandırılır. Bununla birlikte, bu durum, algoritmanın test aşamasında daha yüksek hesaplama maliyetine sahip olmasına neden olur.

4.2.1. Mesafe Metrikleri ve Matematiksel Temeller

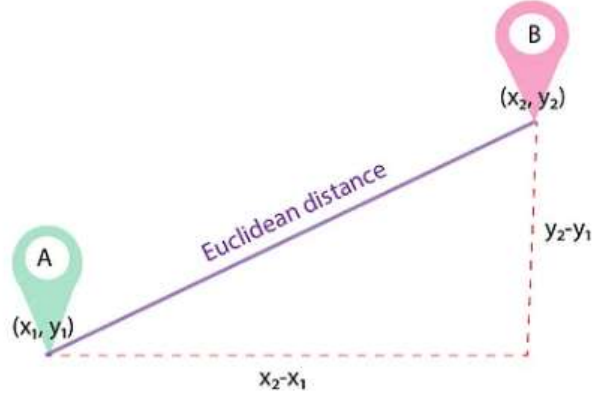
k-NN algoritmasının performansı, büyük ölçüde veri noktaları arasındaki mesafeyi ölçmek için kullanılan metriğe bağlıdır. En yaygın mesafe metrikleri şunlardır:

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

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

(4.13)

Bu metrik, genellikle sürekli ve normal dağılımlı özelliklerde etkili sonuç 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 İşleyiş 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:

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

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 [62].

En yaygın kullanılan kernel fonksiyonları şunlardır:

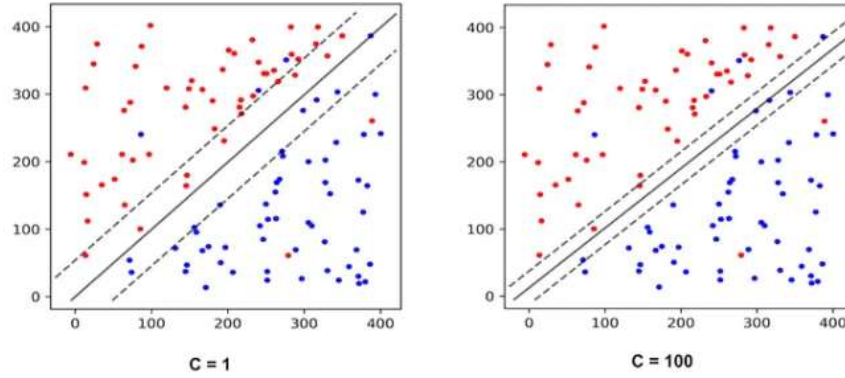
- **Doğrusal Kernel:** $K(x_i, x_j) = x_i * x_j$, verilerin doğrusal olduğu durumlarda kullanılır.
- **Polinom Kernel:** $K(x_i, x_j) = (x_i * x_j + c)^d$, doğrusal olmayan ilişkiler için uygundur.



- **RFB (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:** $K(x_i, x_j) = \tanh(\alpha x_i * x_j + c)$, sinir ağları ile benzer özellikler gösterir.

4.3.4. Parametre Optimizasyonu ve Çapraz Doğrulama

SVM modelinin performansı, büyük ölçüde doğru hiperparametre ayarlarına bağlıdır. İki önemli parametre olan C ve kernel parametrelerinin optimizasyonu, genellikle Grid Search veya Bayesian Optimization gibi yöntemlerle yapılır. Ayrıca, modelin genelleme yeteneğini artırmak için çapraz doğrulama sıkça kullanılır. Bu yöntem, modelin farklı alt veri setlerinde eğitilmesi ve test edilmesi sürecini içerir, böylece modelin aşırı öğrenme riski azalır.




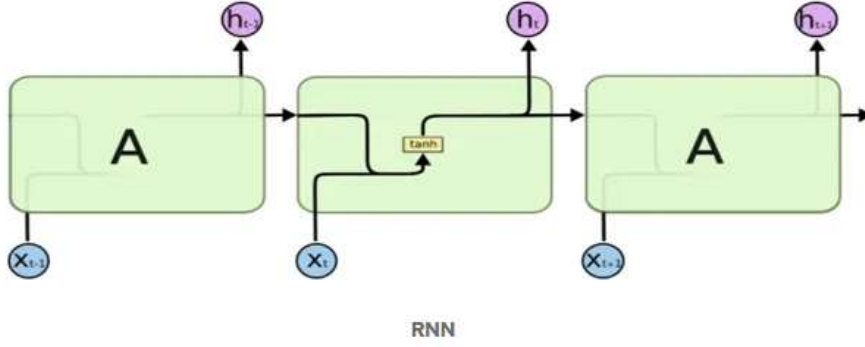
Şekil 4.13 Çapraz Doğrulamanın Görselleştirilmesi

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 bağımlılıkların modellenmesi sorununa yenilikçi bir çözüm getiren bir yapıdır. İlk kez Hochreiter ve Schmidhuber (1997) tarafından tanıtılmıştır. Zaman serileri, doğal dil işleme (NLP), biyomedikal sinyal işleme ve diğer 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.



Forget Gate - Input Gate - Output Gate - Cell State

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_t) 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 [2].

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

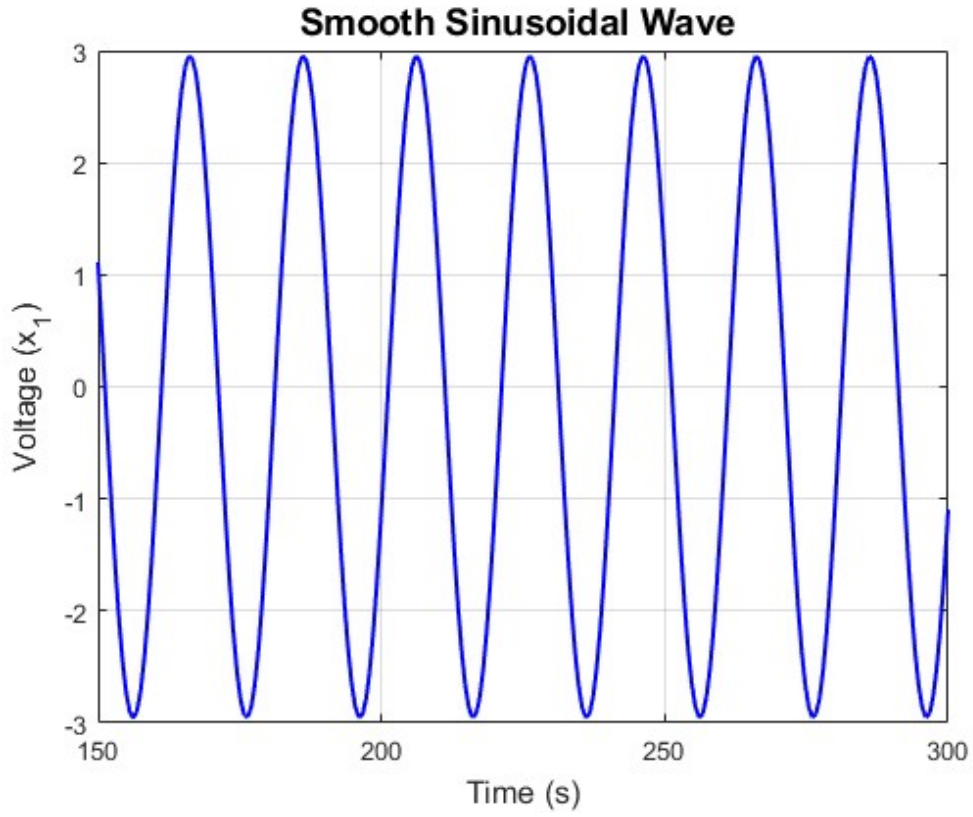
Bu çalışmada kullanılan veri seti, ferreazonans olaylarını tespit etmeye yönelik olarak MATLAB ortamında oluşturulmuştur. Veri seti, toplamda sekiz farklı ferreazonans durumu ile bir normal durumdan oluşmaktadır. Ferreazonans durumları, sistemdeki gerilim ve akım dalga şekillerindeki bozulmaların çeşitli 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 İçin 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 Ferrerozonansız Sinüsoidal Dalga

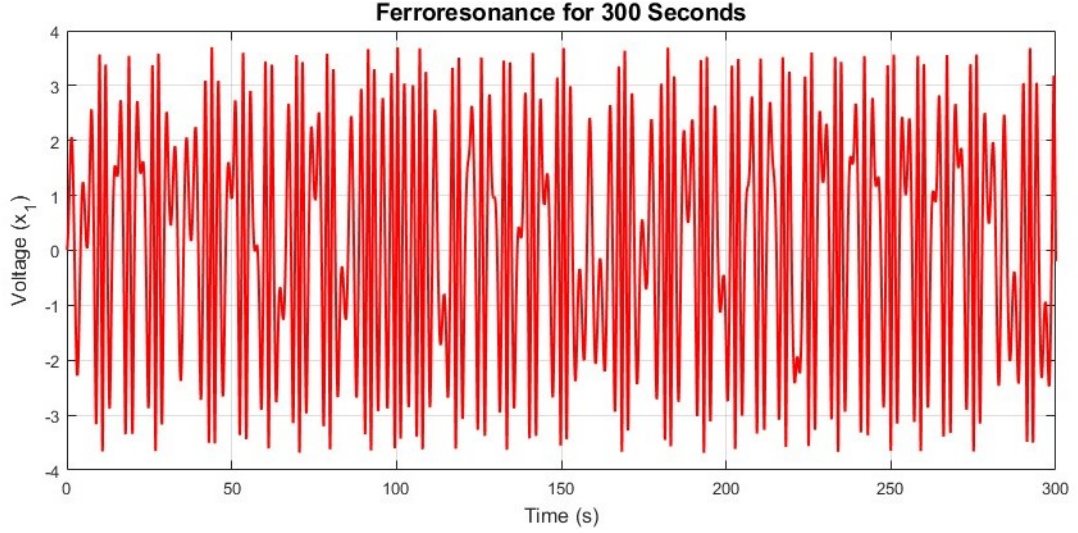
5.1.2. Farklı Ferrerozonans Durumu İçin Veriseti Oluşturulması

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




Şekil 5.2 1 Numaralı Özelliklere Göre Ferrerozonans

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




Şekil 5.3 2 Numaralı Özelliklere Göre Ferrezonans

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




Şekil 5.4 3 Numaralı Özelliklere Göre Ferrezonans

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 Ferrorezonans

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



Şekil 5.8 7 Numaralı Özelliklere Göre Ferrorezonans

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

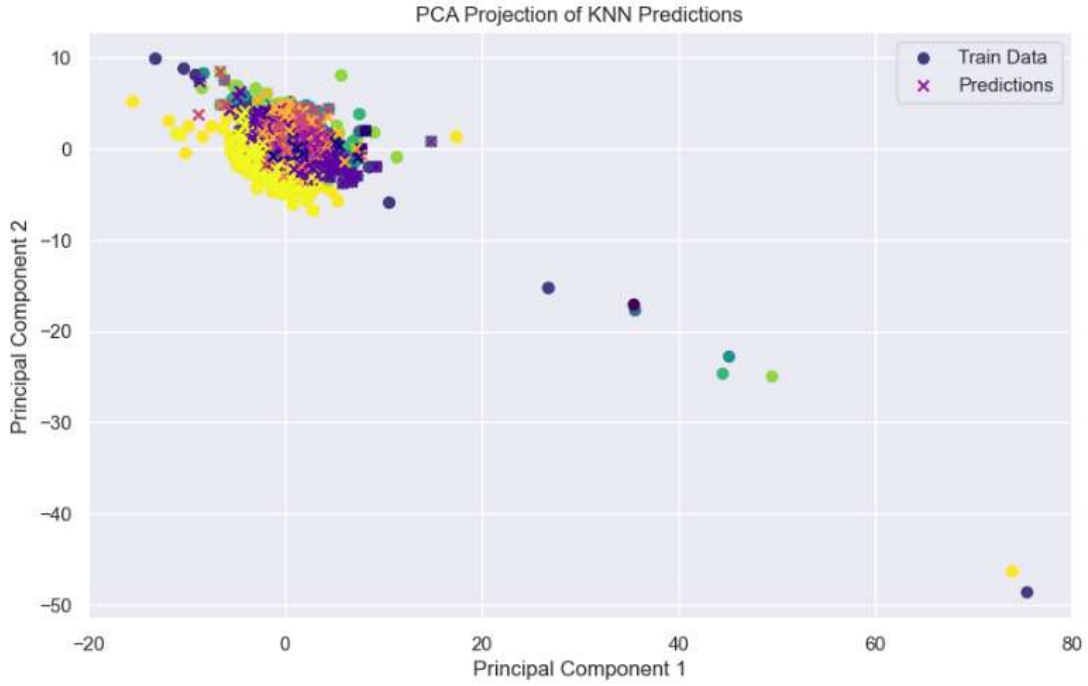


Şekil 5.9 8 Numaralı Özelliklere Göre Ferrerozonans

Son görselde, ferrerozonansın maksimum seviyeye ulaştığı ve sistemin çok büyük dalgalanmalar gösterdiği bir durum gözlemlenmektedir. Bu, ferrerozonansın 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         0.82         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 tanımada 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 Değerlendirilmesi



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      0.78      0.78      8424
 weighted avg     0.79      0.78      0.77      8424

 True Labels Predicted Labels
0             2             2
1             4             4
2             3             3
3             6             6
4             4             4
Test Accuracy: 0.7796
```

Şekil 5.15 SVM Modelinin Sınıflandırma Raporu

Sınıflandırma raporuna göre:

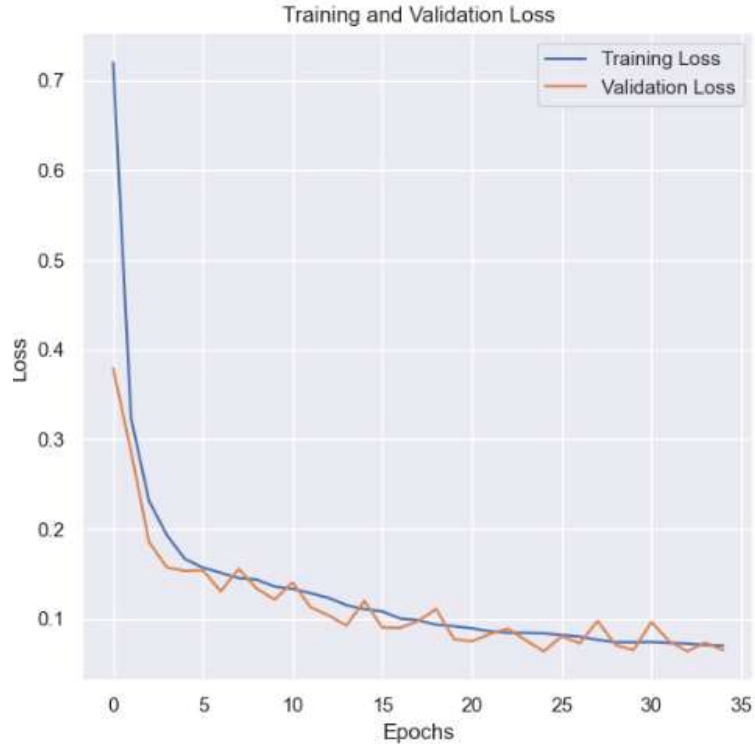
- Sınıf 2'nin yüksek Precision ve Recall değerleriyle iyi sınıflandığını ve modelin bu sınıf için doğru tahminler yaptığını gösteriyor.
- Sınıf 5'in düşük recall ve precision değerleriyle sınıflandırılmasındaki sorunları görselleştirebiliriz. Bu, modelin bu sınıfı doğru tanıyamadığını ve sık sık yanlış 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 Değerlendirilmesi




Şekil 5.16 LSTM Modelinin Öğrenme ve Doğrulama Doğruluğu

Epoch grafiği, modelin eğitim sürecinde doğruluğun arttığını göstermektedir. Eğitim süreci boyunca doğruluk değerinin arttığını ve modelin daha iyi sonuçlar verdiğini gösteren bu grafik, modelin öğrenme kapasitesinin etkili bir şekilde kullanıldığını belirtmektedir. Bu da modelin veri seti üzerinde güçlü bir şekilde genelleme yapabildiğini ve başarıyla eğitildiğini 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 Etiketeki 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                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             0
 1           0             0
 2           0             0
 3           0             0
 4           0             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 Etiketeki 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 yaptığını 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. SONUÇLAR VE ÖNERİLER

Bu çalışma, enerji sistemlerinde meydana gelebilecek ferreazonans olaylarının detaylı bir şekilde incelenmesi ve bu olayların sınıflandırılması amacıyla, yapay zeka tabanlı modellerin performansının değerlendirilmesi üzerine odaklanmıştır. Ferreazonans 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 ferreazonans 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 ferreazonans olaylarını tespit etmede en güçlü yaklaşım olmuştur.

Elde edilen sonuçlara dayanarak, enerji sistemlerinde meydana gelen ferreazonans 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 arttırabilecekleri unutulmamalıdır.

Gelecekteki çalışmalar için çeşitli öneriler sunulabilir. Birincisi, enerji sistemlerinde çalışırken sahadan gelen gerçek zamanlı verilerin kullanılması, yapay zeka modellerinin gerçek koşullar altındaki performansını daha doğru bir şekilde ortaya koyacaktır. İkincisi, LSTM gibi derin öğrenme tabanlı modellerin, farklı hiperparametre optimizasyon teknikleri ve özelleşmiş mimarilerle daha etkin hale getirilebileceği unutulmamalıdır. Özellikle transfer öğrenme yaklaşımlarının kullanılması, mevcut verinin yetersiz olduğu durumlarda önemli faydalar sağlayabilir.

Ayrıca, bu çalışmanın bulguları, enerji sistemleri tasarımı ve çalışma parametrelerinin belirlenmesinde de önemli bir rehber niteliği taşıyabilir.

Ferrerezonansın zararlı etkilerinin en aza indirgenmesi için, enerji şirketleri ve üreticiler, bu tür modellerin saha uygulamalarını hayata geçirme konusunda daha fazla yatırım yapmalıdır. Son olarak, bu çalışma ile yapay zeka uygulamalarının enerji sistemlerine entegrasyonu konusunda bir adım atılmış ve bu entegrasyonun potansiyel faydaları gösterilmiştir. Gelecek çalışmalar, daha geliştirilebilir ve şeffaf modeller geliştirerek bu alandaki bilgi birikimini daha da zenginleştirebilir.

Bu tez, enerji sistemlerinde meydana gelen karmaşık fenomenlerin anlaşılması ve bu fenomenlerin daha etkili bir şekilde yönetilmesi için yenilikçi yaklaşımlar sunmuş olup, ilerleyen çalışmalar için de önemli bir temel oluşturmaktadır.

7. KAYNAKÇA

- [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. Liu, Modeling Ferroresonance in Complex Power Networks. IEEE Transactions on Power Delivery, 29(2), 876-883., 2014.
- [11] X. 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] 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] 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. 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] J. Bergstra, Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(2), 281-305., 2012.

- [34] F. A. Gers, Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451-2471., 2000.
- [35] P. Ferracci, Ferroresonance in power systems. *Schneider Electric Teknik Notları.*, 1998.
- [36] A. M. Mork, Ferroresonance revisited: Modeling and simulation in power systems. *IEEE Transactions on Power Delivery*, 19(1), 39-45., 2004.
- [37] V. G. Mansoor, Understanding ferroresonance in distribution systems. *IEEE Industry Applications Magazine*, 5(1), 8-15., 1999.
- [38] S. J. C. Réthoré, Nonlinear phenomena in power systems: Ferroresonance and bifurcations. *Electrical Power Systems Research*, 64(1), 37-44., 2003.
- [39] B. W. R. Ziegler, Multistable ferroresonance in power transformers. *IEEE Transactions on Power Apparatus and Systems*, 90(2), 839-844., 1971.
- [40] 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.
- [41] L. Chen, Evolution of Ferroresonance in Power Systems. *IEEE Transactions on Power Systems*, 31(4), 2105-2112., 2016.
- [42] Y. Zhang, Modeling Ferroresonance and Protection Strategies in Power Systems. *IEEE Transactions on Power Delivery*, 33(1), 88-95., 2017.
- [43] Q. Chen, Impact of Ferroresonance on Transformers in High Voltage Systems. *IEEE Transactions on Power Systems*, 34(2), 642-649., 2018.
- [44] C. Lee, Solution for Ferroresonance Prevention in Capacitor Banks. *IEEE Transactions on Power Systems*, 34(3), 1221-1228., 2018.
- [45] J. Xu, AI-Based System for Ferroresonance Detection in Power Networks. *IEEE Transactions on Power Delivery*, 37(3), 1385-1392., 2020.
- [46] F. Hughes, Ferroresonance in High Voltage Systems. *Proceedings of the IEE - Part III: Power Engineering*, 109(5), 136-144., 1962.
- [47] M. Pekárová, Study of the Effects of Ferroresonance on Transformers. *IEEE Transactions on Power Delivery*, 10(4), 1792-1798., 1995.
- [48] M. C. W. Amin, Engineering Solutions for Preventing Ferroresonance in Power Systems. *IEEE Transactions on Power Systems*, 16(2), 261-268., 2001.
- [49] A. Miller, Protection Systems for Ferroresonance in Power Systems. *IEEE Transactions on Power Delivery*, 21(3), 1313-1321., 2006.
- [50] R. García, New Techniques for Detection of Ferroresonance in Power Systems. *IEEE Transactions on Power Systems*, 22(4), 1718-1725., 2007.

- [51] A. Rodríguez, Power Losses and Voltage Fluctuations Due to Ferroresonance in Transmission Lines. *IEEE Transactions on Power Systems*, 31(2), 987-994., 2016.
- [52] Q. Wang, Effects of Ferroresonance in High-Voltage Transmission Lines. *IEEE Transactions on Power Systems*, 31(1), 531-539., 2016.
- [53] L. Chen, Impact of Ferroresonance on Transformers in High Voltage Systems. *IEEE Transactions on Power Systems*, 34(2), 642-649., 2018.
- [54] B. A. Ferguson, "Resonance in Power Systems", *IEEE Transactions on Power Apparatus and Systems*, vol. 101, no. 9, pp. 3533-3541,, 1982.
- [55] H. B. Smith, "Magnetic Saturation Effects in Ferroresonance", *Journal of Electrical Power Systems Research*, vol. 67, no. 4, pp. 261-270,, 2004.
- [56] J. A. Martinez, "Parameter Sensitivity Study of Ferroresonance in Distribution Networks", *IEEE Transactions on Power Delivery*, vol. 12, no. 4, pp. 1552-1560,, 1997.
- [57] C. F. Wagner, "Ferroresonance and its Effects on Transformers", *IEEE Power Engineering Review*, vol. 9, no. 3, pp. 32-35,, 1989.
- [58] M. H. Rashid, *Power Electronics Handbook*", Academic Press, 2001.
- [59] T. J. E. Miller, "Ferromagnetic Resonance in Transformer Cores", *Journal of Magnetism and Magnetic Materials*, vol. 56, no. 1, pp. 105-110,, 1986.
- [60] P. Kundur, *"Power System Stability and Control"*, McGraw-Hill Education, 1994.
- [61] B. A. Ferguson, *Resonance in Power Systems"*, *IEEE Transactions on Power Apparatus and Systems*, vol. 101, no. 9, pp. 3533-3541, 1982.
- [62] Cigre, *Technical Brochures on Underground Cables.*, 2019.
- [63] P. M. Anderson, *Power System Protection*. IEEE Press., 1995.
- [64] J. J. Grainger, *Power System Analysis*. McGraw-Hill., 1994.
- [65] J. D. Glover, *Power System Analysis and Design*. Cengage Learning., 2012.
- [66] C. M. Bishop, *Pattern Recognition and Machine Learning*. Springer., 2006.
- [67] T. Hastie, *The Elements of Statistical Learning*. Springer., 2009.
- [68] D. J. C. MacKay, *Information Theory, Inference, and Learning Algorithms*. Cambridge University Press., 2003.
- [69] I. T. Jolliffe, *Principal Component Analysis*. Springer., 2002.
- [70] R. Bellman, *Dynamic Programming*. Princeton University Press., 1957.

- [71] C. J. C. H. Watkins, Q-learning. *Machine Learning*, 8(3), 279-292., 1992.
- [72] C. & V. V. Cortes, Support-vector networks. *Machine Learning*, 20(3), 273-297., 1995.
- [73] V. N. Vapnik, *The Nature of Statistical Learning Theory*. Springer., 1995.
- [74] B. Schölkopf, Nonlinear component analysis as a kernel eigenvalue problem. *Neural Computation*, 10(5), 1299-1319., 1998.
- [75] S. Hochreiter, Long short-term memory. *Neural Computation*, 9(8), 1735-1780., 1997.
- [76] Y. Bengio, Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157-166., 1994.
- [77] T. Cover, Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21-27., 1967.
- [78] T. Hastie, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer., 2009.
- [79] R. O. Duda, *Pattern Classification* (2nd ed.). Wiley-Interscience., 2001.
- [80] K. P. Murphy, *Machine Learning: A Probabilistic Perspective*. MIT Press., 2012.
- [81] I. Guyon, An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*, 3, 1157-1182., 2003.
- [82] N. S. Altman, An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression. *The American Statistician*, 46(3), 175-185., 1992.
- [83] A. Vaswani, Attention is all you need. *Neural Information Processing Systems (NeurIPS)*., 2017.