



**HİDROELEKTRİK SANTRALLERİNDE GERÇEK
ZAMANLI VERİLERE DAYALI ARIZA TAHMİN
ETMEK VE ÖNLEMEK İÇİN MAKİNE
ÖĞRENMESİ TEMELLİ KONTROL SİSTEMİ
GELİŞTİRİLMESİ**

**2025
DOKTORA TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ**

Omer Farhan AL-HARDANEE

**Tez Danışmanı
Prof. Dr. Hüseyin DEMİREL**

**HİDROELEKTRİK SANTRALLERİNDE GERÇEK ZAMANLI VERİLERE
DAYALI ARIZA TAHMİN ETMEK VE ÖNLEMEK İÇİN MAKİNE
ÖĞRENMESİ TEMELLİ KONTROL SİSTEMİ GELİŞTİRİLMESİ**

Omer Farhan AL-HARDANEE

**Tez Danışmanı
Prof. Dr. Hüseyin DEMİREL**

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalında
Doktora Tezi
Olarak Hazırlanmıştır**

**KARABÜK
Nisan 2025**

Omer Farhan AL-HARDANEE tarafından hazırlanan “HİDROELEKTRİK SANTRALLERİNDE GERÇEK ZAMANLI VERİLERE DAYALI ARIZA TAHMİN ETMEK VE ÖNLEMEK İÇİN MAKİNE ÖĞRENMESİ TEMELLİ KONTROL SİSTEMİ GELİŞTİRİLMESİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Prof. Dr. Hüseyin DEMİREL

.....

Tez Danışmanı, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Elektrik-Elektronik Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 30/04/2025

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Prof. Dr. Hüseyin DEMİREL (KBÜ)

.....

Üye : Prof. Dr. Hüseyin CANBOLAT (AYBÜ)

.....

Üye : Prof. Dr. Zıyodulla YUSUPOV (KBÜ)

.....

Üye : Prof. Dr. Serhat Orkun TAN (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Abdullah ORMAN (AYBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Doç. Dr. Zeynep ÖZCAN

.....

Lisansüstü Eğitim Enstitüsü Müdürü



“Bu tezde yer alan bilgiler akademik kurallara ve etik ilkelere uygun olarak elde edildi ve sunuldu. Ayrıca bu çalışmadan kaynaklanmayan herhangi bir atıfta bulunmadığımı garanti ederim.”

Omer Farhan AL-HARDANEE

ÖZET

Doktora Tezi

HİDROELEKTRİK SANTRALLERİNDE GERÇEK ZAMANLI VERİLERE DAYALI ARIZA TAHMİN ETMEK VE ÖNLEMEK İÇİN MAKİNE ÖĞRENMESİ TEMELLİ KONTROL SİSTEMİ GELİŞTİRİLMESİ

Omer Farhan AL-HARDANEE

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalında

Tez Danışmanı:

Prof. Dr. Hüseyin DEMİREL

Nisan 2025, 240 sayfa

Son yıllarda, algoritmalar, geleneksel kontrol sistemlerinin geliştirilmesinde önemli bir rol oynamaya başlamış, bu sistemlerin performansını artırmış ve daha doğru ve verimli hale getirmiştir. Algoritmaların, kontrol sistemlerinin hataları gerçekleşmeden önce yüksek doğrulukla tahmin etme ve bunlardan kaçınma yeteneği, büyük önem taşıyan ve yüksek verimli bir süreç olmasından dolayı, bu tür sistemlerin başarısını önemli ölçüde artırmıştır. Bu da felaket hatalarının önlenmesini sağlar. 2019 yılında, dünya genelindeki toplam elektrik üretiminin %16'sından fazlası hidroelektrik santrallerinden sağlanmıştır. Tipik bir hidroelektrik santralinin çekirdeğini türbinler oluşturur.

Türbinler, suyun içinden geçerken yüksek seviyelerde basınca, titreşime, yüksek sıcaklıklara ve hava boşluklarına maruz kalmaktadır. Suyun türbin kanatlarından geçerken, bu ani artışlar nedeniyle tonlarca ağırlığındaki türbin kanatları kırılabilmektedir. Bu, yol açtığı büyük hasar nedeniyle trajik bir kazadır. Bu araştırma, hidroelektrik santrallerinin kontrol sistemlerini yapay zeka kullanarak geliştirmeyi amaçlamaktadır. Bu sayede, bu santrallerin durumunu etkileyen tüm faktörlere dair gerçek bir veritabanına dayalı olarak durumu doğru bir şekilde tahmin edebilmek ve bu sonuçları, türbinlerin çalışmasını kontrol etmek için kullanarak herhangi bir hasarı önlemek mümkün olacaktır.

Bu santrallerin gelecekteki durumuna dair tipik bir prediktif modelin kontrol sistemiyle entegrasyonu, türbin kanadı kırılmalarını ve güç santrallerindeki felaket kazalarını, bunların neden olduğu hasarları önlemenin, bu santrallerin ömrünü artırmanın, ani kapanmaları engellenin ve elektrik enerjisi üretiminde istikrarı sağlamanın önemini taşımaktadır. Bu sistemi ayıran özellik, santrallerde kullanılan izleme ve kontrol sistemleriyle entegrasyon olasılığına sahip olması ya da bir GUI tabanlı bağımsız entegre bir sistem olarak kullanılabilmesidir. Bu çalışmada, hidroelektrik santralinin durumunu tahmin etmek, hatayı oluşmadan önce tespit etmek ve önlemek amacıyla yapay sinir ağı algoritmaları (RNN ve LSTM) kullanılmıştır. Yapılan testler sonrasında, LSTM algoritması, en yüksek doğruluk ve en düşük hata açısından en iyi sonuçları elde etmiştir. Sonuçlara göre, LSTM modeli %99.55 doğruluk, 0.0072 ortalama kare hata (MSE) ve 0.0053 ortalama mutlak hata (MAE) elde etmiştir.

Anahtar Sözcükler : RNN, LSTM, Titreşim, Sıcaklık, Türbin, Baraj, Kontrol sistemi.

Bilim Kodu : 90529

ABSTRACT

Ph. D. Thesis

DEVELOPING A MACHINE LEARNING BASED CONTROL SYSTEM TO PREDICT AND PREVENT FAILURES IN HYDROELECTRIC POWER PLANTS BASED ON REAL-TIME DATA

Omer Farhan AL-HARDANEE

**Karabük University
Institute of Graduate Programs
Department of Electrical-Electronics Engineering**

Thesis Advisor:

Prof. Dr. Hüseyin DEMİREL

April 2025, 240 pages

In recent years, algorithms have begun to play a pivotal role in developing traditional control systems, improving their performance, and making them more accurate and efficient due to their importance and high efficiency in the prediction process, which enables control systems to know errors before they occur with high accuracy and avoid them, which avoids catastrophic errors. In 2019, more than 16% of the world's total electricity production was provided by hydroelectric power plants. The core of a typical hydroelectric power plant is the turbine.

Turbines are exposed to high levels of pressure, vibration, high temperatures, and air gaps as water passes through them. Turbine blades weighing several tons break due to these sudden increases, which is a tragic accident due to the enormous damage they cause.

This research aims to develop hydroelectric power plant control systems using artificial intelligence to accurately predict the status of these stations based on a real database stored for all factors affecting the status of these stations and use this result to control the operation of the turbines to avoid any damage.

The importance of having a typical predictive model for the future status of these plants integrated with the control system lies in avoiding turbine blade breakage and catastrophic accidents in power plants and the resulting damage, increasing the life of these plants, avoiding sudden shutdown, and ensuring stability in the generation of electrical energy. What distinguishes this system is the possibility of integrating it with the monitoring and control systems used in these plants or using it as a separate integrated system based on a GUI. In this study, artificial neural network algorithms (RNN and LSTM) are used to predict the status of the hydropower plant, identify the error before it occurs, and avoid it. After testing, the LSTM algorithm achieved the greatest results in terms of the highest accuracy and the lowest error. According to the results, the LSTM model achieved an accuracy of 99.55%, a mean square error (MSE) of 0.0072, and a mean absolute error (MAE) of 0.0053.

Key Word : RNN, LSTM, Vibration, Temperature, Turbine, Dam, Control system.

Science Code : 90529

TEŞEKKÜR

Bu tezin tamamlanmasında bilgi ve deneyimlerinden yararlandığım danışman hocam Prof. Dr. Hüseyin DEMİREL'e ve tezimin takip edilmesi sürecinde desteğini esirgemeyen.

Tik üyebrimiz Prof. Dr. Hüseyin CANBOLAT ve Prof. Dr. Ziyadulla YUSUPOV hocalarına teşekkür ederim.

Ayrıca tez sorunuma jurisinde katkılarından dolayı Prof. Dr. Serhat Orkun TAN ile Dr. Öğr. Üyesi Abdullah ORMAN hocalarıma da şükranlarımı sunarım.

Ayrıca öğrenim hayatım boyunca emek veren, maddi ve manevi desteğim olan ve bu başarıya ulaşana kadar öğrenimime devam etmemdeki en büyük motivasyonum olan babama, anneme, kardeşlerime en içten teşekkürlerimi ve takdirlerimi sunarım. Tüm amcalarımı, arkadaşlarımı ve diğer öğretmenlerimi asla unutmayacağım.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xiv
ÇİZELGELER DİZİNİ	xviii
SİMGELER VE KISALTMALAR DİZİNİ	xix
BÖLÜM 1	1
GİRİŞ	1
1.1. MOTİVASYON VE ARAŞTIRMA PROBLEMİ	8
1.2. ARAŞTIRMA AMAÇLARI VE KATKILARI	10
1.3. TOPLANAN VERİLER (VERİ SETLERİNE GENEL BAKIŞ)	12
1.4. İLGİLİ ÇALIŞMA	12
1.4.1. Hidro Türbinler ve Kontrol Sistemleri Üzerine Çalışmalar	12
1.4.2. Hidroelektrik Alanında AI Kullanımı	15
1.4.1.1. Yapay Zekanın Performans Optimizasyonu İçin Uygulamaları	15
1.4.1.2. Yapay Zekanın Bitki Parametrelerinin Tahmini İçin Uygulamaları	17
1.4.1.3. HES'lerin İzlenmesi ve Kontrolünde Yapay Zeka Uygulamaları	25
1.4.1.4. Yapay Zekanın Politika ve Özellik Seçiminde Uygulanması	27
1.4.1.5. Yapay Zekanın Fizibilite Çalışmasındaki Uygulamaları	28
1.4.1.6. Doğruluk Değerlendirmesi ve Yetenek Değerlendirmesi İçin Yapay Zekanın Uygulanması	29
1.5. TEZ ORGANİZASYONU	34

	<u>Sayfa</u>
BÖLÜM 2	36
TEORİK ARKA PLAN	36
2.1. KONTROL SİSTEMLERİ.....	37
2.1.1. Kontrol Sistemlerine Genel Bakış	37
2.1.1.1. Hidroelektrik Santrali İçin Otomasyon.....	37
2.1.1.2. PLC Otomasyon İçin Önemli Bir Araçtır	38
2.1.1.3. Hidroelektrik Santral İçin Scada Sistemi.....	39
2.1.1.4. Field Instrument	40
2.1.1.5. İletişim Protokolü.....	41
2.1.2. SCADA (Gözetimsel Kontrol ve Veri Toplama) Sistemleri	42
2.1.2.1. Sistemin Ele Aldığı Sorunlar	46
2.1.2.2. SCADA Sistemleri Sinyalleri	48
2.1.2.3. SCADA Sisteminin Ana Bileşenleri.....	49
2.1.2.4. SCADA Sistemlerinin Nesilleri.....	57
2.1.3. MATLAB ve GUI.....	61
2.1.3.1. MATLAB: Genel Bakış.....	61
2.1.3.2. MATLAB'ın Temel Özellikleri	61
2.1.3.3. MATLAB Uygulamaları.....	63
2.1.3.4. Avantajlar ve Sınırlamalar	64
2.1.3.5. Grafikselsel Kullanıcı Arayüzü (GUI)	65
2.1.3.6. Grafikselsel Kullanıcı Arayüzü ve Etkileşim Tasarımı.....	66
2.1.4. İşlem Birimi	68
2.1.5. Hidroelektrik Santrallerinde Kullanılan Saha Ekipmanları.....	71
2.1.5.1. Genel Bileşenler.....	71
2.1.5.2. Mekanik ve Hidrolik İzleme	76
2.1.5.3. Titreşim ve Yapısal Sağlık İzleme.....	87
2.1.5.4. Elektrikselsel Performans İzleme	93
2.1.5.5. Regülatör Kontrol Sistemi	102
2.1.5.6. Uyarım Sistemi	103
2.2. TAHMİN VE ÖNGÖRÜ.....	104
2.2.1. Tahmin ve Öngörü Kavramı.....	104
2.2.2. Tahmin Süreci.....	106

	<u>Sayfa</u>
2.2.3. Tahmin Teknikleri	108
2.2.3.1. Nitel Tahmin	108
2.2.3.2. Nicel Tahmin	110
2.2.4. Tahminlemenin Sınırlamaları	114
2.2.5. Planlama ve Tahmin	115
2.2.6. Üretim ve İşletmede Tahminin Önemi	116
2.3. YAPAY ZEKA ve TAHMİN	118
2.3.1. AI Tahmin Uygulamaları	118
2.3.1.1. Finansal Planlama	118
2.3.1.2. Üretim Planlaması	119
2.3.1.3. Satış Tahmini	119
2.3.1.4. Tedarik Zinciri Tahmini	119
2.3.2. Tahmin Yazılımı	120
2.3.2.1. Makine Öğrenimi	120
2.3.2.2. Derin Öğrenme	121
2.3.2.3. Yapay Sinir Ağı (YSA)	121
2.3.3. Sinir Ağı ve Tahmin	121
2.3.4. Sinir Ağları ve Derin Öğrenme	122
2.4. TEKRARLAYAN SİNİR AĞI ve LSTM	124
2.4.1. Tekrarlayan Sinir Ağı Mimarisi	125
2.4.2. Tekrarlayan Sinir Ağlarının Çalışma Prensipleri	126
2.4.3. Tekrarlayan Sinir Ağı ve Evrişimli Sinir Ağları	126
2.4.4. Tekrarlayan Sinir Ağı ve İleri Beslemeli Sinir Ağı	126
2.4.5. Eğitim	128
2.4.6. Tekrarlayan Sinir Ağları Türleri	129
2.4.7. Tekrarlayan Sinir Ağlarının Avantajları	130
2.4.8. Tekrarlayan Sinir Ağlarının Zorlukları	130
2.4.9. Tekrarlayan Sinir Ağlarında Zaman İçinde Geri Yayılım	131
2.4.10. Uzun Kısa Süreli Bellek (LSTM)	133
2.5. HİDROELEKTRİK SANTRALLERİ	137
2.5.1. Hidroelektrik Kullanarak Elektrik Üretimi	138

Sayfa

2.5.2. Hidroelektrik Santrali İşletme Yöntemi ve Karşılaştığı En Önemli Hatalar	141
2.5.3. Titreşim Kaynakları	142
2.5.3.1. Döner Makinelerde Titreşimlerin Nedenleri.....	142
2.5.3.2. Dönmeyen Ekipman Titreşimlerinin Nedenleri.....	143
2.5.4. Hidro Türbin Verimliliği	143
2.5.5. Sıcaklık, Arıza ve Titreşim Arızalarının Teşhisi	144
2.5.6. Mekanik Titreşim.....	144
2.5.7. Aerodinamik Titreşim.....	144
2.5.8. Elektromanyetik titreşim	145
BÖLÜM 3	146
ARAŞTIRMA YÖNTEMİ.....	146
3.1. KONTROL SİSTEMİ ve İŞLEME BİRİMİ	146
3.1.1. SCADA Tarafından Ana İzleme ve Ölçüm	146
3.1.2. Sistem Mimarisi.....	148
3.1.2.1. Karar, İki Olasılığa Dayalı Olarak İki Aşamada Verilir.	149
3.1.3. Metodoloji.....	152
3.2. TEKRARLAYAN SİNİR AĞI RNN ve LSTM.....	153
3.2.1. Tekrarlayan Sinir Ağı Modeli.....	153
3.2.2. Uzun Kısa Süreli Bellek Ağı Yapısı.....	155
3.2.2.1 LSTM Uygulama Adımları.....	159
3.2.3. Malzemeler ve Yöntemler	163
3.2.3.1. Vaka Çalışması	163
3.2.3.2. Veri Toplama ve Açıklama	164
3.2.3.3. Keşifsel Veri Analizi (EDA).....	168
3.2.3.4. Tahmin Metodolojisi.....	175
3.2.3.5. Veri Ön İşleme	176
BÖLÜM 4	177
SONUÇLAR VE TARTIŞMA	177
4.1. KONTROL SİSTEMİ	177

Sayfa

4.2. TAHMİN SONUÇLARI	181
4.1.1. Adam Optimizer ile RNN ve LSTM Modellerini Kullanarak Tahmin	181
4.1.2. RMSprop Optimizer ile LSTM ve RNN Algoritmalarını Kullanarak Tahmin	189
4.1.3. Adagrad Optimizer ile LSTM ve RNN Algoritmalarını Kullanarak Tahmin	196
4.1.4. Adadelta Optimizer ile LSTM ve RNN Algoritmalarını Kullanarak Tahmin	202
 BÖLÜM 5	 210
SONUÇLAR	210
 KAYNAKLAR	 214
 ÖZGEÇMİŞ	 240

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1. 1. Haditha tesisindeki koşucu kanat hasarı (üst sıra) ve yapısal çatlaklar (alt sıra) [18].	4
Şekil 1. 2. HTTPs'de mekanik sıcaklık ölçüm cihazları kullanılır.	5
Şekil 1. 3. Hidroelektrikte AI uygulama alanları	15
Şekil 1. 4. (a) FEM duvar sapmasının eğitim ve (b) test sonuçları sunta [60].	16
Şekil 2. 1. Hidroelektrik santralleri	36
Şekil 2. 2. Bir hidroelektrik santrali istasyonu için otomasyon sistemi	38
Şekil 2. 3. Bir hidroelektrik santralinin SCADA ekranı	40
Şekil 2. 4. SCADA sistemine genel bakış.	49
Şekil 2. 5. Geniş alan ağı SCADA	53
Şekil 2. 6. SCADA ana bilgisayar platformu	54
Şekil 2. 7. Enstrümantasyonun ilerlemesi	56
Şekil 2. 8. Monolitik veya erken SCADA sistemleri	57
Şekil 2. 9. Dağıtılmış SCADA sistemleri	58
Şekil 2. 10. Ağ Bağlantılı SCADA sistemleri	59
Şekil 2. 11. Nesnelerin İnterneti	60
Şekil 2. 12. Grafıksel kullanıcı arayüzünün katmanlarının şeması [203].	68
Şekil 2. 13. Raspberry Pi 5 İşlem Birimi	69
Şekil 2. 14. Limit anahtarları	72
Şekil 2. 15. Basmalı düğmeler	73
Şekil 2. 16. Şamandıra anahtarı	74
Şekil 2. 17. Relay contact	75
Şekil 2. 18. Seçici anahtar	75
Şekil 2. 19. Akış Sensörü	76
Şekil 2. 20. Su Seviye Sensörleri	78
Şekil 2. 21. Sıcaklık Sensörleri	80
Şekil 2. 22. Deplasman Sensörleri	82
Şekil 2. 23. Hidroelektrik Santralindeki sensör konumları.	83
Şekil 2. 24. Basınç Sensörleri	86

Sayfa

Şekil 2. 25. Hava Boşluğu Sensörü.....	87
Şekil 2. 26. Hidro Türbin Titreşim İzleme için Hidro Sensörler	88
Şekil 2. 27. Yakınlık Probları Sensörü.....	89
Şekil 2. 28. Yakınlık Probları Sensör konumu.....	90
Şekil 2. 29. Gerinim Ölçer Sensörü	92
Şekil 2. 30. Akım Trafoları (CT).	96
Şekil 2. 31. Tahmin Sürecindeki Adımlar.....	108
Şekil 2. 32. Tahmin Adımları.....	114
Şekil 2. 33. Tahminin önemi	116
Şekil 2. 34. En Popüler Tahmin Uygulamalarından Bazıları.....	120
Şekil 2. 35. Derin sinir ağları	123
Şekil 2. 36. Bir RNN'nin diyagramını gösterir.....	125
Şekil 2. 37. Tekrarlayan Sinir Ağı	127
Şekil 2. 38. Tekrarlayan Sinir Ağı ve İleri Beslemeli Sinir Ağı	127
Şekil 2. 39. Tekrarlayan Sinir Ağlarının Ana Türleri	129
Şekil 2. 40. Gelişmiş bir sinir ağında yayılma ve yayılma kavramı	132
Şekil 2. 41. Resimde Açılmamış Bir RNN Gösterilmektedir	133
Şekil 2. 42. RNN Scheme with Three Gates	135
Şekil 2. 43. Uzun süreli kısa süreli bellek blok diyagramı yapısı.	135
Şekil 2. 44. Yakıta göre dünya elektrik üretimi.	137
Şekil 2. 45. 2023'e kadar dünya çapında elektrik üretim kaynağı.....	138
Şekil 2. 46. Hidroelektrikten elektrik üretiminin payı, 2023.	139
Şekil 2. 47. Hidroelektrik Santrallerinin Sınıflandırılması	139
Şekil 2. 48. Hidroelektrik Barajı	141
Şekil 2. 49. (a) Hidro jeneratörlerdeki hasarlar ve (b) arızanın temel nedenleri [15].	142
Şekil 2. 50. Türbin kavitasyon hasarı.....	145
Şekil 3. 1. SCADA sistemi.....	149
Şekil 3. 2. Sistem mimarisi	150
Şekil 3. 3. İzleme sisteminin akış şeması	151
Şekil 3. 4. Sensörlerin konumu	153
Şekil 3. 5. Tekrarlayan bir sinir ağının yapısı	154
Şekil 3. 6. LSTM'nin detaylı yapısı.....	155
Şekil 3. 7. Bir LSTM biriminin temel bir açıklayıcı gösterimi.....	157

Şekil 3. 8. Bir LSTM Modelindeki Hücre Durumu.	157
Şekil 3. 9. Zaman içinde açıldığında bir LSTM'nin şematik gösterimi.	158
Şekil 3. 10. LSTM'deki ilk adım: Hangi bilgilerin unutulacağına veya saklanacağına karar verin.	160
Şekil 3. 11. LSTM'deki ikinci adım, bellek hücresinin içeriğini güncellemektir. ...	161
Şekil 3. 12. LSTM modellemesinde 3. Adım.....	161
Şekil 3. 13. LSTM modellemesinde 4. Adım.....	162
Şekil 3. 14. Araj istasyonu arıza tespit modeli için iş akışı sistemi.	163
Şekil 3. 15. Türkiye, Çorum İli'ndeki Obruk hidroelektrik santralinin konumu.....	164
Şekil 3. 16. Veri setindeki titreşim özellikleri için korelasyon katsayısı.	170
Şekil 3. 17. Veri setindeki sıcaklık özellikleri için korelasyon katsayısı.....	171
Şekil 3. 18. Veri setindeki basınç özellikleri için korelasyon katsayısı.	171
Şekil 3. 19. Veri setindeki farklı değişkenlerin birleşik özelliklerinin veritabanı için korelasyon katsayısı.	172
Şekil 3. 20. Zaman içinde haftanın günlerindeki sistem kararlılığı (8 Ağustos 2021 - 15 Ağustos 2021).	173
Şekil 3. 21. Sistemin kararlılığının doğası.	173
Şekil 3. 22. Tüm veriler için NaN'ler.	174
Şekil 3. 23. HES durum tahmin algoritmalarının metodolojisi.....	175
Şekil 4. 1. İzleme sistemi için GUI	178
Şekil 4. 2. İzleme sistemi için GUI	180
Şekil 4. 3. Adam optimizatörü ve bir katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.	183
Şekil 4. 4. Adam optimizatörü ve iki katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.	185
Şekil 4. 5. Adam optimizatörü ve üç katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.	187
Şekil 4. 6. RMSprop optimizatörü ve bir katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.	190
Şekil 4. 7. RMSprop optimizatörü ve iki katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.	192
Şekil 4. 8. RMSprop optimizatörü ve 3 katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.	194
Şekil 4. 9. Adagrad optimizatörü ve bir katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.	197
Şekil 4. 10. Adagrad optimizatörü ve iki katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.	199

Sayfa

Şekil 4. 11. Adagrad optimizatörü ve üç katmanı kullanan bir S-S HPP istasyonu için tahmin sonuçları.	201
Şekil 4. 12. Adadelata optimizatörü ve bir katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.	204
Şekil 4. 13. Adadelata optimizatörü ve iki katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.	206
Şekil 4. 14. Adadelata optimizatörü ve üç katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.	208



ÇİZELGELER DİZİNİ

Sayfa

Çizelge 1. 1. Performans optimizasyonu için AI uygulamalarının özeti	17
Çizelge 1. 2. İstatistiksel ölçümlerin ortalama değerleri [65].	18
Çizelge 1. 3. Yapay zekanın HPP parametrelerini tahmin etmedeki uygulamalarına ilişkin bir özet sunar.	23
Çizelge 1. 4. Yapay zekanın hidroelektrik santrallerinin izlenmesi ve kontrolündeki uygulamalarının özeti.	27
Çizelge 1. 5. Yapay zekanın politika ve özellik seçiminde uygulanmasının özeti	28
Çizelge 1. 6. Yapay Zeka'nın uygulanabilirlik çalışması için uygulamalarının özeti	29
Çizelge 1. 7. Doğruluk değerlendirmesi ve yetenek değerlendirmesi için yapay zekanın uygulamalarının bir özetini sunmaktadır.	31
Çizelge 1. 8. Raspberry Pi kullanımları ve uygulamalarının özeti	34
Çizelge 2. 1. Hidroelektrik santral sınıflandırması	140
Çizelge 2. 2. Hidroelektrik Santralleri Kapasitesi.....	140
Çizelge 3. 1. Kapıların açılıp kapanma kuralları.....	152
Çizelge 3. 2. Tahminde on kaydı temsil eden bir titreşim verisi seti kullanılmıştır.	165
Çizelge 3. 3. Tahminde on kaydı temsil eden bir basınç verisi seti kullanılmıştır. .	165
Çizelge 3. 4. Tahminde on kaydı temsil eden bir sıcaklık verisi seti kullanılmıştır.	166
Çizelge 3. 5. Basınç verisi limitleri.....	167
Çizelge 3. 6. Güç, voltaj, hız, seviye ve $\cos \alpha$ veri sınırları.....	167
Çizelge 3. 7. Sıcaklık verisi limitleri.....	168
Çizelge 4. 1. İlk model için kurallar.....	180
Çizelge 4. 2. İkinci model için kurallar.....	180
Çizelge 4. 3. Adam optimizasyon aracını kullanarak her iki model için tahmin sonuçları.	188
Çizelge 4. 4. RMSprop optimizatörü kullanılarak her iki model için tahmin sonuçları.	195
Çizelge 4. 5. Adagrad optimizatörü kullanılarak her iki model için tahmin sonuçları.	202
Çizelge 4. 6. Adadelta optimizatörü kullanan her iki model için tahmin sonuçları.	209

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

x_t	: bir giriş vektörü (an input vector)
y_t	: bir çıkış vektörü (an output vector)
C_{t-1}	: eski hücre durumu (old cell state)
C_t	: yeni hücre durumu (new cell state)
f_t	: fourier dönüşümü (fourier transform)
$E(t)$	: zamanın bir fonksiyonu olarak hatadır (error as a function of time)
$M(t)$	: denetleyici çıktısıdır (controller output)
K_d	: türev sabitleri (derivative constants)
K_p	: orantılı sabitleri (proportional constants)
K_i	: integral sabitleri (integral constants)
T	: örnekleme aralığı (sampling interval)
E_i	: i'inci örnekleme aralığındaki Hata (Error at a second sampling interval)
E_{i-1}	: önceki örnekleme aralığında hata (error in the previous sampling interval)
M	: toplama n örnek sayısıdır (number of samples collected)
S_i	: hataların toplamıdır (sum of the errors)
r	: bileşenler arasındaki korelasyon katsayısını (correlation coefficient between components)
X_t	: t zamanındaki HPP üretiminin beklenen değeri (expected value of HPP production in time t)

KISALTMALAR

DL	: Derin Öğrenme (Deep Learning)
ANN	: Yapay Sinir Ağları (Artificial Neural Network)
RNN	: Tekrarlayan Sinir Ağı (Recurrent Neural Network)
PNN	: Olasılıksal Sinir Ağı (Probabilistic Neural Network)
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
HEPP	: Hidroelektrik Santralleri (Hydroelectric Power Plant)
ANN	: Yapay Sinir Ağları (Artificial Neural Network)
GUI	: Grafiksel Kullanıcı Arayüzü (Graphical User Interface)
MSE	: Ortalama Karesel Hata (Mean Square Error)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
RMSE	: Kök Ortalama Kare Hatası (Root Mean Square Error)
Acc	: Doğruluk (Accuracy)
Val	: Doğrulama (Validation)
SCADA	: Denetleyici Kontrol ve Veri Toplama (Supervisory Control and Data Acquisition)
SHP	: Kaynak Hidroelektrik (Sources Hydropower)
STA	: Standart (Standard)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
GA	: Genetik Algoritma (Genetic Algorithm)
GWO	: Gri Kurt Optimizasyonu (Grey Wolf Optimization)
MIP	: (En Önemli Parametre) Most Important Parameter
MS	: (Mikro Sismik) Micro Seismic
NF	: (Nöro-Bulanık) Neuro-Fuzzy
WT	: Dalgacık Eşikleme (Wavelet Thresholding)
ANFIS	: Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System)
DELM	: Erken Latin El Yazmaları Veritabanları (Databases of Early Latin Manuscript)
RTU	: Uzak Terminal Birimi (Remote Terminal Unit)
PLC	: Programlanabilir Mantık Denetleyicisi (Programmable Logic Controller)

DNP	: Dağıtılmış Ağ Protokolü (Distributed Network Protocol)
IEC	: Uluslararası Elektroteknik Komisyonu (International Electrotechnical Commission)
ICS	: endüstriyel kontrol sistemi (industrial control system)
DCS	: Dağıtılmış Kontrol Sistemi (Distributed Control System)
RTC	: Gerçek Zamanlı Saat (Real-Time Clock)
MTU	: Ana Terminal Ünitesi (Master Terminal Unit)
IED	: Akıllı Elektronik Cihaz (Intelligent Electronic Device)
DI	: Dijital Giriş (Digital Input)
DO	: Dijital Çıkış (Digital Output)
AI	: Analog Giriş (Analog Input)
AO	: Analog Çıkış (Analog Output)
HMI	: İnsan Makine Arayüzü (Human Machine Interface)
PAC	: Programlanabilir Otomasyon Kontrol Cihazı (Programmable Automation Controller)
OIT	: Operatör Arayüz Terminali. (Operator Interface Terminal)
FEP	: Ön Uç İşlemcisi (Front-End Processor)
FED	: Ön Uç Sürücüsü (Front-End Driver)
OLE DB	: Veritabanları için Nesne Bağlantısı ve Gömme (Object Linking and Embedding for Databases)
ODBC	: Açık Veritabanı Bağlantısı (Open Database Connectivity)
NO	: Normalde Açık (Normally Open)
NC	: Normalde Kapalı (Normally Closed)
RTD	: Direnç Sıcaklık Dedektörleri (Resistance Temperature Detectors)
LVDT	: Doğrusal Değişken Diferansiyel Transformatörler (Linear Variable Differential Transformers)
CT	: Akım Transformatörü (Current Transformer)
AC	: Alternatif Akım (Alternating Current)
DC	: Doğru Akım (Direct Current)
VSHF	: Değişken Hızlı Hidroelektrik Santralleri (Variable Speed Hydropower Plants)
PSS	: Güç Sistemi Sabitleyicisi (Power System Stabilizer)

LAN	: Yerel Alan Ağı (Local Area Network)
CLI	: Komut Satırı Arayüzü (Command-Line Interface)
MVC	: Model-Görünüm-Denetleyici (Model-View-Controller)
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
USB	: Evrensel Seri Veri Yolu (Universal Serial Bus)
LLM	: Büyük Dil Modeli (Large Language Model)
BPTT	: Zaman İçinde Geri Yayılım (Back-Propagation Through Time)
ASL	: Deniz Seviyesinin Üzerinde (Above Sea Level)
FM	: Akış Ölçerler (Flow Meters)
RoR	: Nehir akışı (Run-of-River)
EDA	: Keşifsel Veri Analizi (Exploratory Data Analysis)
DELM	: Erken Latin El Yazmaları Veritabanları (Databases of Early Latin Manuscripts)
EMD-GRU	: Deneyisel Mod Ayırıştırma-Kapılı Tekrarlayan Birim (Empirical Mode Decomposition-Gated Recurrent Unit)
RF	: Rastgele Orman (Random Forest)

BÖLÜM 1

GİRİŞ

Enerji, herhangi bir ülkenin sosyal ve ekonomik kalkınması için temel bir girdidir, çünkü insan toplumlarının enerji ve elektriğe olan ihtiyacı ekonomik refahta temel bir faktörle ilişkilendirilmiştir. Bu ihtiyaç, ülkelerin yaşamın her alanında tanık olduğu önemli gelişme ve nüfus artışıyla aynı zamana denk gelerek son yıllarda artmıştır [1]. Fosil kaynaklar, yaşamı sürdürmede hayati bir bileşen haline gelen enerji üretiminde yaygın olarak kullanılmaktadır. Bu enerji kaynaklarına olan artan bağımlılık, uzun vadeli ve geri döndürülemez çevresel hasara yol açmaktadır. Günümüzde ülkeler, temiz enerji kaynaklarının oranını artırmak için planlar geliştirirken, fosil enerji kaynaklarının kullanımını azaltmak ve küresel ısınmayı sınırlamak için önemli çabalar göstermektedir [2].

Dünya giderek daha fazla enerji kaynağından yararlanmaya ilgi duymaya başladıkça, dikkat yenilenebilir enerjiye kayıyor. Tüm yenilenebilir enerji kaynakları arasında, hidroelektrik (SHP), elektrik üretimi için en uygun maliyetli ve çevre dostu teknolojilerden biridir [3].

Hidroelektrik enerjisi, yirminci yüzyılın başlarında elektrik üretmek için büyük ölçekte geliştirilmeye başlandı. O yüzyılın ortalarında, yenilenebilir bir enerji kaynağı olarak kabul edildi [4, 5].

Hidroelektrik santralleri (HES'ler), dünya çapında birçok ülkenin toplam elektrik ihtiyacının %25'inden fazlasına katkıda bulunmaktadır. Ek olarak, hidroelektrik santralleri 65 ülkede elektrik talebinin %50'sini, 32 ülkede %80'ini ve 13 ülkede neredeyse tüm elektrik talebini karşılamaktadır. 2019 yılına kadar toplam 1.307 gigawatt hidroelektrik santrali kurulmuş olup, o yılki küresel elektrik üretiminin

%16'sını oluşturmaktadır [6]. Hidroelektrik santrallerinden elde edilen toplam elektrik üretimi, dünya elektriğinin yaklaşık %20'sidir [7].

Dünyada elektrik üretmek için su barajları kullanan ülkelerde, özellikle elektrik üretimi ile daha fazla elektrik üretme ihtiyacı arasındaki büyük farktan muzdarip olan Doğu Asya ülkelerinde hidroelektrik santrallerinin çalışma koşulları nedeniyle, santraller gerekli elektriği sağlamak ve üretimdeki açığı ve açığı kapatmak için azami çabayla çalışmakta ve bu da bu santralleri çok kötü çalışma koşullarına sokmaktadır. Bu kötü çalışma koşulları, özellikle türbinlerde belirgindir, çünkü bunlar hidroelektrik santrallerinin çekirdeğidir ve su basınç enerjisini mekanik kinetik enerjiye dönüştürme sürecinin eksenidir, bu da jeneratör çekirdeklerinin dönüşünü sağlar ve elektrik gücü üretir. Bu süreç, türbini yüksek dinamik yüklere karşı savunmasız hale getirir ve düşman kanatlarının çatlaması ve kırılması riskini artıran olumsuz etkiye sahip çok sayıda faktöre maruz bırakır. Bu koşullar, Irak ve Suriye gibi ülkelerin yaşadığı uzun süreli ekonomik sıkıntıların bir sonucu olarak bakım çalışmalarının uzun süreli askıya alınmasıyla daha da kötüleşir [8-10].

Hidroelektrik enerji kullanarak elektrik üreten şirketlerin karşılaştığı en önemli engellerden biri, özellikle kanal kanatlarında olmak üzere tüm bileşenlerinde yüksek korozyona uğrayan üretim istasyonlarının, özellikle türbinlerin durumunun bilinmemesidir; bu kanatlar, yüksek dinamik yükleme ve yüksek titreşim dalgalarına, yüksek basınca ve sıcaklığa maruz kalma sonucu kanatlarını çatlatmaya meyillidir ve su basıncının etkisi ile, ayrıca birkaç ton ağırlığındaki kanatların kırılmasına yol açan bir hava boşluğu oluşması ve bunun sonucunda ekonomi, geçim kaynağı ve üretim üzerinde riskler ve feci kazalar meydana gelmesi, işçilerin hayatlarını tehlikeye atması ve bu çarpışmanın barajın yapısına olan etkisinin onu yıkılma riskine maruz bırakabilmesi ve sakinlerin hayatlarını tehlikeye atabilmesi ve yüksek malzeme maliyetleri ile diğer kıtalardaki ülkelerdeki fabrikalardan bakım çalışması yaptırma ve yedek parça satın alma ihtiyacının ortaya çıkabilmesi, bu da daha fazla maddi ve ekonomik kayıp anlamına gelmektedir. Özellikle bu istasyonlar üretici tarafından belirlenen ve garanti edilen optimum çalışma aralığı olmaksızın uzun bir süre (neredeyse tüm yıl boyunca) çalışmaktadır [5, 11, 12].

Alışma koşullarını daha da kötüleştiren şey, bazı baraj göllerindeki su seviyesinin, bazı bölgelerin son birkaç yıldır yaşadığı kuraklık nedeniyle düşük olmasıdır [13, 14]. Tüm bunlar, bunları üretici tarafından garanti edilen çalışma aralığının dışına yerleştirerek, güç üretimi için yüksek performans ve türbinin hayati kısmında dayanıklı mekanik mukavemet sağlar [6]. Benzer koşullar yaşayan Haditha ve Obruk istasyonları gibi, hemen hemen tüm hidroelektrik santralleri, çalışmalarının benzer doğası nedeniyle benzer sorunlardan muzdariptir [9].

Haditha Barajı, Irak'ın Anbar Valiliği'ndeki Haditha şehrinin kuzeyinde, Fırat Nehri üzerinde bulunan bir toprak barajdır. En önemlileri hidroelektrik güç üretmek, Fırat Nehri'nin akışını düzenlemek ve sulama için su sağlamak olan çok amaçlı bir baraj olarak inşa edilmiştir. Irak'ın hidroelektrik güç sistemine en büyük ikinci katkıyı yapan barajdır ve Anbar Valiliği'nde başka bir elektrik santrali yoktur; bu açıdan bakıldığında, Irak'ın bu bölgesi için ana enerji kaynaklarından biri olarak kabul edilir. Haditha Barajı, her biri 110 megavat, toplamda 660 megavat üreten altı Kaplan türbininden oluşmaktadır. İstasyon 1986 yılında hizmete açılmış ve faaliyete başlamıştır [15].

Bu hidroelektrik santralleri, büyük üretim açığını kapatmak için maksimum kapasitede ve çok yüksek dinamik yük ile son derece zorlu çalışma koşulları altında çalışmaktadır. Makinelerin eskimesi ve uzun rehabilitasyon süreleri nedeniyle, tüm bunlar bu istasyonların verimliliğini artırmanın önünde büyük bir engel ve zorluk haline gelmiştir ve dolayısıyla yeterli enerji sağlamanın ve güvenliklerini sürdürmenin önünde bir engeldir. Yüksek dinamik yük, kanatlar ve şasi dahil olmak üzere türbin bileşenlerini ve ayrıca güç jeneratörü ve iletim şaftını doğrudan etkiler. Bu, Haditha Barajı'nda ve çoğu barajda yaygın bir sorundur [8, 16].

Yukarıda belirtilen işletme koşulları nedeniyle, barajın işletme ünitelerinden biri olan 5 No'lu Ünite, türbindeki iki koşucu kanadının tamamen kırıldığı ve diğer dört kanadın kavitasyon olayları nedeniyle ciddi aşınmaya uğradığı keşfedildikten sonra kaybedildi. Ayrıca kalan beş ünitenin tümünün koşucu kanatlarında ciddi kavitasyon aşınması olduğu ve Şekil 1.1'de gösterildiği gibi yüksek dinamik yükleme nedeniyle 2 No'lu ünite kanatlarından birinin yüzeyinde çatlak olduğu bulundu. Titreşim ve basınçta ani

bir artış, kanat kırılmasına ve kaçınılması gereken trajik bir kazaya yol açacaktır [15, 17].

Elektrik üretmek ve ihtiyaç duyulan miktarın büyük bir yüzdesini karşılayacak şekilde maksimum kapasitede çalıştırılması ve temiz, yenilenebilir enerji olması için barajlara odaklanmanın arttığı bir zamanda, su türbinlerinin arızalanmasıyla ilgili çeşitli riskler ve bunların santralin işletme faaliyetleri ve elektrik enerjisinin ideal üretimi üzerindeki etkileri artmaktadır [19, 20].




Şekil 1. 1. Haditha tesisindeki koşucu kanat hasarı (üst sıra) ve yapısal çatlaklar (alt sıra) [18].

Hidroelektrik santralleri, baraj gölündeki su seviyesi gibi titreşimler, basınç, sıcaklık ve diğer etki eden faktörler dahil olmak üzere durumlarını etkileyen faktörleri izleyen izleme sistemlerine sahiptir ve bu da santrallerin durumu, arıza yerleri ve zayıf okumalara sahip faktörler hakkında bilgi sağlar. Hidroelektrik santrallerinde kullanılan en modern sistemler izleme amaçlıdır. Çeşitli sensörlerin elektronik sinyali okumaya ve bunları (SCADA) gibi sistemlerde görüntülemeye dayalı kontrol sistemleri, gerçek zamanlı olarak durumun entegre okumalarını sağlar ve buna dayanarak, hata

oluştığında bir uyarı sinyali verilebilir, bu da hatanın devam etmesini azaltmada ve üretim ünitesinin mekanik bileşenlerinin güvenliğini sağlamada ve güvenliğini sağlamada önemlidir [16, 17].

Bazı hidroelektrik santrallerinde ayrıca bağımsız izleme sistemleri bulunur, çünkü bu sistemler sensörlerden gelen sinyalleri okumak ve görüntülemek için çalışır. Bazı istasyonlarda ayrıca, Şekil 1.2'de gösterildiği gibi çeşitli etki faktörlerini izlemek için mekanik ölçüm cihazlarına güvendikleri için bu sistemlerin en eskisi olan elektronik olmayan izleme sistemleri bulunur.



Şekil 1. 2. HTTPs'de mekanik sıcaklık ölçüm cihazları kullanılır.

Hidroelektrik santrallerinde etki eden faktörler için izleme sistemleri olmasına rağmen, çoğu elektronik sensörlere dayalı olarak tasarlanmış sistemlere dayanmaktadır, bu sistemlerin etkisi, titreşim, basınç, sıcaklık vb. gibi etki eden faktörlerden birinin seviyesini gösteren bir dizi sinyal görüntülemek için çalışan geleneksel çalışma yapıları nedeniyle oldukça sınırlıdır. Bu sistemler, hatalar meydana geldiğinde bunları gösterir ve alarm cihazlarını çalıştırmak için bir sinyal tetikler. Bu, istasyonları, istasyonun gelecekteki durumundan habersiz oldukları için birkaç ton ağırlığındaki türbin kanatlarının kırılmasına yol açabilecek risklerden kurtarmaz, bu da özellikle bu faktörlerin seviyesi hızla değişebildiğinden, felaketi önlemek için bilinçli bir karar vermeyi zorlaştırır.

Çeşitli alanlarda dijital gelişimin ilerlemesi ve verilerin her an ardışık dijital forma dönüştürülmesi ve bulut depolama, sensör ağları, sosyal ağlar ve çok sayıda diğer ağlar gibi çeşitli ağlar aracılığıyla işlendikten sonra büyük veri tabanlarında toplanması ve depolanmasıyla birlikte. Gelecekteki durum ve desen tanıma, makine öğrenimi, istatistiksel veri analizi ve genel olarak veri bilimi bundan faydalanabilir [21]. Bu miktardaki veri, verimli bir şekilde alma ve analiz etme konusunda zorluklar sunarken, hem işletmeler hem de akademisyenler için muazzam fırsatlar sunar [22].

Bu tür prosedürler için gereken üstel alan ve zaman, büyük veri kümelerini koruma ihtiyacını ortadan kaldıran yararlı özetlere sıkıştırılarak azaltılabilir. Gözetimsiz öğrenme literatürüne göre, bu özetler, verilerin anlaşılmasını geliştiren ve verilerin iyileştirilmiş görselleştirilmesini sağlayan "kümelere" benzetilebilir. Bu strateji, makine öğreniminin, desen tanımanın ve bilgi almanın temel unsurlarını birleştirir [23, 24].

Geleneksel kontrol sistemlerinin sınırlı verimliliği, hidroelektrik santrali operasyonlarını etkileyen tüm faktörler için mevcut olan muazzam miktardaki veri ve dünya çapındaki yapay zeka alanındaki ilerlemeler göz önüne alındığında, bu veriler izleme ve kontrol sistemlerinin geliştirilmesinde bir atılımın çekirdeği olarak kabul edilmektedir.

Bilgisayar teknolojisi ilerledikçe, yapay sinir ağıları [25, 26], destek vektör makineleri [27] ve aşırı öğrenme makineleri [28] gibi makine öğrenme algoritmaları, derin öğrenme teorilerinin olağanüstü modelleme ve veri işleme yeteneklerinin farklı makineler için belirgin veri analizi çözümleri sunduğu deformasyon tahmin modellerinde giderek daha yaygın hale gelmiştir [29, 30].

Ek olarak, bu algoritmalar hataları teşhis etme ve tanımlama alanına etkili bir şekilde katkıda bulunmuştur [31]. Ayrıca, geleneksel analitik modelleme kullanılarak çözülmesi çok zor olan karmaşık sorunları profesyonel olarak çözer. Derin öğrenme ve AI algoritmaları, yüksek doğrulukları, güçleri ve genel olarak mükemmel yetenekleriyle bilinir [32, 33].

Ancak, makine öğrenimi teknikleri aşırı uyum, yerel minimumlar ve modelin hiperparametrelerini belirlemedeki zorluk dahil olmak üzere çeşitli dezavantajlardan muzdariptir. Son yıllarda derin öğrenme teknolojilerinin ilerlemesiyle birlikte LSTM, hücre durumlarını ve kapıları dahil ederek gradyan patlaması, gradyan kaybolması ve geleneksel tekrarlayan sinir ağı (RNN) modellerine uzun vadeli bağımlılık sorunlarını başarıyla ele aldı [34]. LSTM modelleri, araç yörüngesi [35], akarsu akışı [36], kuyu üretimi [37], baraj deformasyonu [38, 39] ve diğer konularla ilgili olanlar da dahil olmak üzere çok sayıda tahminde yaygın olarak kullanılmıştır. Kontrol sistemleri, yapay zeka ve makine öğreniminin kontrol alanına girmesiyle yeni bir döneme girmiş ve önemli bir nitel sıçramaya işaret etmiştir.

Bu çalışmada, hidroelektrik santrallerinde kullanılan geleneksel izleme ve kontrol sistemleri, hidroelektrik santrali durum izleme teknolojisi ve gelişmiş kontrol sistemlerinde ortaya çıkan trendler olan yapay zeka, makine öğrenmesi ve derin öğrenmeye dayalı gelişmiş tahmin algoritmaları kullanılarak daha doğru, etkili ve güvenilir hale getirilmek üzere geliştirilmiştir.

Kontrol alanındaki bu nitel sıçramanın önemi, istasyonun gelecekteki durumunu bilmek ve hatayı oluşmadan önce tahmin etmek olup, bu da bu istasyonlarda ve türbinlerinde meydana gelebilecek, sakinlerin hayatlarına zarar verebilecek ve ekonomide ve geçim kaynaklarında meydana gelen kayıplara, elektrik kesintilerine,

ağır bakım çalışmalarına duyulan ihtiyaca ve çalışanların hayatlarını ve barajın yapısını tehdit edebilecek felaket sonuçlarına sahip olabilecek herhangi bir felaketi önlemek için uygun önlemlerin ve kararların alınmasına olanak tanır. Güncellenen sistemler tüm bu hasarları ve bunların sonuçlarını önleyecek, ayrıca bu istasyonların verimliliğini ve üretim miktarını artıracak ve ömrünü uzatacaktır.

1.1. MOTİVASYON VE ARAŞTIRMA PROBLEMİ

Tipik bir hidroelektrik santralinin çekirdeği türbindir. HES türbinleri, hizmet ömürlerini sürekli olarak azaltan birden fazla parametreye karşı hassastır. Mekanik kuvvetler, malzeme tahribatı, mekanik kırma, yüksek sıcaklık farkları, yüksek basınç ve titreşim, kavitasyon ve korozyon, elektrik santrallerinde çeşitli hasar türlerine neden olabilir. Bu zorluklar, enerji açığını kapatmak için artan yük ve son yıllarda Doğu Asya bölgesindeki bazı ülkelerin yaşadığı sert ve istikrarsız koşullar nedeniyle daha da kötüleşmektedir [40, 41].

Bu durum, eninde sonunda türbin kanatlarının tamamen kırılmasına ve devre dışı kalmasına yol açabilir, (Ünite No. 5 - Haditha Barajı) örneğinde olduğu gibi, türbindeki iki tahrik kanadı tamamen kırılmış ve diğer dört kanat ciddi erozyona maruz kalmıştır. Ayrıca, kalan beş ünitenin tümünün koşucu kanatlarında ciddi erozyona maruz kaldığı, Şekil 1.1'de gösterildiği gibi, yüksek dinamik yükleme nedeniyle Ünite No. 2'nin kanatlarından birinin yüzeyinde çatlak olduğu bulunmuştur.

Hidroelektrik enerji kullanarak elektrik üreten işletmelerin karşılaştığı en önemli engellerden biri, özellikle türbinlerin gelecekteki durumunu öngörebilecek, hatayı oluşmadan önce tespit edip, gerekli önlemleri alabilecek gelişmiş ve etkili kontrol sistemlerinin bulunmamasıdır.

Geleceği bilmemek, türbinleri titreşimlerde, basınçta ve diğer etki eden faktörlerde ani artışlar nedeniyle korozyona ve kanatlarının çatlamasına maruz bırakabilir, bu da birkaç ton ağırlığındaki kanatların kırılmasına ve felaket risklerine yol açabilir. Bu kazalar, işçilerin hayatlarını tehlikeye atmanın yanı sıra ekonomik, yaşam ve üretim seviyelerinde meydana gelir. Bu kazaların barajın yapısı üzerindeki etkisi, onu

tehlikeye maruz bırakır, bu da yıkımına yol açar ve özellikle türbinler dengesiz ve yüksek basınç altında ve elektrik üretimindeki açığı kapatmak için maksimum çabayla çalıştığından, sakinlerin hayatlarını tehlikeye atar [42-45].

Hidroelektrik santrallerinin düzgün çalışmasının sürekliliğini sağlamak ve verimliliklerini artırmak için, bu santrallerin, özellikle türbinlerin gelecekteki durumunu tahmin etmek, herhangi bir tehlikeli durumun oluşmadan önce tespit edilmesini ve önlenmesini sağlamak ve böylece bundan kaynaklanabilecek ciddi hasarları önlemek için gelişmiş ve oldukça güvenilir bir kontrol sistemine acil ihtiyaç duyulmuştur. Bu program esnek ve dünyadaki çeşitli barajlardaki tüm santrallere uygulanabilir.

Bu araştırma önerisi, gelişmiş yapay zeka kullanan ve bu istasyonların durumunu etkileyen tüm faktörlerin bulunduğu devasa bir veri tabanına dayanan gelişmiş algoritmalara dayalı olarak bu istasyonların gelecekteki durumunu tahmin etme sürecini ekleyerek geleneksel kontrol sistemleri daha verimli ve etkili sistemlerle güncellendiğinden, gelişmiş kontrol teknolojisindeki yeni bir eğilimi ele almaktadır. Bu güncellemeyi uygulayarak, gelecekteki durum bilinir, herhangi bir hata oluşmadan önce tespit edilir ve bunları önlemek için uygun önlemler alınır.

Bu yükseltme, türbinin güç çıkışının artırılması ve kavitasyon olgusunun (kavitasyon erozyonu) etkisinin minimum değerlere düşürülmesini içerir ve tüm bunlara, tasarım dışı çalışma aralıkları dahil olmak üzere tüm çalışma aralıklarında türbin verimliliğinde bir artış eşlik eder. Bu, türbinlerin ve hidroelektrik santrallerinin ömrünü uzatır, onları daha verimli ve etkili hale getirir. Sonuç olarak, türbin tarafından üretilen enerji artar ve bu istasyonların ömrünü azaltan faktörlerin etkisi, değerlerinin izin verilen tasarım sınırları içinde tutulmasıyla azaltılır. Bakım sayesinde duruşlar da ortadan kalkar ve pahalı ve değiştirilmesi zor parçaların satın alınması ve değiştirilmesi gerekmez.

Bu yeni teknolojinin temel avantajlarından biri, türbin sensörlerinin tüm eski parçalarının (titreşim sensörleri, sıcaklık sensörleri, basınç sensörleri, vb.) değişmeden kalmasıdır, bu da hem maliyet, hem işgücü hacmi hem de zamandan önemli tasarruflar

anlamına gelir ve bir elektrik santralının eski izleme sistemini yenilemeye karar verirken çok uygulanabilir bir yaklaşım olan ekonomik bir bakış açısıdır.

Bu, hidroelektrik santrallerinin kısmi yüklerde bile, herhangi bir yan etki (ağır dinamik yükleme ile birleştiğinde bu aşınma nedeniyle kanatların aşınması ve bu kanatların bütünlüğünün kaybı) olmadan tüm yıl boyunca çalışmasını sağlayacaktır. Enerji üretimindeki herhangi bir artışın, nüfusun yaşamlarında ve ekonomik çarkın sürdürülebilirliğinde büyük bir fark yaratacağını hesaba katarsak.

Yukarıdaki hedeflere ulaşmada karşılaşılan en büyük zorluk, heyecan verici türbinin algılama bileşenlerini sabit tutmak ve bu projeye uygun gelişmiş algoritmalar ve gelişmiş bir işlemci kullanarak bir kontrol ve tahmin yazılımı geliştirmek ve bunu kontrolle entegre etmek gibi zorlu sınır koşulları olacaktır. Projenin düşük maliyetini korurken türbinlere herhangi bir zarar gelmemesi için en iyi programı sağlamak ve en yüksek verimlilikte çalışmaya devam etmek.

1.2. ARAŞTIRMA AMAÇLARI VE KATKILARI

Bu araştırma, yapay zekayı dahil ederek hidroelektrik santralleri için gelişmiş ve akıllı izleme ve kontrol sistemleri geliştirmeyi amaçlamaktadır. Bu, özellikle bu amaç için tasarlanmış gelişmiş algoritmalar kullanılarak istasyonların gelecekteki durumu için tahmin süreçlerini dahil ederek elde edilir. Bu algoritmalar sağlam ve doğrudur ve bu türbinlerin ve hidroelektrik santrallerinin çalışmasını olumsuz etkileyen parametreleri toplamak için kapsamlı bir veritabanından yararlanır. Veri serisi, eşleşen veriler ile tekrar ve sırayla zaman içinde girilen veriler arasındaki benzerliği temsil etmek için bir ölçüt olarak kullanılır ve gelecekteki okumaların tahmin edilmesine olanak tanır.

Tahmin algoritmalarına dayalı önerilen gelişmiş kontrol programı, titreşimlerde, basınçta ve sıcaklıkta beklenmedik ve ani bir artış, kavitasyon oluşumu gibi büyük bir sorunu çözecek ve türbülanslı dinamik yüklemeyi sınırlayacak ve dolayısıyla bu ani artışlar nedeniyle türbinlerde herhangi bir felaket sorununu sınırlayacak ve önleyecek ideal olarak işleyen ve etkilenmemiş bir sistemdir.

Bu araştırmanın temel katkıları hidroelektrik santralleri için algoritmik düzeydeki katkılar ve tahmin katkıları başlığı altında özetlenmiştir:

Algoritmik düzeydeki katkılar

1. Bu çalışma, yüksek titreşim, basınç, dengesiz yüksek sıcaklıklar ve kavitasyon gibi hidroelektrik santrallerinin temel sorunlarını ele almak için büyük bir veritabanı kullanan LSTM tabanlı RNN tahmin algoritmaları önermektedir.
2. Değişen etki sınırlarına sahip faktörler ve veri değerlerinin varyansına bakılmaksızın, önerilen algoritma santralin gelecekteki durumunu etkili bir şekilde belirler.
3. Önerilen algoritma, elde edilen sonuçları değerlendirmek ve analiz etmek ve santralin son durumunu belirlemek için aşırı değerlerin veya eksik verilerin varlığını işleyebilir.
4. Santralin durumunu belirlemek için farklı etkili faktörlerin tüm değerlerine sahip olmak gerekli değildir; algoritma esnek, verimli ve uygulanması kolaydır.
5. Algoritma, farklı değerlere sahip düzensiz sınırlara ve değerlerin varyansına rağmen santralin gelecekteki durumunu tahmin edebilir.
6. Veri setindeki değerlerin sırası nihai sonuçları etkilemez.

Hidroelektrik santralleri için tahmin algoritmalarının katkısı

Hidroelektrik santral (HES) elektrik üretiminde türbin durumu tahmin modelinin önemi, katkılarıyla gösterilebilir; HES santrallerindeki üretim ekipmanları için gerçek zamanlı türbin sistemi durum tahmininin avantajları aşağıdaki gibi sıralanabilir [5,33]:

1. Arıza süresine neden olan büyük arızalar en aza indirilir.
2. İşletme ve bakım maliyetleri düşer.
3. Ekipman, sistem parametrelerine göre bakım görür.
4. Ekipmanın kullanım ömrü ve etkinliği artar.
5. Arıza süresi sıklığı azalır.
6. Çalışanlar için riskler azalır.
7. İstasyonlar titreşim, basınç ve sıcaklık sınırları içinde çalışır.

HES tahmin sistemi etkinleştirildiğinde, listelenen maliyet avantajları, sistemin güvenilirliğine bağlı olarak aşağıda listelenenlerden daha iyidir [16,33]:

1. Bakım maliyeti %50 ila %80 oranında düşer.
2. Ekipman arızaları %50 ila %80 oranında azalır.
3. Makine duruş süresini %50-80 oranında azaltır.
4. Fazla mesai maliyetleri %20 ila %50 oranında azalır.
5. Makine ömrü %20 ila %40 oranında artar.
6. Karlar %25 ila %30 oranında artar.

1.3. TOPLANAN VERİLER (VERİ SETLERİNE GENEL BAKIŞ)

Obruk Barajı hidroelektrik santrallerinin durumunu etkileyen türbinler, jeneratörler ve şaftlar dahil tüm faktörleri içeren büyük bir gerçek veri seti kullanıldı. Bu veri seti, satırlar ve sütunlar halinde düzenlenmiş binlerce sayısal veri noktasından oluşur ve her sütun titreşim, basınç, sıcaklık, baraj havzasındaki su seviyesi ve üretilen elektrik enerjisi miktarı gibi faktörlerden birinin seviyesini temsil eder. Tüm bu okumalar, tipik ve son derece doğru tahmin algoritmaları oluşturmak için binlerce satırda birleştirildi.

1.4. İLGİLİ ÇALIŞMA

Hidroelektrik, elektrik üretiminin önemli bir bölümünü oluşturmasına rağmen, yenilenebilir enerji üzerine yapılan akademik araştırmalardan sınırlı ilgi görmüştür ve yalnızca %2,3'ünü oluşturmaktadır [19]. Barajlar üzerine yapılan araştırmaların çoğu, iklim değişikliği ve su rezervuarlarındaki seviyedeki değişiklikleri ve hidrolik türbinler ile karşılaştıkları sorunları dikkate alarak hidroelektrik üretimini tahmin etmek için yapılmıştır

1.4.1. Hidro Türbinler ve Kontrol Sistemleri Üzerine Çalışmalar

Zhong Liu ve Lihua Zhou, LabVIEW ve titreşim dalgası gösterimine dayalı baraj istasyonlarının hidrolik türbinlerinde bir titreşim izleme sistemi sundular [46]. Rati

Mohanta ve diğerleri, hidrolik türbinlerde meydana gelen titreşimlerin nedenleri ve titreşim ölçüm kriterlerine dayalı dönen ve sabit bileşenler üzerindeki etkileri üzerine bir çalışma sundular ve son 30 yıldır çalışmalarda kullanılan sistemlerin bir özetini verdiler [47]. Delphin Technology, barajlarda elektrik üretmek için kullanılan türbinlerin titreşim sinyallerini izlemek için bir sistem tasarladı; Femaris, hidrolik türbinlerin titreşimini izlemek için kendi sistemlerini sağladı ve buna göre, arıza teşhisi için ProfiSignal Basic ve ProfiSignal Vibr kullanıldı [48]. Vijaya ve Surender, dumanı ve sıcaklığı izleyen bir endüstriyel robot tasarlamak ve uygulamak için MATLAB GUI'sini kullandılar [49].

Puneet Bansal ve Raja Vidyaraj, MATLAB kullanarak elektrik motorlarındaki titreşimi izlemek ve GUI kullanarak sinyalleri görüntülemek için bir sistem tasarladılar [50]. Omar Al-Hardane ve diğerleri, türbinlerin durumunu etkileyen titreşim ve sıcaklık faktörlerini izlemek ve arızaları oluşmadan önce tahmin etmek ve bunlardan kaçınmak ve ayrıca su türbinlerini iki şekilde kontrol etmek için bir sistem tasarladılar, biri otomatik ve diğeri kontrolör tarafından. Titreşim ve sıcaklık sensörler tarafından ölçülür ve MATLAB'ın grafiksel kullanıcı arayüzü (GUI) kullanılarak görüntülenir; sistem, tahmini yapmak için sensörlerden alınan sinyalleri izin verilen sınırlarla analiz eder [51].

Paulin Coulibaly ve Francois Anctil, yıllık potansiyel enerjinin uzun vadeli tahmini için sinir ağı tabanlı bir sistem önermektedir. Çalışma, zamanla değişen hidrolojik verilerin uzun vadeli tahmini için ICA'nın ilk pratik kullanımını göstermektedir. STA'nın temel sınırlaması, verimli bir durdurma kriterine yol açan OWEP kullanılarak ele alınmaktadır. OWEP kullanılarak FNN ve RNN tahmininin en düşük varyansı, ağ genelleme performansını iyileştirmedeki etkinliğini doğrulamaktadır. Test sonuçları, hem RNN'in hem de OWEP'li FNN'in standart STA veya PCA-STA'dan daha doğru tahmin ediciler olduğunu göstermektedir. RNN'in FNN'den daha doğru ve sağlam bir tahmin sistemi olduğu ortaya çıkmıştır [52].

Gözetimsel Kontrol ve Veri Toplama (SCADA) sistemleri, hidroelektrik santrallerinin otomasyonu, izlenmesi ve kontrolünde önemli bir rol oynar. Birkaç çalışma ve uygulama, SCADA'nın bu tesislerin operasyonel verimliliğini ve güvenilirliğini

artırmadaki etkinliğini göstermiştir. Sukhmit ve diğerleri, küçük ölçekli hidroelektrik santrallerindeki senkron ve endüksiyon jeneratörlerinin performansını inceleyerek, SCADA sistemlerinin izleme ve kontroldeki rolünü vurguladılar. Araştırma, değişen su seviyeleri ve çalışma parametreleri altında deneysel ölçümleri içeriyordu ve SCADA'nın jeneratör performansını iyileştirme ve tesis işletme verimliliğini sağlama yeteneğini gösteriyordu [53].

FM Enescu ve diğerleri, özellikle hidroelektrik jeneratörleriyle donatılmış elektrik tesislerinin izlenmesi ve kontrolüne odaklanarak, sık müdahaleler gerektiren büyük ölçekli operasyonları hedefleyen bir SCADA izleme sistemi sundular. Çalışma, küçük ve büyük hidroelektrik jeneratörlerine uygulanabilen esnek bir çözüm tasarlamak için Citect SCADA sistemini kullandı ve SCADA'nın çeşitli operasyonel bağlamlarda uyarlanabilirliğini gösterdi [54].

Hyghor Miranda Cortes ve diğerleri, özellikle hidroelektrik santralleri ve trafo merkezleri olmak üzere elektrik sistemlerindeki veri ağı ekipmanlarının durumunu izlemek için bir uzman sistemi geliştirdiler. Bulanık mantık ve askıya alınmış sözde tutarlı mantığı birleştirerek, sistem belirsiz sinyalleri etkili bir şekilde analiz etti ve kritik ekipmanların çalışma koşullarını belirledi ve SCADA sistemlerinin tesis operasyonel güvenilirliğini sağlamada gelişmiş uygulamasını gösterdi [55].

Munir Ahmad, hidroelektrik santralleri de dahil olmak üzere çok çeşitli kontrol ve izleme uygulamaları için tasarlanmış modüler, gerçek zamanlı bir çözüm olan Network Manager SCADA sistemini tanıttı. Ölçeklenebilirliği ve dağıtım kolaylığı, gelecekteki ihtiyaçlara uyum sağlamasını ve sanal ortamları desteklemesini, donanım maliyetlerini azaltmasını ve operasyonel esnekliği artırmasını sağlar [56].

Campbell Company'den Charles Johnck, bir hidrolojik SCADA sisteminin uygulanmasıyla havza ölçeğindeki hidrolojik veri ağını çok sayıda iyileştirmeyle modernize etti. Bu sistem uzak istasyonları izler ve güvenli iletişimler sağlayarak hidroelektrik operasyonları için veri toplama ve kontrol yeteneklerini artırır [57].

1.4.2. Hidroelektrik Alanında AI Kullanımı

AI, bilgisayar bilimi, sinir bilimi, ekonomi, bilgi teorisi, matematik, psikoloji, kontrol teorisi ve optimizasyon gibi çeşitli disiplinleri teknikler ve bakış açılarıyla kullanan çok disiplinli bir alandır. Yapay zeka kelimesi, akıllı varlıkların tasarımı ve araştırmasını ifade eder [58]. AI'nın hidroelektrik alanındaki uygulama alanlarını gözden geçirmek için, Şekil 1.3'te verildiği gibi aşağıdaki alt bölümlere ayrılmıştır.




Şekil 1. 3. Hidroelektrikte AI uygulama alanları

1.4.1.1. Yapay Zekanın Performans Optimizasyonu İçin Uygulamaları

Çeşitli yöntemler şu anda hidroelektrik santralının performans optimizasyonu için kullanılmaktadır. Conteh ve diğerleri [59], gerekli yükü atabilen optimum bir yük atma tekniği geliştirmiştir. Geri yayımlı yapay sinir ağını kullanır. Herhangi bir giriş verisi aralığı için yük atma kabiliyetini daha da optimize etmek için, hem sinir ağı hem de bulanık mantık, uyarlanabilir bir nöro-bulanık çıkarım sistemi oluşturmak üzere birleştirilir. İlk senaryo, üretim kaynakları maksimum sınırlarında çalışmaya başladığında kesicinin kapatılmasıyla elde edildi. Ayrıca, ikinci senaryo, tesis arızasına neden olan ani bir güç düşüşüyle elde edildi. İki yöntemden kaynaklanan yük atma hataları, ANFIS yönteminin geri yayımlı yapay sinir ağı yönteminden daha

sağlam olduğunu göstermektedir. Zhang ve diğerleri [60], çeşitli tekniklerin hesaplama performansını karşılaştırmıştır. Şekil 1.4 ve 5, XGBoost, MARS, ANN ve SVM modellerinin eğitim ve test sonuçlarını göstermektedir.

Test verileri için, XGBoost modeli tarafından sağlanan FEM ile SCM tahminleri arasındaki RMSE, R2, önyargı faktörü ve MAPE sırasıyla 7.90, 0.99, 1.00 ve 0.04 olarak bulundu. MARS modeli, test eğilimleri için RMSE, R2, önyargı faktörü ve MAPE'yi sırasıyla 11.10, 0.97, 1.02 ve 0.07 olarak verdi; ANN modelinden beklenen değerler için RMSE, R2, önyargı faktörü ve MAPE sırasıyla 11.73, 0.97, 1.00 ve 0.07 olarak elde edildi. SVM modelinin RMSE, R2, faktör önyargısı ve MAPE'si sırasıyla 17.40, 0.94, 1.01 ve 0.06 idi.



Şekil 1. 4. (a) FEM duvar sapsmasının eğitim ve (b) test sonuçları sunta [60].

Kurt ve diğerleri [61] Kayaboğazi Barajı'nda güç üretimini araştırdı. Kurulum için üç küçük ünite önerildi. Hem güç kapasitesi hem de güç talebi kısıtlamaları dikkate alınarak türbinlerin çıktısını optimize etmek için bir FL algoritması kullanıldı. Buna karşılık, Herath ve diğerleri [62] enerji fiyatını tahmin etti. Yapay zekanın hidroelektrik santrallerinin performans optimizasyonu için uygulanmasının bir özeti Çizelge 1.1.'de verilmiştir.

Çizelge 1. 1. Performans optimizasyonu için AI uygulamalarının özeti

Yazar(lar)	Yöntem(ler)	Amaç(lar)	Bulgular
Sunta ve ark. [60]	ANFIS	Şebeke kararlılığı için gereken miktarda yükü atabilen optimum yük atma	İstenen miktarda yük daha hızlı bir oranda atılabilir ve bu da sistemin kararlılığını artırır
Kora ve ark. [61]	Fuzzy logic controller	FL algoritması kullanılarak güç potansiyeli ve güç talebi kısıtlamalarının optimizasyonu için türbinlerin çalışması	Enerji üretimini optimize etmek için ünite sayısının seçimi

1.4.1.2. Yapay Zekanın Bitki Parametrelerinin Tahmini İçin Uygulamaları

Senthil ve ark. [63], bir havzada üretilen bir YSA kullanarak tortu yükünü tahmin etti. Tortularla hidro-iklimsel faktörlerin yüksek değişkenliğinin tortu modelleme sürecini zahmetli ve sıkıcı hale getirdiği sonucuna vardılar. Diğer yumuşak hesaplama teknikleriyle karşılaştırıldığında, M5 modeli iyi performans gösterdi. M5M1 ve ANNSC22 için RMSE'nin 0,54 olduğu bulunurken, REPTree modeli en kötü performans gösterdi (0,82). M5M1 ve ANNSC22 modelleri için korelasyon katsayısının en iyi değeri 0,96 iken, REPTreeM2 modelinin korelasyon katsayısı 0,90'dır. Kumar ve ark. [64], şebekeyi stabilize etmeye yardımcı olacak günlük tesis yükünü tahmin etmek için bir makine öğrenimi tekniği uyguladı. Fayaz ve ark. [65], binalardaki enerji tüketimini tahmin etmek için bir derin öğrenme algoritması kullandı. Bu amaçla her iki döneme ait ortalama istatistiksel ölçüm değerleri hesaplanmış ve Çizelge 1.2.'de sunulmuştur. İstatistiksel değerler DELM'in benzerlerine göre daha iyi verimliliğe sahip olduğunu göstermektedir.

Çizelge 1. 2. İstatistiksel ölçümlerin ortalama değerleri [65].

İstatistiksel Ölçümler	MAE	MAPE	RMSE
ANN	2.4317	7.0830	4.8561
ANFIS	2.4556	6.8841	2.8174
DELM	2.1677	6.1271	2.4657

Shamshirband ve diğerleri [66], basınç gradyanını tahmin etmek için bir ANFIS ve CFD yaklaşımı kullandı. Araştırma sonuçları, giriş parametrelerinin ve kural sayısının algoritmanın doğruluğu üzerinde önemli bir etkiye sahip olduğunu gösterdi. Lounis ve diğerleri [67], hidroelektrik santrallerindeki deşarj akışını tahmin etmek için beş desen sınıflandırma algoritmasının performansını araştırdı. Sonuçlar, sinir ağı yönteminin diğer yaklaşımlara göre güçlü bir üstünlüğe sahip olduğunu gösterdi. Egoigwe ve diğerleri [68], türbinin dönüşü nedeniyle zamanla değişen hidroelektrik santrallerinin akış hızını analiz etti. Sonuçlar, hidroelektrik üretimi için hız düzenlemesinin, bulanık mantık denetleyicisiyle ve denetleyicisi olmadan sırasıyla 319,8 m/s ve 65 m/s olduğunu gösterdi.

Bu, Bulanık Mantık Denetleyicisinin daha iyi sonuçlar ürettiği ve türbin dönüş hızını artırdığı anlamına gelir. Hidroelektrik jeneratör hız denetleyicisinin modellenmesi için genel bir denklem, Denklem 1'de verilmiştir.

$$M(t) = K_p E(t) + K_i \int_0^t E(t) dt + K_d \frac{dE}{dt} \quad (1.1)$$

Burada K_p , K_i ve K_d sırasıyla orantılı, integral ve türev sabitleridir. $E(t)$ zamanın bir fonksiyonu olarak hatadır ve $M(t)$ denetleyici çıktısıdır. Türev modu, ölçüm yöntemi daha hızlı bir tepki süresinde bozulduğundan hatayı hesaba katar. Eq.1'in dijital eşdeğeri aşağıda verilmiştir:

$$M_i = K_p \left[E_i + T K_i \sum_{j=1}^i E_j + \frac{K_d}{T} (E_i - E_{i-1}) \right] \quad (1.2)$$

Burada T örnekleme aralığı, E_i i'inci örnekleme aralığındaki Hata ve E_{i-1} bir önceki örnekleme aralığındaki hatadır.

$$M_i = K_p \left(1 + \frac{K_d}{T} \right) E_i - \left(\frac{K_d K_p}{T} \right) E_{i-1} + (TK_p K_i) S_i \quad (1.3)$$

Burada S_i , hataların toplamıdır.

Luna ve diğerleri [69], akış tahmini için bir TS-FIS modeli sundu. Modelin doğrulaması MAPE, RMSE ve MAE kullanılarak gerçekleştirildi. Model, %79 ile %98 arasında değişen kütle eğrisi katsayısının iyi bir performans değerini gösterdi. Abdulkadir ve diğerleri [70], çok katmanlı bir sinir algılayıcı ağı kullanarak enerji üretimi için barajların rezervuar değişkenlerini modelledi. Sinir ağı açıklaması, Kainji ve Jebba hidroelektrik rezervuarları için sırasıyla 0,89 ve 0,77 korelasyon katsayısının güçlü bir tahminini aldı. Li ve diğerleri [71], destek vektör makinesi (SVM) ve genetik algoritma (GA) kullanarak kısa vadeli güç üretimini tahmin etti. Stokelj ve diğerleri [72], sinir ağı mimarisini kullanarak su akışını tahmin etti. Shaktawat ve diğerleri [73], bir hidroelektrik santralının maliyet aşımını belirlemek için bir Bulanık araç sundu. Bir hidroelektrik santralinde maliyet aşımı, elektrik üretim fiyatında artışa neden olur. Aşımaları değerlendirme yöntemi, yatırımcıların belirsizliği belirlemesine yardımcı olacaktır.

Li ve diğerleri [74], güç üretiminin tahmini için derin bir sinir ağı uyguladı. Sonuç olarak, HGDNN modeli RMSE değerini 202,92'ye düşürdü. Ek olarak, HGDNN, ST-ResNet ile karşılaştırıldığında RMSE, MAE ve MAPE'de sırasıyla en az %6, %9 ve %49'luk bir iyileştirme kaydetti. Ölçüm parametreleri aşağıda listelenmiştir.

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^M (\hat{x}_t - X_t)^2} \quad (1.4)$$

$$MAE = \frac{1}{M} \sum_{i=1}^M |\hat{x}_t - X_t| \quad (1.5)$$

$$MAPE = \frac{1}{M} \sum_{i=1}^M \left| \frac{\hat{x}_t - X_t}{X_t} \right| \quad (1.6)$$

Burada $\hat{x}_t$ ve X_t , t zamanındaki öngörülen ve gerçek hidroelektrik üretim değeridir ve M, toplana n örnek sayısıdır.

Mamlook ve diğerleri [75], elektrik üretmek için farklı seçimler kullanarak nöro-bulanık programlamayı karşılaştırdı. Maliyet-fayda oranına göre, güneş, rüzgar ve hidroelektrik, elektrik üretmek için en iyi sistemler olarak kabul edildi ve nükleer güç en kötü seçimdir. Valizadeh ve diğerleri [76].

ANFIS kullanarak barajın günlük su seviyesini tahmin etti. Her iki model setinde girdi olarak yağışla birlikte rezervuar seviyesinin yükseltilmesi, tahmin edilen ve gözlemlenen sonuçların uygunluğunu önemli ölçüde iyileştirdi. Ölçüm istasyonunun uzaklığı bilinmediğinden, ölçüm istasyonları arasındaki uzaklık, girdilerin farklı zaman gecikmelerinde çeşitli modeller kullanılarak belirlenebilir; ancak, hassas bir tahmin sağlamak için girdilerde ve çıktılarda uygun uzunluğu gösterir. Oltean ve diğerleri [77], kademeli hidroelektrik santrallerinde enerji üretimini tahsis etmek için çıkarmalı kümeleme yoluyla bulanık modeller oluşturmak için bir yöntem sundu. Bu model, test veri setindeki ortalama mutlak yüzde hatası için %6,47'lik bir değer gösteriyor.

Model için, test veri setlerindeki verilerin %90'ı %13,59'dan daha az bir temel yüzde hatası üretti. Model, test veri noktasının çoğu için çok iyi performans gösterdi. Cheng ve diğerleri [78], uzun vadeli deşarjı tahmin etmek için ANFIS modelini simüle etti. Doğrulama ve eğitim için, tahmini ve gözlemsel değerler arasındaki korelasyon katsayıları sırasıyla 0,889 ve 0,918 olarak bulunmuştur. Ayrıca, ANFIS modelinin, sonuçları uygun bir ANN modeliyle karşılaştırarak daha doğru tahminler sağlayabileceği bulunmuştur.

Dehghani ve diğerleri [79], hidroelektrik gelişimini tahmin etmek için ANFIS ile birlikte Gri Kurt Optimizasyonu (GWO) yöntemini uyguladı. Baraj akışı, yağış ve çeşitli aylardaki hidroelektrik dahil olmak üzere yirmi girdi kombinasyonu kullanıldı, üretim ise tüm senaryolarda bir aylık hidroelektrik üretimi içindi. Daha sonra

hidroelektrik üretimi, eşleştirilmiş model kullanılarak tahmin edildi. Sonuçlar, GWO-ANFIS modelinin hidroelektrik üretimini tatmin edici bir şekilde tahmin edebildiğini, ANFIS'in ise dokuz girdi-çıkı kombinasyonunda daha iyi olmadığını gösterdi.

Kucukali ve diğerleri [80], ANN modelinin sonuçlarının, seçilen tüm konumlar için nispeten yüksek bir korelasyon katsayısı değeriyle gerçek ve öngörülen rezervuar girişi arasında pozitif bir ilişki gösterdiğini sonucuna vardı. Bu, modelin rezervuar girişini modellemek için ideal olduğunu göstermektedir.

Ghosh ve diğerleri [81], HPP çıktısını göstermenin yeni bir yolunu önerdi. Her bir gerekli parametreyi vermek için MCDM ve ANN yöntemleri uygulandı. Verilere göre en önemli parametre (MIP) su mevcudiyeti iken, erişilebilirlik en az önemli olanıdır. ANN modeli, bağımsız bir HES durum tahmin sistemi olarak oluşturulmuştur. Olası sahanın sürekli değerlendirilmesine izin vermek için endeksin dinamik, uyarlanabilir zaman değişkenli bir versiyonu geliştirilebilir.

Alrayess ve diğerleri [82], kısa vadeli enerji üretim tahmininde makine öğrenme tekniklerini kullanmıştır. Almus HES'in enerji üretimini tahmin etmek için üç model, ANN, Destek Vektör Makinesi (SVM) ve Derin Öğrenme (DL) kullanılmıştır. ANN, SVM ve DL için korelasyon değerleri sırasıyla 0,766, 0,682 ve 0,998 olarak bulunmuştur. Ayrıca, ANN, SVM ve DL için kareli korelasyon değerleri sırasıyla 0,587, 0,466 ve 0,995 olarak elde edilmiştir. Sonuçlar, DL algoritmasının diğer tekniklerden daha iyi performans gösterdiğini göstermiştir.

Hammid ve diğerleri [83], çalışma sırasında on yıl boyunca toplanan veriler üzerinde net türbin başlığı, su akış hızı ve güç üretimi açısından hidroelektrik santrallerinin çıktısını tahmin etmek için ANN uyguladı. ANN, doğrusal olmayan santral çıktısını modellemek için etkili bir analiz ve tanı aracı sağlar. ANN'nin, öngörülen ve gözlenen çıktı değişkenleri arasındaki korelasyon katsayısının 0,96'dan yüksek bir değere sahip olmasıyla santral performansını tahmin edebileceği sonucuna varılmıştır. Stokelj ve diğerleri [84], kısa vadeli su girişi tahmini ve başarılı teklif verme teknikleri için geliştirilmiş bir ANN modeli sundu.

Feng ve diğerleri [85], Mikro Sismik (MS) izleme verilerine ve geliştirilmiş bir Olasılıksal Sinir Ağı (PNN) modeline dayalı bir kaya patlaması sistemi geliştirdi. PNN parametresindeki düzeltme faktörünü en üst düzeye çıkarmak için, değiştirilmiş ateş böceği yöntemi kullanıldı. Sonuçlar, öngörülen ve öğrenme örneklerinin doğru kaya patlaması oranları için sırasıyla %100 ve %86,75 doğruluğa sahip olduğunu ortaya koymaktadır.

Jalalkamali ve diğerleri. [86], yeraltı suyu seviyelerini tahmin etmek için Neuro-Fuzzy (NF) ve ANN tekniklerinin potansiyelini inceledi. NF hesaplama tekniklerinin ayrıca ANN modellerinden daha yüksek verimliliğe sahip olduğu bulundu. Kumar ve diğerleri [87], hidroelektrik santrallerinin işletimi ve bakımının tahmini analizinde kullanılabilen günlük silt yoğunluğu hacmini sınıflandırdı.

Bina ve diğerleri [88], bireysel ev aletlerinin toplam günlük güç talebini tahmin etti. Yük tahmini için ağaç tabanlı stratejiler de DR'de yaygın olarak kullanıldı [89]. Perakendecilerin veya toplayıcıların fiyat şeması optimizasyonu için, GA genellikle bireyleri dikkate alır [90]. Konut alanları [91, 92], endüstriler [93], binalar ve ofis binaları [94] için temel yük tahmini konusunda çok sayıda çalışma mevcuttur.

Piyasa düzeyindeki bilgilerin çoğu, rekabetçi konut fiyatlandırma şemalarını tahmin etmekle ilgiliydi [95, 96, 97]. Ancak, toplam yük tahmini, bina düzeyinde veya besleyici veya mahalle düzeyinde günlük tepe talebini değerlendirmeye de yoğunlaşabilir [98, 99]. Ayrıca, konut yük tahmini farklı toplama hızlarında gerçekleştirildi [100].

Ali Th. ve diğerleri, yapay sinir ağları (YSA) kullanarak Hamrin Gölü-Diyala Barajı'nda hidroelektrik santralinin elektrik üretme kapasitesini tahmin eden bir sistem oluşturdu. Bulgular, elde edilen en büyük performansın 0,0032734'lük bir kök ortalama kare hatası (RMSE) değerine ve 0,96'lık bir R kare (R^2) değerine sahip olduğunu gösterdi [101].

Omar Al-Hardanee ve Hussein Demiral, hidroelektrik santrallerinin durumunu tahmin etmek, operasyonlarını iyileştirmek, verimliliklerini artırmak ve tahmine dayalı

gelişmiş eylemlerde bulunarak sorunları önlemek için bir sistem geliştirdiler. Optimizasyon süreci, Obruk hidroelektrik santralinden alınan gerçek verilere dayanan tekrarlayan sinir ağı (RNN) ve uzun kısa vadeli bellek (LSTM) ağlarını kullandı. Önerilen sistem, yaklaşık %99,55'lik en yüksek doğruluğun yanı sıra 0,0072'lik ortalama kare hata (MSE) ve 0,0053'lük ortalama mutlak hata (MAE) elde etti [8].

HGU, Junyan Li ve meslektaşları, hidroelektrik üretim ünitesinin sıcaklığını belirleyen bir zaman serisi tahmin modeli oluşturmak için zamansal bir evrimsel ağ (TCN) ve RNN kullandılar. Çalışma, iki TCN-RNN modeli sıcaklık tahmin modelinin sırasıyla %42,2 ve %48,3'lük ortalama bir MSE artışı gösterdiğini buldu. RMSE ortalama %23,4 ve %43,2 oranında artarken, MAE ortalama %26,5 ve %16,4 oranında arttı [103].

Çizelge 1. 3. Yapay zekanın HPP parametrelerini tahmin etmedeki uygulamalarına ilişkin bir özet sunar.

Yazar(lar)	Yöntem(ler)	Amaç(lar)	Bulgular
Senthil ve ark. [63]	ANN	Sediment yüklemesini tahmin etmek	REPTree modeli, daha az hesaplama süresi ile daha iyi içgörü sağlar
Fayaz ve ark. [65]	ANN ve ANFIS	Enerji tüketimi tahmini	DELM, kısa ve uzun vadeli enerji tüketimi projeksiyonlarında YSA ve ANFIS'ten çok daha iyidir
Lounis ve ark. [67]	Makine öğrenimi	Akış tahmini	Sinir ağı yaklaşımı diğer tekniklere göre üstündür
Egoigwe ve ark. [68]	Bulanık mantık denetleyicisi	Akış hızı tahmini	Hız 254.8 m/s'ye ulaştığında, bulanık mantık kontrolörü daha iyi sonuç verir
Luna ve ark. [69]	TS-FIS modeli	Giriş akışı tahmini	Kütle eğrisi katsayısı (performans endeksleri) %79 ile %98 arasında değişmektedir
Abdulkadir ve ark. [70]	ANN	Enerji üretimi tahmini	Şebekeyi dengelemek amacıyla bir gün öncesinden enerji üretimi tahmin edilmiştir

Li ve ark.[71]	GA-SVM	Enerji üretimi tahmini	GA-SVM modeli, kısa vadeli tahmin doğruluğunu artırmak için etkili bir yöntemdir
Shaktawat ve ark. [72]	Bulanık mantık kontrolörü	Maliyet tahmini	Hidroelektrik projelerinin maliyet aşırımları kolay ve daha az hesaplama süresiyle hesaplanmıştır
Li ve ark. [74]	Derin sinir ağı	Üretim tahmini	HGDNN yöntemi hidroelektrik üretimini daha iyi tahmin eder
Cheng ve ark. [78]	ANFIS	Deşarj tahmini	ANFIS için çeşitli üyelik fonksiyonlarının karşılaştırılmasında, TRAPMF uzun vadeli deşarj tahmininde en iyi performansı gösterir
Dehghani ve ark. [79]	ANFIS	Enerji üretimi tahmini	GWO-ANFIS, hidroelektrik üretimini tatmin edici şekilde tahmin edebilmektedir
Ghosh ve ark. [81]	MCDM ve YSA	DELM Databases of Early Latin Manuscripts	YSA modeli, tahmin gücü açısından regresyon modelini geride bırakmıştır
Alrayess ve ark.[82]	YSA, SVM ve DL	Kısa vadeli enerji üretimi tahmini	Korelasyon değerleri, Derin Öğrenme modelinin YSA ve SVM'ye göre daha yüksek doğruluk ve performansla sonuçlar verdiğini göstermiştir
Hamid ve ark.[83]	YSA	Yükseklik tahmini	YSA modellemesi küçük hidroelektrik santrallerin davranışını tahmin etmek için kullanılabilir
Feng ve ark. [85]	YSA	Kaya patlaması tahmini	MIVA-MFA-PNN modeli, kaya patlaması tahmininde iyi performans göstermektedir
Jalalkamali ve ark.[86]	YSA ve Bulanık mantık kontrolörü	Su seviyesi tahmini	NF hesaplama tekniği, yeraltı su seviyesi modellemesi için uygundur
Kumar ve ark. [87]	SOM	Öngörücü bakım	SOM, günlük silt verilerinin analizi ve makine bakımı planlaması için kullanılabilir
Bina ve ark. [88]	Gaussian Copulas	Toplam talep tahmini	Dağıtım trafoları ve besleyicilerin kullanımı geliştirilebilir

Park ve ark. [89]	SOM, K-means	Temel seviye tahmini	DR yönetiminde, büyük miktarda akıllı sayaç verisi toplandığında veri odaklı yaklaşım CBL tahmini için olası bir yöntemdir
Jazaeri ve ark. [92]	Doğrusal olmayan regresyon, YSA	Temel seviye tahmini	Teknikler arasında, makine öğrenimi en düşük sapmayı üretmiştir
Arunaun ve ark. [93]	YSA	Temel seviye tahmini	LM algoritması ile sinir ağları kullanılarak yapılan temel hesaplama en doğru yöntemdir
Escriba ve ark. [94]	YSA	Temel yük tahmini	Yapay sinir ağlarına (YSA) dayalı çok yönlü ve uyarlanabilir algoritma, bina enerji tüketimini doğru bir şekilde tahmin etmek için uygundur
Ali Th. ve ark. [101]	YSA	Hamrin Gölü-Diyala Barajı'nda hidroelektrik üretimi tahmini	RMSE: 0.0032734 ve R ² : 0.96 ile yüksek doğruluk elde edilmiştir
M. Bilgili ve ark. [103]	LSTM sinir ağı	Türkiye'de günlük hidroelektrik üretiminin kısa vadeli tahmini	LSTM modeli, MAE: 2.71 GWh, MAPE: %5.98, RMSE: 3.62 GWh ve R ² : 0.9914 ile geleneksel ANFIS modelini geride bırakmıştır
Omar Al-Hardane ve Hüseyin Demirel [8]	RNN ve LSTM ağları	Hidroelektrik santralin durumunu daha verimli ve önleyici tahmin etmek	%99.55 doğruluk, MSE: 0.0072 ve MAE: 0.0053 elde edilmiştir
HGU, Junyan Li ve ark. [103]	TCN ve RNN	Hidroelektrik jeneratör birimlerinin sıcaklığını tahmin etmek	TCN-RNN modelleri, MSE'yi %42.2 ve %48.3, RMSE'yi %23.4 ve %43.2, MAE'yi %26.5 ve %16.4 oranlarında artırmıştır

1.4.1.3. HES'lerin İzlenmesi ve Kontrolünde Yapay Zeka Uygulamaları

İzleme ve kontrol, bir hidroelektrik santralının temel unsurlarıdır. Chapuis ve diğerleri [104], bir hidroelektrik santrali çıkış kontrol yapısı tanıttı. Çıkış kontrolü, rezervuarın

toplam çıkışını kontrol etmek için birçok aktüatörün (türbinler ve barajlar) gerekli olması gerçeğiyle ayırt edildi. Adhikary ve diğerleri [105], savak kapıları aracılığıyla güvenli rezervuar kontrolü için Bulanık Mantık kullandı. Tabu Arama Algoritması'na (TSA) dayalı bulanık modelin tahmin doğruluğunun makul olduğu sonucuna vardılar. Xu ve diğerleri [106], Bulanık Kontrol Teorisi ve Sinir Ağı Teorisi'ne dayalı kontrol parametrelerinin açıklaması ve optimizasyonu açısından Akıllı Kontrol Teorisi'nin kullanımını tartışılar.

Theophilus ve diğerleri [107], değişken hibrit Bulanık tabanlı bir mantık kontrolörü ve Nöro-Bulanık tekniği adı verilen derecelendirilmiş bir sinir ağı sundular. Kural ve üyelik fonksiyonuna dayalı rezervuar kontrolü için bulanık mantık, tasarımda gösterilmiştir. Bu sayede türbin hızının kararlılığı artırılarak gerçek zamanlı olarak beklenen aralıkta optimum hidroelektrik üretimi sağlandı. Oğuz ve diğerleri [108], nehir hidroelektrik santrallerinin işletilmesi için bir risk yönetimi çerçevesi önerdi. Uzman yargıları ayrıca risk faktörlerinin göreceli değeri için de oluşturuldu. Anketin sonuçları, saha jeolojisi ve çevresel sorunların en ilişkili riskler olduğunu gösterdi.

Falchetta ve diğerleri [109], elektrik arzının güvenilirliğini etkileyen hidro-iklimsel uç noktaları analiz etti. Çerçeve, veri kıtlığını azaltmak ve ölçülmemişken nehir deşarjlarındaki oynaklığı tahmin etmek için rastgele orman regresyonu algoritmalarını kullanır. Doğrulanmış tahminler, hidro-iklimsel olayların hidroelektrik verimliliği üzerindeki etkisini belirlemek için kullanıldı. Molina ve diğerleri [110], çeşitli sinyallerin izlenmesine dayalı hidroelektrik santrali operasyonları için yeni bir tasarım tanıttı. Arızaları önlemek için, NNPM, tesis durum değişkenlerinden farklı durumları belirlemek için bir ART-MAP kullandı. Ayrıca, ART-MAP modülü için eksiksiz bir eğitim seti oluşturmak üzere benzersiz bir süreç geliştirildi.

Çizelge 1.4. hidroelektrik santrallerinin izlenmesi ve kontrolünde AI uygulamalarının özetini göstermektedir. Yazarlar, Fang Dao vd., hidroelektrik türbinlerindeki korozyon sorunlarını tanımlamak için CNN-LSTM (Konvolüsyonel Sinir Ağı-Uzun Kısa Kısa Süreli Bellek) ve IWSO (Geliştirilmiş Beyaz Köpekbalığı Optimizatörü) ile birlikte WT'nin (Dalgacık Eşikleme Algoritması) geliştirilmiş ön işlemesine dayanan bir yöntem önerdiler; ayrıca IWSO tekniğini kullanarak CNN-LSTM modelinin

hiperparametrelerini deęiřtirdiler. Deneysel bulgular, önerilen yöntemin %96,2'lik bir doğruluęa sahip olduğunu, bunun da gürültü giderme olmadan IWSO-CNN-LSTM modelinin doğruluęundan %8,9 daha iyi olduğunu göstermektedir [111].

Çizelge 1. 4. Yapay zekanın hidroelektrik santrallerinin izlenmesi ve kontrolündeki uygulamalarının özeti.

Referans	Yöntem (ler)	Amaç (lar)	Bulgular
Adhikary ve ark. [105]	Bulanık mantık denetleyicisi	Rezervuar kontrolü	Bulanık modelin Tabu Arama Algoritması (TSA) tahmin doğruluęu makul
Theophilus ve ark. [107]	ANFIS	Rezervuar kontrolü	Su seviyelerini düzenlemek ve akışı kontrol etmek için bir Nöro-bulanık kontrolörün tasarımı
Molina ve ark. [110]	ANN	İzleme parametresi	ART modeli, olası anormal koşullarla ilişkili deęişken deęerleri tahmin eder
Fang Dao ve dięerleri. [111]	CNN-LSTM (WT) ve (IWSO) ile	Hidroelektrik türbinlerindeki korozyon sorunlarını belirleyin	Doęruluk %8,9 oranında artırıldı ve %96,2 doęruluk elde edildi

1.4.1.4. Yapay Zekanın Politika ve Özellik Seçiminde Uygulanması

Wotawa ve ark. [112], hidroelektrik nehir sistemlerinde optimum rezervuar işletme politikalarını bulmak için derin öğrenmenin kullanımını göstermiştir. Deng ve ark. [113], dalgacık dönüşümü ile birleştirilmiş yük üretiminin özelliklerini analiz etmiştir. PSO, başlangıç sinir ağı ağırlıklarını ve eşiklerini iyileştirmek için kullanılmıştır. Bazı illerde gerçek vaka ile kontrol edildikten sonra, yük tahmininin hassasiyeti %93,7'ye ulaşmıştır; bu, yüksek gerilim şebekesi için deęerlendirme kriterlerinin doğruluęundan daha yüksektir.

Kentel ve ark. [114], ekonomik, teknik ve çevresel kriterleri analiz ederek atıksu arıtma tesisi çıkışlarında hidroelektrik üretimi için düşük başlı (LH) hidroelektrik teknolojisinin en sürdürülebilir seçeneğini deęerlendirmiştir. Finansal ve çevresel gereksinimler açısından üstün performansı nedeniyle, Arşimet vidası bir atıksu arıtma

tesisinin çıkışında hidroelektrik üretimi için Kaplan türbininden daha iyi bir alternatiftir.

Titreşim yönünü tahmin etmek için Bi Yang ve diğerleri, çift yönlü uzun kısa süreli bellek (BLSTM) ağı ve birleşik bir özellik seçimi ölçüsüne dayalı bir çerçeve oluşturdu. Uygun çalışma koşulu değişkenlerini seçmek ve tahmin modelinin kararlılığını artırmak için mesafe ve Pearson korelasyon katsayısına dayalı bir birleşik metriği önerildi. Önerilen yaklaşımın (WTD-Corr-BLSTM) ürettiği sonuçların RMSE ve MAE'si sırasıyla 0,42 ve 0,31'dir [115].

Bai ve diğerleri [116], daha iyi performans ve güç üretimi kontrolü için optimum makro düzeyde operasyonel kuralları türetmek üzere bir Bulanık mantık modeli geliştirdiler. "Eğer-o zaman" kurallarını kullanan bulanık bir çıkarım yöntemi, ayrıntılı nicel analizler kullanmadan insan anlayışının ve akıl yürütme süreçlerinin nitel boyutlarını modelleyebilir. Yapay zekanın hidroelektrik santralleri için politika ve özellik seçimindeki uygulamalarının bir özeti Çizelge 1.5.'te verilmiştir.

Çizelge 1. 5. Yapay zekanın politika ve özellik seçiminde uygulanmasının özeti

Yazar(lar)	Yöntem (ler)	Amaç(lar)	Bulgular
Kentel ve ark. [114]	Bulanık mantık denetleyicisi	En iyi kriter seçimi	Arşimet vidası, belirli bir WWTP durumu için Kaplan türbininden daha iyi bir alternatiftir
P. Young ve diğerleri. [115]	Özellik seçimiyle BLSTM	Hidroelektrik sistemlerinde titreşim yönünü tahmin edin	0,42'lik RMSE ve 0,31'lik MAE elde edildi
Bai ve ark. [116]	Bulanık mantık denetleyicisi	Optimum çalışma kuralı seçimi	Bir makinenin verimlilik bölgesinde çalışmasına yardımcı olur.

1.4.1.5. Yapay Zekanın Fizibilite Çalışmasındaki Uygulamaları

Gunduz ve ark. [117], proje maliyetlerine ve yatırım miktarına dayalı olarak ANN kullanarak bir hidroelektrik santraline yatırım yapmanın fizibilitesini analiz etti. Tripathi ve ark. [118], Nepal'deki Boot hidroelektrik projeleriyle ilişkili riski ölçmek

için Bulanık Derecelendirme Aracını uyguladı. Shimray ve ark. [119], santral inşası için yer seçiminin karmaşık olduğu ve dikkatli bir değerlendirme gerektirdiği sonucuna vardı. Hidroelektrik santrallerinin inşası ağır finansal harcama, iş gücü ve zaman kısıtlamaları gerektirir. Bu nedenle, çevre ve dolayısıyla insanlık üzerinde olumsuz etkileri önlemek için sistematik bir yaklaşım gereklidir. ANN tabanlı formalizm, MLP-GA'nın hidroelektrik santrallerinin kurulumu için potansiyel yerlere kesin öncelik verebileceğini göstermektedir. Çizelge 1.6. hidroelektrik santrallerinin fizibilite çalışması için AI uygulamalarının bir özetini sunmaktadır.

Çizelge 1. 6. Yapay Zeka'nın uygulanabilirlik çalışması için uygulamalarının özeti

Yazar(lar)	Yöntem(ler)	Amaç(lar)	Bulgular
Junds ve ark. [117]	ANN	Yatırım fizibilitesi	Bir projenin ekonomik uygulanabilirliği analiz edilebilir
Tripathi ve ark. [118]	Bulanık mantık denetleyicisi	Risk değerlendirme	Risk endeksi proje sorunlarının erken bir göstergesi olarak kullanılabilir
Shamri ve ark. [119]	ANN	Yer seçimi	MLP-GA potansiyel sahaları doğru bir şekilde önceliklendirebilir

1.4.1.6. Doğruluk Değerlendirmesi ve Yetenek Değerlendirmesi İçin Yapay Zekanın Uygulanması

Qu ve diğerleri [120], Kaba Küme (RS) teorisini ve Uzun Süreli Bellek (LSTM) ağını birleştiren RS-LSTM kullanarak beton baraj deformasyonunu tahmin etmeye odaklandı. Mosavi ve diğerleri [121], çıkış voltajını ve değişken hızlı türbin frekansını kontrol etmek için bir ANFIS modeli uyguladı. Pérez-Díaz et al. ve diğerleri [122], hem türbinin hızının hem de kılavuz kanatlarının konumunun eksenel akışlı pervane türbin kontrol yeteneklerini analiz etti. Nehir akışı santralının dinamiklerini incelemek için bir hidroelektrik santralının deneysel bir kurulumu inşa edildi. Basınç bir pompa aracılığıyla oluşturulur; bir asenkron jeneratör, bir kontrol mekanizmasıyla bir türbin aracılığıyla şebekeye bağlanmıştır. Deşarjı ve torku ölçmek için bir Venturi akış ölçer ve bir tork ölçer takılmıştır. Deney, kılavuz kanatlarının konumunu buna göre değiştirerek türbinin performansını artırmanın mümkün olduğunu göstermiştir.

Zaidi ve diğerleri [123], enerji-su bağlantısında veri ve makine öğrenimi için metodolojiyi açıkladı. Enerji-su bağlantısı ve makine öğrenimi toplulukları arasındaki olası çalışma konularının ve iş birliği fırsatlarının karşılıklı sinerjik faydaya yol açabileceği ortaya çıktı. Dahası, tüketicilerin toplanması için bir talep esnekliği modeli geliştirmek de faydalı olabilir [124] ve PSO, müşterilerin tüketimini planlamak için kullanılabilir [125].

Kısa vadeli elektrik yükü tahmini için özellik seçimi (FS-EMD-GRU) ile ampirik mod ayrıştırma-kapılı tekrarlayan birim (EMD-GRU) yaklaşımı Xin Gao ve arkadaşları tarafından sunulmuştur. Dört veri setinin sonuçları önerilen tekniğin ortalama tahmin doğruluğunun sırasıyla %96,79, %95,31, %95,72 ve %97,17 olduğunu göstermiştir. Tek bir GRU modeli EMD-GRU, EMD-SVR, EMD-RF, rastgele orman (RF) ve destek vektör regresyonu (SVR) modelleriyle karşılaştırılmıştır [126].

Uzun kısa vadeli bellek (LSTM) ve varyasyon modu ayrıştırma (VMD) kullanan ağları kullanan Feifei He ve arkadaşları, Bayes optimizasyon yaklaşımı (BOA) kullanılarak iyileştirilen bir hibrit kısa yük tahmin sistemi geliştirmiştir. SVR, çok katmanlı algılayıcı regresyonu, LR, RF ve EMD-LSTM ile karşılaştırıldığında, önerilen yöntemin sonuçları MAPE'nin %0,4186 ve R-kare'nin 0,9945 olduğunu göstermektedir [127].

Mobarak Abumohsen ve diğerlerinin tahmin modelinden üç model—LSTM, GRU ve RNN—elektrik şirketinin mevcut elektrik yükü verilerine dayanarak elektrik yükünü tahmin etmek için seçilmiştir. %90,228'lik R-kare, 0,00215'lik MSE ve 0,03266'lık MAE ile GRU modeli en yüksek doğruluğu ve en düşük hatayı göstermiştir [128].

Çizelge 1. 7. Doğruluk değerlendirmesi ve yetenek değerlendirmesi için yapay zekanın uygulamalarının bir özetini sunmaktadır.

Yazar(lar)	Yöntem(ler)	Amaçlar	Bulgular
Pérez-Díaz ve diğerleri. [122]	ANN	Düzenleme kapasitesi değerlendirmesi	Türbinin performansı, kılavuz kanatlarının konumunu yeterli şekilde değiştirerek iyileştirilebilir
Zaidi ve ark. [123]	Makine öğrenimi	Enerji su-bağlantısı	Makine Öğrenmesi, suyun ve uygulamalarının görünümelerini anlamak için kullanılabilir
Babar ve ark. [124]	Markov kararı	Talebin fiyat esnekliğinin analizi	Tüketicinin toplam talebinin fiyat elastik davranışı formüle edilmiştir.
Xin Gao ve diğerleri. [126]	EMD-GRU	Kısa vadeli elektrik yükü tahmini	Tahmin doğruluğu dört veri kümesinde %95,31 ile %97,17 arasında değişti
Feifei He ve diğerleri. [127]	VMD ve BOA ile LSTM	Kısa yük tahminini iyileştir	0,4186% MAPE ve 0,9945 R ² elde edildi
Mobarak Abumohsen ve diğerleri. [128]	LSTM, GRU ve RNN modelleri	Elektrik yükünü elektrik şirketi verilerine göre tahmin et	GRU modeli %90,228 R ² , 0,00215 MSE ve 0,03266 MAE ile en iyi performansı gösterdi

Shang-Yi Chuang ve diğerleri, Raspberry Pi tabanlı bir platformda sensör veri analitiği kullanan bir öngörücü bakım sistemi sundular. Bu çalışma, Raspberry Pi tabanlı bir deneysel platform kullanarak bir öngörücü bakım sistemi geliştirdi. Sistem, sensör verilerini (örneğin sıcaklık, nem ve titreşim) toplar ve ekipman arızalarını tahmin etmek için verileri analiz etmek üzere makine öğrenimini kullanır. Sensör verilerini toplamak ve ön işleme tabi tutmak için bir Raspberry Pi ve bir PIC mikrodenetleyici kullanıldı. Veriler bir zaman serisinde depolandı ve ön işleme, modelleme ve tahmin için İstatistiksel Analiz Yazılımı (SAS) kullanılarak analiz edildi. Çok değişkenli analiz, ekipman durumunu belirlemek ve bakım ihtiyaçlarını tahmin etmek için de kullanıldı. Sistem, ekipman arızalarını başarıyla tahmin etti ve bakım programlarını optimize etti. Çok değişkenli analizin kullanımı, karar alma sürecini iyileştirdi ve beklenmeyen kesintileri azalttı. Sistem, öngörücü bakım için düşük maliyetli donanım kullanmanın uygulanabilirliğini gösterdi [129].

Nicholas James ve diğerkleri, tek bir Raspberry Pi Spark kümesi kullanarak dağıtılmış DL çıkarımının performansını inceledi ve bunu ortalama bir masaüstü bilgisayarla karşılaştırdı. Dağıtılmış DL çıkarımı için TensorFlow kullanılarak 2 düğümlü bir Raspberry Pi Spark kümesi oluşturuldu. Üç deney gerçekleştirildi: görüntü sınıflandırması, yüz algılama ve gerçek zamanlı yüz algılama. Küme performansı tek bir Raspberry Pi ve bir masaüstü bilgisayarla karşılaştırıldı. Raspberry Pi Spark kümesi, Raspberry Pi'ye göre önemli bir performans iyileştirmesi göstermedi. Raspberry Pi'yi güçlendirmek (örneğin, hız aşırma, SSD kullanma) bir küme kullanmaktan daha etkiliydi. Masaüstü bilgisayar, DL görevlerinde Raspberry Pi'yi 6 ila 15 kat geride bıraktı. Hafif DL modelleri, Raspberry Pi [130] gibi kaynak açısından kısıtlı cihazlarda daha iyi performans gösterdi.

Dennis Klinkhammer, MicroPython kullanarak Raspberry Pi Pico gibi mikrodnetleyicilere önceden eğitilmiş sinir ağlarını taşımak için bir çerçeve olan AI-Anne'i sundu. Sinir ağı bileşenleri (nöronlar, katmanlar, aktivasyon fonksiyonları) MicroPython'da uygulandı. İki sinir ağı (6-Neuron ve 8-Neuron) Tensorflow/Keras'ta önceden eğitildi ve Raspberry Pi Pico'ya taşındı. IRIS veri kümesi ikili sınıflandırma görevleri için kullanıldı. 6-Neuron ağı %95 doğruluk elde ederken, 8-Neuron ağı %90 doğruluk elde etti. Çalışma, sinir ağlarını kaynak kısıtlı cihazlarda dağıtmanın uygulanabilirliğini gösterdi. AI-Anne, mikrodnetleyicilerde sinir ağlarını keşfetmek için esnek ve eğitici bir araç sağladı [131].

En Li ve diğerkleri, uç cihaz sinerjisiyle talep üzerine derin öğrenme modeli oluşturdu. Çalışmada, gecikmeyi azaltmak için mobil cihazlar ve uç sunucular arasında işbirlikçi DNN çıkarımı için bir çerçeve olan Edgent önerildi. DNN bölümlendirme: DNN hesaplaması, mevcut bant genişliğine göre cihaz ve uç sunucu arasında bölümlendirildi. DNN doğru boyutlandırma: Erken çıkış mekanizmaları, ara katmanlardan çıkarak hesaplamayı azaltmak için kullanıldı. Mobil cihaz olarak bir Raspberry Pi kullanıldı ve bir masaüstü bilgisayar uç sunucuyu simüle etti. Çerçeve, CIFAR-10 veri kümesi ve Alexnet alt modeli kullanılarak değerlendirildi. Edgent, DNN bölümlendirmeyi ve doğru boyutlandırmayı optimize ederek gecikmeyi etkili bir şekilde azalttı. Çerçeve, değişen bant genişliği ve performans gereksinimleri altında

daha yüksek doğruluk elde etti. Çalışma, uçta düşük gecikmeli uç zekası için uç-cihaz sinerjisinin potansiyelini gösterdi [132].

Haoyu Ren, kaynak kısıtlı mikrodenetleyicisinde (MCUS) Tinyml uygulamaları için tasarlanmış birleşik bir meta öğrenme algoritması olan TinyReptile'ı tanıttı. Amaç, veri çeşitliliği ve kaynak kısıtlamaları gibi zorlukları ele alırken küçük cihazlar arasında işbirlikçi öğrenmeyi etkinleştirmektir. TinyReptile, cihazların aynı anda tek bir merkezi sunucuyla iletişim kurmasına izin veren seri bir iletişim şeması kullanır ve bu da onu ağ istikrarsızlığına karşı dayanıklı hale getirir. Algoritma, verileri akışlı bir şekilde işler, her güncellemeden sonra verileri atar ve bu da bellek kullanımını azaltır. Algoritma, bir Raspberry Pi 4 ve bir Arduino Nano 33 Ble Sense MCU üzerinde başarıyla test edilmiş ve Tinyml uygulamaları için uygulanabilirliğini göstermiştir. TinyReptile, heterojen veri ortamlarında geleneksel FL algoritmalarından (FedAVG ve FedSGD) daha iyi performans gösterir [133].

Hasib-Al Rashid, küçük ve kaynak açısından kısıtlı cihazlar için tasarlanmış esnek bir multimedia öğrenme çerçevesi olan TINYM2 Net hakkında bir makale sundu. Çerçeve iki vaka çalışması üzerinde değerlendirildi: Multimedia ses kayıtlarından COVID-19 tespiti ve multimedia görüntülerinden ve sesinden savaş alanı nesne tespiti. Çerçeve, doğruluğu korurken küçük cihazlar için modeli optimize etmek amacıyla karma tahmin (INT4 ve INT8) kullanır. Çerçeve, çıkarım süresini ve güç tüketimini ölçmek için bir Raspberry Pi 4 üzerinde test edildi. Çerçeve, COVID-19 tespiti için 1,2 saniye ve savaş alanı nesne tespiti için 1,7 saniye çıkarım süreleriyle bir Raspberry Pi 4 üzerinde başarıyla uygulandı. Makale, öngörücü bakım için sensör verilerinin ve makine öğreniminin kullanımına odaklanarak bu sistemlerin bir Raspberry Pi üzerinde uygulanmasının uygulanabilirliğini göstermektedir [134].

Çizelge 1. 8. Raspberry Pi kullanımları ve uygulamalarının özeti

Araştırmacılar	Konu	Yöntem	Sonuçlar
Chuang, ve ark. [129]	Sensör veri analitiği kullanılarak öngörücü bakım	Çok değişkenli analiz, veri modelleme için SAS	Azaltılmış kesinti süresi, iyileştirilmiş bakım planlaması
James, ve ark. [130]	Raspberry Pi Spark kümesini kullanarak dağıtılmış DL çıkarımı	Görüntü sınıflandırması, yüz algılama ve gerçek zamanlı yüz algılama deneyleri	Küme önemli bir gelişme göstermedi; masaüstü Raspberry Pi'den daha iyi performans gösterdi
Klinkhammer [131]	TinyML kullanarak DL modellerini mikrodenetleyicilere aktarma	IRIS veri setini kullanarak ikili sınıflandırma	6 nöronlu ağ %95 doğruluk elde etti ve 8 nöronlu ağ %90 doğruluk elde etti
En Li , ve ark. [132]	İsteğe bağlı DNN eş çıkarımı, cihaz-uç sinerjisi	Branchy AlexNet modeli, CIFAR-10 veri seti	Azaltılmış gecikme, değişen bant genişliği ve gecikme altında iyileştirilmiş doğruluk
Haoyu ve ark. [133]	Kaynak kısıtlı MCU'larda işbirlikçi öğrenmeyi etkinleştirin; veri heterojenliğini ve kaynak kısıtlamalarını ele alın	TinyReptile: Seri iletişim ve veri akışı işleme ile meta öğrenme algoritması	Heterojen veri ortamlarında FedAVG ve FedSGD'yi geride bırakır; Raspberry Pi 4 ve Arduino Nano 33 BLE Sense üzerinde test edilmiştir
Hasib-Al ve ark. [134]	Doğruluğu korurken küçük cihazlar için modelleri optimize edin; kaynak kısıtlı cihazlarda multimedya öğrenmeyi etkinleştirin	TinyReptile: Seri iletişim ve veri akışı işleme ile meta öğrenme algoritması	1,2 saniyelik (COVID-19 tespiti) ve 1,7 saniyelik (savaş alanı nesne tespiti) çıkarım sürelerine ulaşıldı; Raspberry Pi 4'te test edildi

1.5. TEZ ORGANİZASYONU

Bölüm 1: Ana motivasyonların ve araştırma problem ifadesinin genel bir bakışı, araştırma hedefleri ve katkıları özetlenmiştir. Bu bölüm ayrıca hidroelektrik santrallerinde kullanılan sistemlerin literatür taraması, bu alanda yapay zeka algoritmalarının kullanımı ve diğer ilgili çalışmalarla ilgili çalışmaları da sunmaktadır.

Bölüm 2: Bu bölüm, hidroelektrik santrallerinin izlenmesi ve kontrolünde kullanılan kontrol sistemleri hakkında teorik bir arka plan sağlamanın yanı sıra, tahmin kavramı, tahminin işlediği farklı mekanizmalar, teknikleri, önemi ve ilişkileri de dahil olmak üzere tahmin hakkında teorik bir arka plan sağlar.

Bölüm 3: Bu bölümde araştırma metodolojisi açıklanmakta olup, ana izleme ve ölçüm işleme birimi de dahil olmak üzere kontrol sistemi ve SCADA ve MATLAB-GUI gibi farklı sistemler ve sistem mimarisi açıklanmaktadır. İkinci bölüm, tekrarlayan sinir ağı ve LSTM, tekrarlayan sinir ağı modeli ve uzun süreli bellek ağının yapısı ile ilgilenmektedir. Materyaller ve yöntemler, bir vaka çalışmasına ek olarak, kullanılan veriler ve bunların analizi, deneysel analiz ve tartışmanın açıklandığı bu bölümde, deneyleri yürütmek için kullanılan yapay ve gerçek veritabanlarının eksiksiz bir açıklaması yer almaktadır. Elde edilen sonuçların değerlendirilmesi ve çeşitli senaryolar kullanılarak deneylerin analizi de sunulmaktadır.


Bölüm 4: Deneysel analiz ve tartışma, deneyleri gerçekleştirmek için kullanılan sentetik ve gerçek dünya veritabanlarının eksiksiz bir açıklamasını içeren bu bölümde açıklanmaktadır. Elde edilen sonuçların değerlendirilmesi ve çeşitli senaryolar kullanılarak yapılan deneylerin analizi de sunulmaktadır.

Bölüm 5: Son bölüm sunulan araştırmayı özetlemekte ve tezin bulguları ve katkılarıyla sonuçlanmaktadır. Tüm araştırma hedefleri ve sonuçlarının bir incelemesi yapılmaktadır. Bu bölüm ayrıca bu araştırma çalışmasının bilimsel katkılarını da vurgulamaktadır.

BÖLÜM 2

TEORİK ARKA PLAN

Bu bölüm, hidroelektrik santrallerinde kullanılan izleme ve kontrol sistemlerine genel bir bakışın yanı sıra tahmin ve yapay zekanın (YZ) incelenmesi ve bunların izleme ve kontrolle ilişkisi, teorik ve metodolojik katkılar dahil olmak üzere bir inceleme sunmaktadır. Burada kullanılan araştırma metodolojisi, çeşitli araştırma alanlarının kesişim noktasındadır. Bu tez, kontrol kavramlarını ve kullanılan sistemleri, ayrıca tahmin kavramlarını, tahmin sürecini, teknolojisini ve sınırlamalarını tanıtmaktadır. Daha sonra, tahmin algoritmaları ve tahminde YZ ve sinir ağlarının kullanımı ile ilgili bazı terimler tanımlanmaktadır. Çalışma, çeşitli yaklaşımları analiz ederek, ilgili literatüre daha kapsamlı bir genel bakış sağlamak için her yaklaşımın avantajlarını ve dezavantajlarını incelemektedir.



Şekil 2. 1. Hidroelektrik santralleri

2.1. KONTROL SİSTEMLERİ

2.1.1. Kontrol Sistemlerine Genel Bakış


Kontrol sistemleri, hidroelektrik santrallerindeki cihazların veya diğer sistemlerin davranışlarını izlemek, yönetmek, düzenlemek ve kontrol etmek için tasarlanmıştır ve bu santrallerin davranışlarının anlaşılmasını, istenen çıktının elde edilmesini ve önceden tanımlanmış görevlerin gerçekleştirilmesini sağlar. Sistemin mevcut durum girişlerini bir dizi sensörden (konum, basınç, titreşim, sıcaklık, hız vb. gibi) alarak, bunları programlama döngülerine girerek, istenen hedef veya referans değeriyle (Setpoint) karşılaştırarak ve gerçek ve istenen durum arasındaki farkı en aza indirmek için ayarlamalar yaparak çalışırlar. Kontrol sistemleri, robotik, havacılık, üretim ve ev otomasyonu dahil olmak üzere çeşitli endüstrilerde ve uygulamalarda yaygın olarak kullanılmaktadır. Bunlar arasında hidroelektrik santrallerinde kullanılan SCADA sistemi gibi kontrol sistemleri ve MATLAB ve grafiksel kullanıcı arayüzü (GUI) kullanılarak tasarlanmış izleme ve kontrol sistemleri bulunmaktadır.

2.1.1.1. Hidroelektrik Santrali İçin Otomasyon

Otomasyon sistemlerinin ortaya çıkmasından önce, kalifiye personel ekipmanı manuel olarak çalıştırıyordu. Buna manuel sistem deniyordu. Tüm santral ekipmanını (türbin, jeneratör, kesici vb.) manuel olarak çalıştıran kalifiye personel, öncelikle ekipmanın durumunu kontrol etmelidir. Operatör, duruma göre belirlenen eksiklikleri gidermek için gerekli düzeltmeleri yapabilir. Bu yaklaşım, operatörler tarafından tam zamanlı denetim gerektirir. Aynısı otomatik bir sistem için de geçerlidir. Otomatik bir sistem ayrıca ekipman durumunda bulunan bilgileri okur ve ardından santraldeki çeşitli ekipmanlar için komutları etkinleştirir. Otomatik sıralamadan sorumludur.

Ancak bu tür bir sistem aynı zamanda uzmanlaşmış personel gerektirecektir. Otomatik sistemin operatörü, zaman zaman ihtiyaçlara veya üretim gereksinimlerine göre komutlarda veya kontrollerde gerekli değişiklikleri yapmalıdır. Bir hidroelektrik santralinin işletimini yönetme ve kontrol etme sistemi Şekil 2.2'de gösterilmiştir. Gerçek zamanlı bilgi edinerek, yerel ve uzaktan bir kontrol sistemi ve gelişmiş bir

koruma sistemi sağlayarak elde edilir. Otomasyon sistemi, Şekil 2.2.'da gösterildiği gibi aşağıdakilerden oluşur [135].



Şekil 2. 2. Bir hidroelektrik santrali istasyonu için otomasyon sistemi

2.1.1.2. PLC Otomasyon İçin Önemli Bir Araçtır

Hidroelektrik santralinin otomasyonunun amacı, tüm tesis sürecini otomatikleştirmektir. Böyle bir işlem genellikle birden fazla adım ve prosedür içerir. Bu adımlardan bazıları sırayla gerçekleşirken diğerleri paralel olarak gerçekleşir. Bazı olaylar, vanaların açık veya kapalı olması veya aksesuarların açık veya kapalı olması gibi tesisteki durumların ayrı ayrı ayarlanmasını içerebilir. Diğer olaylar, zaman içinde veya çalışma sırasında sürekli bir değişkenin düzenlenmesini içerebilir. Örneğin, bir makinenin diğeriyle senkronize kalması için sabit bir hızın korunması çok önemlidir. Bu nedenle, bir hidroelektrik santralinin çalışması hem ayrı hem de sürekli süreçlerin bir kombinasyonunu içerir.

Geliştirmenin ilk günlerinde, bir mikroişlemci bu görevleri yerine getirmenin önemli bir yoluydu, ancak röle sayısı değişmeden kaldı. Ancak PLC'nin yardımıyla, sabit kablolu rölelerin kullanımı en aza indirildi. Büyük bir PLC, tüm işlemleri gerçekleştirmek için yeterli sayıda röleye sahiptir. Bu rölelerin avantajları, dijital olmaları, sisteme minimum hasar vermeleri, maliyet düşürmeleri ve bakım

gereksinimlerini azaltmalarıdır. Kontrol sisteminde deęişiklik yapılması gerektiğinde sadece programın güncellenmesi yeterli oluyor, bu da ek bir maliyete yol açmadan kolaylıkla yapılabilir.


PLC bu işlemleri çok etkili bir şekilde gerçekleştirebilir. PLC'ye çeşitli işlevler ve kontroller programlanabilir. Bunlar, otomatik çalışmayı, hız kontrolünü, yük kontrolünü, uyarma kontrolünü, seviye kontrolünü, otomatik başlatma/durdurma dizisini, kapı kontrolünü ve yardımcı sistemlerin başlatılmasını/durdurulmasını ve ayrıca koruma gereksinimlerini yönetmek de dahil olmak üzere tam tesis otomasyonu için kullanılabilirler [136]. PLC, ayrık kontrol sistemleri için en uygundur. PLC [137], işlemi izleyen SCADA'ya (Denetleyici Kontrol ve Veri Toplama) bağlanır. Burada olay dizisi bir merdiven diyagramı oluşturacak şekilde programlanır. Örneğin, bir makineyi başlatmada yer alan olay dizisi, basınç anahtarlarının ve limit anahtarlarının algılanması gibi ayrı durum kontrolünü içerir. Diğer olaylar tamamen sürekli veya belki de hem ayrık hem de sürekli süreçlerin bir kombinasyonudur.

2.1.1.3. Hidroelektrik Santral İçin Scada Sistemi

SCADA, genellikle endüstriyel kontrol sistemlerine, endüstriyel süreçleri izleyen ve kontrol eden bir bilgisayar sistemine atıfta bulunan Denetleyici Kontrol ve Veri Toplama [138] anlamına gelir. Bir SCADA kontrol merkezi, alarmları ve işleme durumunu izleme dahil olmak üzere uzun mesafeli iletişim ağları üzerinden saha sahaları için merkezi izleme ve kontrol gerçekleştirir.

PC tabanlı SCADA sistemleriyle [139] birleştirilen PLC tipi tesis kontrolörü, tesis kontrolü ve veri toplama için kullanılır. Bu, sistemi ekonomik olarak uygulanabilir hale getirir ve onu birçok küçük hidroelektrik santrali [140] için üretim, kontrol ve otomasyon açısından uygun hale getirir. Uzak istasyonlardan alınan bilgilere dayanarak, otomatik veya operatör tarafından yönlendirilen denetleyici komutlar, genellikle saha cihazları olarak adlandırılan uzak istasyon kontrol cihazlarına gönderilebilir.

Şekil 2.3. Bir hidroelektrik santralının tipik bir SCADA sistemini göstermektedir. Bu diyagramın, işletme ve izleme için gereken farklı bölümlere sahip olduğu görülebilir.



Şekil 2. 3. Bir hidroelektrik santralının SCADA ekranı

2.1.1.4. Field Instrument

Bir alet, akış, sıcaklık, seviye veya basınç gibi fiziksel nicelikleri/işlem değişkenlerini ölçen ve/veya düzenleyen bir cihazdır. Bu aletler, bir enerji santralinde ölçüm için çeşitli uzak yerlere kurulur. Yani, besleme borusundaki veya enerji santrali rezervuarındaki akışı ölçmek için bir akış sensörü. Çıkış enstrümantasyonu, solenoidler, vanalar, regülatörler, devre kesiciler ve röleler gibi cihazları içerir. Bu cihazlar, istenen bir çıkış değişkenini kontrol eder ve uzaktan veya otomatik kontrol yetenekleri sağlar. Bunlar, uzaktan veya bir kontrol sistemi tarafından kontrol edildiğinde genellikle son kontrol elemanları olarak adlandırılır.

Vericiler, genellikle 4–20 mA elektrik akımı sinyali biçiminde bir çıkış sinyali üreten cihazlardır. Ancak, voltaj, frekans ve basınç gibi birçok başka seçenek de mümkündür.

Bu sinyal, bilgilendirme amaçlı kullanılacak veya kontrol ve izleme için bir PLC SCADA sistemine gönderilebilir.

2.1.1.5. İletişim Protokolü

Çeşitli kontrol ve koruma sistemlerini SCADA ile arayüzlemek için iletişim protokolleri gereklidir. Standart ve tescilli iletişim protokolleri, telefon hatları, kablo, fiber ve yayın, mikrodalga ve uydu gibi radyo frekansları dahil olmak üzere çeşitli telemetri tekniklerini kullanarak kontrol merkezi ile saha sahaları arasında bilgi taşımak için kullanılır.

Başlıca iletişim protokolleri aşağıdaki gibidir.

Modbus

Modbus, Modicon Corporation tarafından tanıtılan bir iletişim protokolüdür. Endüstriyel otomasyonda yaygın olarak kullanılır ve gerçek endüstriyel standart haline gelmiştir [141]. Noktadan noktaya Modbus protokolü, RTU ve PLC iletişimleri için sanal bir standart haline gelmiştir. Bir Modbus ağında iletişim sırasında, protokol her bir denetleyicinin cihaz adresini nasıl tanımladığını, kendisine gönderilen bir mesajı nasıl tanıdığını, gerçekleştirilecek eylemi nasıl belirlediğini ve kendisine eklenen herhangi bir bilgi veya veriyi nasıl çıkardığını belirler. Bu eksiklikleri gidermek için birkaç genişletmeye ihtiyaç vardır.

DNP (Dağıtılmış Ağ Protokolü)

Dağıtılmış Ağ Protokolü Sürüm 3 (DNP3), kamu hizmetleri sektörünü destekleyen Gözetim Kontrol ve Veri Toplama (SCADA) Sistemleri için geliştirilen açık ve optimize edilmiş bir protokoldür [142]. Bazı Elektrik Enerjisi sistemlerinde üye kısıtlamalı bir protokol kullanılır. DNP protokolü çeşitli yinelemelerden geçmiştir. Şu anda sürüm 3.0'a ulaşmıştır. DNP derneğinin protokolün kullanımını kısıtlama eğiliminde olan kuralları vardır ve büyük SCADA yazılım tedarikçileri protokolü uygulamada yavaş davranmıştır.

IEC 60870

IEC 60870, Uluslararası Elektroteknik Komisyonu (IEC) tarafından SCADA telemetrisi, kontrolü ve bilgisinin iletimi için geliştirilen açık standartlar koleksiyonudur [143]. Bu protokol çoğunlukla güç iletim ve dağıtım sistemlerinde kullanılır. IEC 60870-5-101, dünya çapında birçok ülkede yaygın olarak benimsenen Elektrik Gücü iletim sistemlerinin telekontrolüne yönelik bir Uluslararası İletişim Protokolü Standardıdır.

IEC 60870-5, sistemler arasında kalıcı olarak doğrudan bağlı veri devreleri kullanan iki sistem arasında temel telekontrol mesajları göndermek için bir iletişim profili sağlar. IEC TC 57 WG3, elektrik güç sistemleri için telekontrol, telekoruma ve ilişkili telekomünikasyonlar için bir protokol standardı geliştirmiştir. Bu çalışmanın sonucu

1. IEC 60870-5'tir. Beş belge temel IEC 60870-5'i belirtir:
2. IEC 60870-5-1 İletim Çerçeve Biçimleri
3. IEC 60870-5-2 Veri Bağlantısı İletim Hizmetleri
4. IEC 60870-5-3 Uygulama Verilerinin Genel Yapısı.

2.1.2. SCADA (Gözetimsel Kontrol ve Veri Toplama) Sistemleri

Endüstriyel kontrol sistemi (ICS), kritik altyapı ve endüstriyel sektörlerde sıklıkla bulunan programlanabilir mantık denetleyicileri (PLC'ler), denetleyici kontrol ve veri toplama (SCADA) sistemleri ve dağıtılmış kontrol sistemleri (DCS) dahil olmak üzere çeşitli kontrol sistemi türlerini kapsayan genel bir terimdir. ICS'ler gaz, elektrik, petrol, su, ulaşım, kağıt hamuru ve kağıt, kimyasallar, ilaçlar, içecekler, gıda ve ayrı üretim (örneğin dayanıklı mallar, havacılık ve otomotiv) dahil olmak üzere çeşitli endüstrilerde kullanılır [144].

SCADA, Denetleyici Kontrol ve Veri Toplama anlamına gelir. Üretim, güç üretimi ve su arıtma gibi endüstriyel süreçleri uzaktan kontrol etmek ve izlemek için kullanılan bir sistemi ifade eder. Sistem operatörlere saha cihazlarından gerçek zamanlı veriler

sağlar ve süreçleri merkezi bir konumdan kontrol etmelerine ve yönetmelerine olanak tanır.

SCADA, karmaşık sistemlerin sürekli izlenmesini ve kontrolünü gerektiren, verimliliği, güvenilirliği ve emniyeti sağlayan büyük ölçekli endüstriler için kritik öneme sahiptir. Operasyonel kontrolü geliştirir, insan müdahalesini en aza indirir, optimum kaynak tahsisini sağlar ve sistem güvenilirliğini iyileştirir. SCADA'nın birincil işlevi, pompalar, vanalar ve diğer cihazlar gibi uzak ekipmanlardan veri toplamak ve bu verileri SCADA ana yazılım platformunda görüntülemektir. Bu, yerel operasyonel kontrol sağlar. Bu, bu makinelerin gerçek zamanlı olarak başlatılmasını ve durdurulmasını sağlayarak kontrol stratejinizi destekler ve bu süreçler için olayları (alarmları) yakalamak ve verileri izlemek için uzaktan bir yöntem sağlar. SCADA ana platformları ayrıca geçmiş verileri depolamak, grafikleri görüntülemek ve iş zekası oluşturmak için işlevler sağlar [145].

Erken Sistemler: SCADA sistemleri, operatörlerin endüstriyel süreçleri fiziksel olarak kontrol ettiği 1960'ların manuel kontrol süreçlerinden evrimleşmiştir. Erken sistemler, verileri merkezi bir kontrol odasına iletmek için telemetri ile temel kontrol döngülerini kullanmıştır. Dijital Devrim: 1980'lerde, kişisel bilgisayarlar ve mikroişlemcilerin ortaya çıkmasıyla SCADA sistemleri analogdan dijital sistemlere geçiş yaptı ve verilerin işlenmesini, görselleştirilmesini ve uzaktan izlenmesini mümkün kıldı [146].

SCADA sistemleri, saha verilerini toplamak, bunları merkezi bir bilgisayar tesisine iletmek ve verileri operatöre grafiksel veya metinsel olarak görüntülemek için tasarlanmıştır; böylece operatör, gerçek zamanlı olarak merkezi bir konumdan tüm sistemi izleyebilir veya kontrol edebilir. Bireysel sistemin karmaşıklığına ve kurulumuna bağlı olarak, herhangi bir sistemin, operasyonun veya görevin kontrolü otomatik olabilir veya operatör talimatlarıyla gerçekleştirilebilir [147-148].

Modern SCADA: Günümüzde SCADA sistemleri, modern BT teknolojilerini, Nesnelerin İnterneti cihazlarını ve kablosuz iletişimlerini entegre ederek oldukça gelişmiştir. Gerçek zamanlı veri analitiği, öngörücü bakım ve uzaktan sorun gidermeyi mümkün kılar. Denetim, bir süreci yönetmek ve denetlemekten oluşur. Bu hedefe

ulařmak için, bir süreç denetim sistemi, süreçle ilişkili kritik veri kaynaklarını toplamalı, izlemeli ve kaydetmeli, olası işlev kaybını tespit etmeli ve insan operatörü uyarmalıdır [149-147].

Bir denetim sisteminin temel amacı, bir insan operatörüne son derece otomatikleştirilmiş bir süreci kontrol etme ve yönetme araçları sağlamaktır. Bu nedenle, endüstriyel proses denetimi, bir prosesin işleyişini kontrol etmek ve denetlemek için tasarlanmış bir dizi görevi kapsar [150-148]. Bunlar, fiziksel dünyadaki endüstriyel prosesleri kontrol eden ve izleyen bilgisayar tabanlı kontrol sistemleridir. SCADA sistemleri, petrol işleme ve üretimi, ilaçlar, endüstriyel tesisler, enerji, dağıtım, su arıtma ve diğerleri dahil olmak üzere çeşitli endüstrilerde yaygın olarak kullanılmaktadır. Analiz ve toplama gerektiren, hızlı tempolu operasyonlarda hassas kontrol gerektiren veya uzun mesafelere yayılmış büyük miktarda veri içeren prosesler için en iyi kontrol yöntemidir [151-149].

Öte yandan, oldukça dağıtılmış SCADA sistemleri, genellikle yerel kontrol ve veri toplamanın sistem operasyonları için kritik öneme sahip olduğu, geniş alanlara yayılmış, coğrafi olarak dağılmış varlıkları kontrol etmek için kullanılır. Atık su toplama ve su dağıtım sistemleri, gaz ve petrol boru hatları, demiryolu iletim sistemleri ve elektrik şebekeleri dahil olmak üzere çeşitli dağıtım sistemlerinde kullanılırlar. Bir SCADA kontrol merkezi, durum verilerinin sağlanması ve alarm izleme dahil olmak üzere uzun mesafeli iletişim ağları üzerinden saha sahalarında yerel izleme ve kontrol gerçekleştirir. Uzak istasyonlardan alınan verilere dayanarak, operatör tarafından yönlendirilen veya otomatik denetim talimatları, genellikle saha enstrümanları olarak adlandırılan uzak istasyonun kontrol ekipmanına iletilebilir. Saha enstrümanları, vanaları kapatma ve açma gibi işlemleri kontrol eder, sensör sistemlerinden veri toplar ve alarm koşulları açısından ortamı izler [144].

Bu sistemler su dağıtımında, gaz ve petrol boru hatlarında, demiryolu iletim sistemlerinde ve elektrik şebekelerinde kullanılır. SCADA kontrol merkezi, durum verilerinin toplanması ve alarmların izlenmesi dahil olmak üzere uzun mesafeli iletişim ağları üzerinden saha sahalarının yerinde izlenmesini ve kontrolünü gerçekleştirir. Uzak istasyonlardan alınan verilere dayanarak, operatör tarafından

yönlendirilen veya otomatik denetim talimatları, genellikle saha enstrümanları olarak adlandırılan uzak istasyonun kontrol ekipmanına gönderilebilir. Saha enstrümanları, vanaları ve kesicileri kapatma ve açma, sensör sistemlerinden veri toplama ve alarm koşulları için orijinal ortamı izleme gibi işlem operasyonlarını kontrol eder [144].

Bir SCADA sistemi üretim ve iletim sistemlerini denetler. Bu sistemlerin temel bileşeni, verileri otomatik olarak toplayan ve sensörler, ölçüm cihazları, günlükler veya proses ekipmanlarıyla doğrudan iletişim kuran RTU'dur (Uzak Terminal Birimi) [150-152]. İzlenen prosesin yakınında bulunurlar ve talep üzerine verileri kontrol ünitesine iletirler. Genellikle entegre yazılım, veri kaydı yetenekleri, gerçek zamanlı saat (RTC) ve pil yedeği içerirler. Çoğu RTU zaman yedeklidir. Bu cihazlar, birincil RTU arızası durumunda düzgün çalışması için gerekli tüm vericileri, kodlayıcıları ve işlemcileri içeren eksiksiz terminal birimleridir. Ölçüm cihazları ve ekipman durum raporları ayrıca programlanabilir mantık denetleyicileri (PLC'ler) tarafından da gerçekleştirilebilir.

SCADA sistemleri hem yazılım hem de donanım bileşenlerini içerir. Standart donanım, kontrolün merkezinde konumlandırılmış bir MTU (Ana Terminal Birimi), iletişim ekipmanı (örneğin, telefon hatları, kablolar, uydular veya radyolar) ve aktüatörleri kontrol eden ve/veya sensörleri gözlemleyen bir PLC veya RTU içeren coğrafi olarak dağıtılmış bir veya daha fazla saha alanını kapsar. MTU, RTU çıkışlarından ve girişlerinden gelen verileri adresler ve kaydederken, PLC veya RTU yerel operasyonu kontrol eder. İletişim cihazı, PLC'ler veya RTU'lar ile MTU arasında veri ve bilgi iletimi için izin verir. Yazılım, sisteme ne zaman ve neyi gözlemleyeceğini, parametreler geçerli değerleri aştığında hangi yankıların başlatılacağını ve hangi parametre aralıklarının geçerli kabul edileceğini bildirmek üzere programlanmıştır.

Koruyucu röle gibi bir IED (Akıllı Elektronik Cihaz), doğrudan SCADA ana istasyonu ile iletişim kurabilir veya yerel bir RTU, IED'lerden veri toplamayı ve SCADA ana istasyonuna göndermeyi seçebilir. IED'ler, ekipmanı, kontrolü ve sensörleri gözlemlemek için anında bir arayüz sağlar. IED'ler SCADA ana istasyonu tarafından hemen seçilebilir ve kontrol edilebilir ve çoğu eyalette, SCADA kontrol

merkezinden anında talimat almadan IED'nin otonom olarak çalışmasını sağlayan yerel programlama vardır. SCADA sistemleri tipik olarak arıza toleranslı olacak şekilde tasarlanır ve sistem yapılarına yüksek yedeklilik entegre edilir [153].

2.1.2.1. Sistemin Ele Aldığı Sorunlar

Sistemin farklı tip, boyut ve çalışma modlarındaki hidroelektrik makinelerinin farklı taleplerini karşılayacak şekilde ideal hale getirilmesi için aşağıdaki hususlara odaklanılmıştır:

İzleme

Health Hydro izleme modülü, tüm ölçümleri ve karakteristik değerleri çalışma modu ve çalışma noktasının bir fonksiyonu olarak değerlendirir ve ünitenin mekanik korumasına aktarılabilecek gezi sinyallerini üreten parametrelere dayalı mantıksal fonksiyonları içerir. Aşağıdaki izleme fonksiyonlarını destekler. Health Hydro konsepti:

1. Şaft, yatak, türbin başlığı kapağı, stator çekirdeği, labirent, uç sargısı ve eksenel titreşim,
2. Kısmi deşarj,
3. Jeneratör hava boşluğu,
4. Manyetik akı,
5. Diğerlerinin yanı sıra: sıcaklık, basınç ve şaft akımı.

Kavitasyon izleme

Kavitasyon, hidrolik türbinlerin çalışma aralığını potansiyel olarak sınırlayan istenmeyen bir hidrolik olgudur. Gürültü ve titreşimlere neden olur ve hatta türbin bileşenlerinin yüzeyini aşındırabilir. Sağlık kavitasyon izleme, hidrolik makinenin içindeki kavitasyon durumu hakkında güvenilir çevrimiçi bilgi sağlar. Bu modül, operasyonel gereksinimler ile ekonomik performans arasında doğru dengeyi bulmanıza yardımcı olur.

Health Hydro kavitasyon izleme sisteminin temel faydaları şunlardır:

1. Uzatılmış bakım aralıkları, ilk kavitasyon hasarının erken tespiti ve işletme kaybının azaltılması sayesinde bakım maliyetleri %30'a kadar azaltıldı,
2. Gerekli onarımların daha iyi planlanması ve kavitasyon hasarları nedeniyle muayene ve bakım bekleme süresinin azaltılmasıyla kullanılabilirlik %0,5'e kadar artırıldı,
3. Alışılmadık davranışların erken tespiti, kavitasyon bölgelerinin önlenmesi ve kavitasyon koşullarında işletme maliyetinin nicelleştirilmesi yoluyla işletme ve telafi optimizasyonu.

Voith şu anda sürekli Health Hydro kavitasyon izlemesinin işlevselliğini geliştirmek ve genişletmek için özel müşterilerle ortak geliştirmeler üzerinde işbirliği yapıyor. İlk pilot müşterilerden biri olun ve kavitasyon izlemenin ek, kapsamlı faydalarından yararlanın.

Analiz

Tesis operatörüne sağlanan faydaları genişletmek için, sistemin koşula dayalı bakım stratejilerini verimli bir şekilde destekleyebilmesi gerekir. Health Hydro modülleri, bu gelişmiş gereksinimleri karşılamak üzere özel olarak tasarlanmıştır:

1. Uyarlanmış analiz tekniklerine sahip son derece hassas ölçüm teknolojisi,
2. Belirli parametrelerin doğru seçimi ve ölçülen değerlerin belirli tesis koşullarına ve makine çalışma modlarına bağlı olarak beklenen davranışla karşılaştırılması için tanısal zeka,
3. Çok düşük hız veya son derece değişken uyarma gereksinimlerine sahip çeşitli çalışma modları gibi belirli koşulları karşılamak için özel olarak tasarlanmış sistemler,
4. Ölçüm cihazından önceden işlenmiş değerlerin analitik değerlendirmesini kapsayan akıllı ölçüm ve analiz sistemleri aracılığıyla hassas makine izleme. Örneğin, frekans analizi frekans seçici gözlem sonuçları sağlar ve daha fazla hidroelektrik gücüne özgü karakteristik değer hesaplar.

Tanımlama

Esnekliği ve uyarlanabilir modüler yapılandırmasıyla Health Hydro, güvenilir teşhis için güçlü bir araç sunar ve her zaman güvenli çalışmayı garanti eder; bu, öngörücü bakımın temel bir bileşenidir. Bir bilgi veritabanı, analiz sonuçlarını otomatik olarak işler. Veritabanı, her güç ünitesine göre uyarlanır ve öncelikle tamamen özelleştirilmiş, dinamik makine modellerine dayanır. Ünitenin matematiksel modeli, en yüksek proses uzmanlığını ve mevcut tüm mekanik bağlantıları içerdiğinden niceliksel ve nitel değerlendirmeleri garanti eder. Ek olarak, operasyonel deneyim bilgi veritabanına entegre edilebilir.

2.1.2.2. SCADA Sistemleri Sinyalleri

SCADA sistemlerinde, çok sayıda bileşen çeşitli sinyal türleri gönderip alır ve SCADA sisteminin veri toplamasını ve sistemin gerekli görevlerini yerine getirmesini kontrol etmesini sağlar. SCADA sistemindeki sinyal türleri iki ana türe kısaltılmıştır. İlk sinyal türü şudur:

1. DI – Dijital Giriş,
2. DO – Dijital Çıkış.

Dijital veya Ayrık sinyaller, bir SCADA sistemine AÇIK veya KAPALI girişi sağlar. Bu sinyaller, açık veya kapalı bir anahtar gibi sadece bir veya sıfır olmak üzere iki değer alır. Bunlar, bilgisayar işlemcilerinde kullanılan aynı ikili sinyallerdir.

İkinci sinyal türü şudur:

1. AI – Analog Giriş,
2. AO – Analog Çıkış.


Analog sinyaller, sürekli değişen değerlere sahip sinyallerdir. Bu değişikliğe göre, önerilen sistemde yeni bir değişiklik vardır. Öte yandan, sinyal değerindeki bir değişiklik, gözlemlenen parametrelerde bir değişiklik olduğunu gösterir. Örneğin, basınç ve sıcaklık analog sinyallerdir. Enstrümanlar tarafından üretilen ve bir SCADA

sistemi tarafından gözlemlenen sinyallerin formatı tipik olarak akım veya voltajdır, örneğin 4-20 mA, 0-20 mA, 1- 5 V DC, 0-5 V DC, -10 V DC ila 10 V DC, vb. [149].

2.1.2.3. SCADA Sisteminin Ana Bileşenleri

SCADA sistemlerini uygulamak, her sistemin dört hassas bileşenini anlamayı gerektirir. Birçok üretici genellikle uzak veya tehlikeli yerlerdeki ekipmanları izlemek ve kontrol etmek için SCADA sistemlerini kullanır. Her sistem, dört temel bileşene ayrılmış çeşitli parçalarla donatılmıştır [154].

1. PLC (Programlanabilir Mantık Denetleyicisi) / RTU (Uzak Terminal Birimi),
2. Merkezi Bilgisayar İstasyonu, HMI Yazılımı dahil – belirli RTU'lar için özel veya açık, çeşitli ürünlerle arayüz oluşturma yeteneğiyle,
3. İletişim Bağlantısı – açık standart (MODBUS gibi) ve özel,
4. SCADA Sistemlerinde Kullanılan Ortak Sensörler veya Saha Aletleri ve hidroelektrik santrallerinde kullanılan saha ekipmanları.



Şekil 2. 4. SCADA sistemine genel bakış

PLC ve RTU

SCADA sistemi, cihazlardan veri toplayan, bunları bilgisayar tarafından okunabilen ve anlaşılabilen bir biçime dönüştüren ve yüksek hızlı iletişimi kolaylaştıran önemli bir bileşen içerir. Bu parça programlanabilir mantık denetleyicisidir (PLC) [155].

1968'de PLC (Programlanabilir Mantık Denetleyicisi), Bedford Associates mühendisi Dick Morley tarafından otomobil üreticisini desteklemek için tasarlandı. İlk nesil PLC'ye MODICON (MODULAR DIGITAL CONTROLLER) adı verildi [156].

Gün geçtikçe PLC'nin çeşitleri gelişti. Bunlardan ikisi şunlardır:

1. RTU – Uzaktan Telemetri Birimi,
2. PAC (Programlanabilir Otomasyon Denetleyicisi) veya bir tür PLC (Programlanabilir Mantık Denetleyicisi).

Uzaktan Telemetri Birimi (RTU), veri toplamak ve ardından bu verileri uzak bir işlemciye göndermek için tasarlanmıştır. Bir RTU, bir PC'nin bağlantı yeteneklerine ve bir PLC'nin G/Ç yeteneklerine sahipken, aynı zamanda zorlu ortamlara dayanacak şekilde üretilmiştir. Dahili bir program kullanarak işlemleri kontrol etmese de, belirli bir zamanda temel denetleyiciye veri aktarabilen bir veri kaydedici olarak işlev görür. RTU'nun hibrit bir versiyonu, ev içi işlemleri kontrol eden ve bir RTU'nun iletişim görevlerini yerine getiren bir PLC içerir [156].

Programlanabilir Mantık Denetleyicisinin (PLC) yeni nesli, bir PLC ile aynı biçime ve işleve sahip bir Programlanabilir Otomasyon Denetleyicisidir (PAC). Bu cihaz, hesaplama teknikleri ve hız açısından bir bilgisayarla daha fazla ilişkilendirilen bir işlemciye sahiptir. PAC'nin en önemli avantajı, Ethernet'e dayanan modern iletişim ağlarıyla daha verimli bir şekilde iletişim kurabilme yeteneğidir [149].

Uzaktan Telemetri Birimleri (RTU'lar) ve Programlanabilir Mantık Denetleyicileri (PLC'ler), belirgin şekilde farklı ekipman parçaları olarak kullanılır; Ancak, bu

farklılıklar genellikle gün geçtikçe belirsizleşir. Bu, bu cihazların sanayicileri pazar taleplerini karşılama yeteneklerini geliştirdikçe bir teknoloji alışverişi olmuştur.

Otuz yıl önce, bir RTU, saha cihazlarını bağlamak için kullanılan 'aptal' bir telemetri kutusu idi. RTU, verileri cihazlardan SCADA ana bilgisayarına herhangi bir adresleme veya kontrol olmadan 'aktarırdı', ancak iyi gelişmiş iletişim arayüzlerine veya telemetriye sahipti. Birkaç yıl sonra, özellikle 1990'larda, üreticiler RTU'ya kontrol programlaması ekleyerek onu Programlanabilir Mantık Denetleyicisine (PLC) daha benzer hale getirdiler. Öte yandan, PLC'ler her zaman kontrol programını yürütebilirdi, ancak iletişim arayüzleri, yakın zamanda eklenen verileri kaydetme yeteneğinden yoksundu.

Sahadaki enstrümanların daha da evrimi, bir dizi cihaz ve enstrümanı bir RTU/PLC ile birleştirebilen, teknoloji setlerini birleştirerek ortak operasyon taleplerine 'hazır' bir yol sağlayan belirli bir uygulama sunmaktır, örneğin akış ölçümü, gözlemlene unsurları ve SCADA ana bilgisayarına bir varlık olarak genişleyecek kontrolü kapsayan gaz kuyusu üretimi.

Ekolojik ve düzenleyici boyun eğdirme deyimlerinde, RTU'lar ve PLC'ler benzer bir ortamda çalıştıkları için benzer taleplerle karşı karşıyadır. PLC'ler geleneksel olarak RTU'lar kadar çevre dostu olmasa da. Bunun temel nedeni, PLC'lerin fabrika zeminleri gibi ortamın daha önce bir dereceye kadar şartlandırılmış olduğu ortamlarda çalışmak üzere tasarlanmış olmalarıdır [154].

Uzaktan İletişim Ağları

Uzak iletişim ağı, sahada veya boru hattı boyunca bulunan uzak RTU'lardan/PLC'lerden, genellikle merkezi kontrol merkezinde veya saha ofisinde bulunan SCADA ana bilgisayarına bilgi aktarımı için çok önemlidir. Varlıklar geniş bir coğrafi alana dağıtıldığında, iletişim bir SCADA sisteminin bağlayıcı parçası veya tutkalı olarak hizmet eder ve çalışması için temeldir. Bir SCADA sisteminin uzak varlıklarla etkili bir şekilde iletişim kurabilme yeteneği, genel başarısı için çok önemlidir.


Yirmi yıl önce, iletişim ağı, kurulumu ve bakımı çok maliyetli olan kiralık hatlardan veya çevirmeli modemlerden oluşuyordu. Ancak, birçok tüketici yakın zamanda maliyetleri düşürmek ve sorunlu kablolama sorunlarını ortadan kaldırmak için uydu veya radyo iletişimine geçti. Son zamanlarda, daha iyi teşhis ve daha yüksek iletişim oranları sağlayan hücresel iletişimler ve gelişmiş radyo cihazları da dahil olmak üzere diğer iletişim biçimleri kullanılabilir hale geldi. Bu tür iletişim ortamlarının hala arızaya meyilli olması, dağıtılmış, modern SCADA sistemleri için temel bir sorun olsa da, iletişim ortamı değiştiğinde protokoller de buna göre değişir.

Protokollerin tanımı, RTU'ların ve PLC'lerin diğer RTU'lar ve PLC'ler veya SCADA ana bilgisayar platformlarıyla bilgi alışverişinde bulunmak için kullandıkları elektronik dillerdir. Önceleri, protokoller tek bir üreticinin ürünü ve tescilli idi. Daha ileri bir evrim olarak, birçok sanayici tek bir protokole, MODBUS'a ilgi duydu, ancak belirli görev taleplerini karşılamak için tescilli bileşenler ekledi. Gaz ve petrol endüstrisinde, MODBUS ASCII, MODBUS RTU ve MODBUS/TCP dahil ancak bunlarla sınırlı olmamak üzere çeşitli MODBUS protokolleri kullanılır.

Bu, belirli bir PLC veya RTU'dan akış veya adres bilgilerini kurtarmak için bir iletişim normu sağladı. MODBUS protokol değişkenlerini kullanmadaki bu artan gelişme bir ilerleme olarak görüldü, ancak yine de bir kullanıcıyı belirli bir sanayiciye bağladı ve bu durum bugün de geçerliliğini koruyor. İyi bir örnek, bir SCADA ana bilgisayarı tarafından bir RTU/PLC'den geçmiş akış bilgilerinin nasıl kurtarıldığıdır. SCADA ana bilgisayar yazılımının iyileştirilmesi ve bazı eyaletlerde protokol dillerinin katılımı, tescilli öğelerle ilgili sorunların bir kısmının daha da çözüldüğünü gösterse de.

Son zamanlarda, DNP (Dağıtılmış Ağ Protokolü) gibi gerçekten tescilli olmayan protokoller ortaya çıktı. Bu protokoller herhangi bir sanayiciden bağımsız olarak geliştirildi ve bir üretim standardı haline geldi; birçok kişi ve sanayici bunların evrimine katkıda bulundu ve bu protokolleri benimsedi. Bu protokoller henüz gaz ve petrol piyasalarının operasyonel ve düzenleme talepleri için geniş bir çekiciliğe sahip olacak kadar önemli ölçüde gelişmemiş olsa da. Bu nedenle, gaz ve petrol dükkanları hala MODBUS değişkenlerine büyük yatırım yapıyor. Bu protokollerin müşteriler için daha belirgin olan faydaları var; Bunların daha kolay kabul göreceği ve özellikle gaz

ve petrol piyasaları için sağlanan normatif çözümlerin bir unsuru olacağı öngörülmektedir [145].



Şekil 2. 5. Geniş alan ağı SCADA

SCADA sistemleri, çalışma alanından veri toplamaya dayanır ve operatör bu sisteme iki gruba ayrılabilen çeşitli tekniklerle erişebilir:

1. HMI – İnsan Makine Arayüzü,
2. OIT – Operatör Arayüz Terminali.


OIT'ler, özellikle uzak yerlerde veya ayrı bir sistemle arayüz oluştururken yerel bir arayüz sağlar. Ekranlar, 4 inçten 14 inç kadar değişen büyük olmadıkları ve her yere yerleştirilebildikleri için verileri görüntülemek için basit bir tasarıma sahiptir. HMI yazılımı temel kontrol pozisyonunda kullanılır. Yazılım, daha yüksek performanslı işlemciler ve daha fazla veri sunan daha büyük ekranlara sahip bilgisayarlara kurulur. Ayrıca, operatörün dikkatini yoğunlaştırarak, bir alarmı duyurarak veya önemli operasyon yerlerinde hassas verileri onaylayarak animasyondan da faydalanırlar [149].

Genellikle, SCADA ana bilgisayar yazılımı, eğilimleri, grafiksel gösterimleri ve alarmları görüntüleme yeteneğine sahiptir. SCADA ana bilgisayarının kontrolü,

yalnızca uzak cihazlar için kontrol bileşenleri geliştiğinde mevcuttu. Bu sistemleri dış dünyadan ayırdılar ve mühendisler, teknisyenler ve operatörlerin alanı haline geldiler. Sorumlulukları SCADA bileşenlerini tasarlamak, işletmek ve bakımını yapmaktı. Bilgi Teknolojisi (BT) gelişti ve artık durum böyle değil. Birçok paydaş artık SCADA ana yazılımı tarafından sağlanan bilgilere gerçek zamanlı erişim gerektiriyor. Bakım yönetimi, muhasebe ve malzeme satın alma talepleri kısmen SCADA sisteminden üretilen veriler kullanılarak karşılanıyor.

Bu nedenle, SCADA ana bilgisayarının birden fazla istemciye ve operasyona veri sağlayan bir Kurumsal yapı olması yönünde bir talep vardır. Bu, SCADA ana bilgisayar yazılımının bu sistemlerle arayüzü kolaylaştırmak için standartları ve teknik özellikleri benimsemesini teşvik etmiştir. Bu, genellikle SCADA sistemlerinden izole edilen BT'nin ağları destekleme ve sürdürme, veritabanlarıyla arayüz oluşturma ve istemciye bilgilere erişim sağlama konusunda yer aldığını göstermektedir.

İlk SCADA ana bilgisayar ürünlerinin çoğu, SCADA sisteminin tipik olarak tek bir bina veya kompleks içinde kurulduğu ve coğrafi olarak dağıtılmış varlıklar için SCADA sistemlerinin telemetri iletişim özelliklerinin çoğundan yoksun olduğu endüstriyel ortam için özel olarak geliştirilmiştir [158].



Şekil 2. 6. SCADA ana bilgisayar platformu

Bu tür birinci nesil SCADA ana bilgisayarları, uzak cihazlarla iletişimi yönetmek için genellikle Ön Uç İşlemcisi (FEP) veya Ön Uç Sürücüsü (FED) olarak bilinen hibrit bir RTU veya PLC gerektirir. Bu, SCADA ana bilgisayar platformuyla harici iletişim gerektirdiği, bir iletişim darboğazı yarattığı ve özel programlama gerektirdiği için birkaç dezavantajla gerçekleştirildi. Birçok FEP veya FED cihazının bunlardan bazılarını işlemesine rağmen, özel mimarileri ve ek maliyetleri nedeniyle bunları oluşturmak ve sürdürmek zorlu oldu. Kapsamlı işlevsellik sunan modern SCADA yazılımları, başlangıçta iletişim için tasarlanmış olan bu tür hibrit PLC'lere artık ihtiyaç duymuyor. Artık SCADA ana bilgisayarının kendisine entegre edilmiş "sürücüler" adı verilen yazılım programlarını kullanıyorlar. Yazılım sürücüleri, PLC'ler ve RTU'lar gibi uzak cihazlara bağlanmak için çeşitli protokolleri kapsar.

Teknolojik gelişmenin bir sonucu olarak, SCADA ana bilgisayar yazılım platformları birçok yeni özelliğe sahip hale geldi. Bunlar, büyük sistemler için saniyede binlerce olayı işleyebilen ve aynı zamanda Veritabanları için Nesne Bağlantısı ve Gömme (OLE DB) ve Açık Veritabanı Bağlantısı (ODBC) gibi standart veritabanı arayüzlerini destekleyen, SCADA ana bilgisayar yazılım gereksinimleri için özel olarak tasarlanmış entegre veritabanlarının iyileştirilmesini kapsıyordu. Bu normlar bu amaç için gereklidir ve üçüncü taraf veritabanları SCADA ana bilgisayar yazılımında bulunan verilere erişebilir. SCADA ana bilgisayarına uzak kullanıcı erişimi, istemcilerin SCADA sistemlerini uzaktan, ya hareket halindeyken ya da diğer konumlarda çalıştırmasını ve gözlemlemesini sağlayan başka bir teknolojidir [145].

SCADA Sistemlerinde Kullanılan Ortak Sensörler veya Saha Enstrümanları.

Tasarlanan herhangi bir sistemde, bir şeyi kontrol etme ihtiyacı, o sistem içindeki bir şeyi ölçme ve durumunu belirleme ihtiyacını ifade eder ve bu bilgilere dayanarak bilinçli kararlar alınmasını sağlar. Buna göre, kontrolöre bağlı elektronik ölçüm ve izleme cihazları, geliştirilmiş ve daha güvenli bir kontrol sisteminin temel bileşenleridir. Buna karşılık, eski sistemler, vanalar ve pompalar manuel olarak kontrol ediliyordu. O zamanlar, operatör pompaları manuel olarak başlatır ve durdururdu ve vanalar manuel olarak açılıp kapatılırdı. Bazı durumlarda, bu cihazlar geri bildirim sağlayan seviye sensörleri, basınç sensörleri ve sıcaklık sensörleri gibi sensörlere

bağlanıyordu. Bunlar, verileri SCADA ana bilgisayar yazılımına iletmek için yerel bir RTU veya PLC'ye bağlanıyordu.

	Erken Enstrümantasyon	Geri Besleme Sensörleri	Aktüatör Ekleme
Avantaj	Kurulum maliyeti düşüktür	Merkezi izleme	Merkezi kontrol
Dezavantaj	İşletme maliyeti yüksektir	Hâlâ işletme maliyeti yüksek	Daha yüksek teknik gereksinimler

Şekil 2. 7. Enstrümantasyonun ilerlemesi

Günümüzün enstrüman teknisyeni, geçmişe kıyasla daha fazla teknik bilgiye ve ekipmanı modelleme, bakımını yapma ve kurma becerisine ihtiyaç duysa da, bu, otomatik süreçlerin daha düşük maliyeti ve personel tarafından tutulan geniş teknik personel ile hafifletilmektedir. Günümüzde, vanalar ve kapılar gibi saha mekanik cihazlarının çoğu, açılıp kapanmalarının kontrol edilmesini sağlayan aktüatörlerle donatılmıştır ve bu da geleneksel manuel operasyona güvenmek yerine bir PLC veya RTU'nun cihazı kontrol etmesine olanak tanır. Bu tür bir yetenek, kontrol sisteminin daha hızlı tepki vermesini, üretimi optimize etmesini ve kolaylaştırmasını veya olağandışı olaylar durumunda operasyonları durdurmasını sağlar.

Düzenleyici uyumluluk açısından, petrol ve gaz endüstrisi için cihazlar tehlikeli sınıf, grup ve bölüm gerekliliklerine uymak üzere halihazırda kurulmuştur. Gerekliklik, cihazın kurulduğu alan veya konum için tasarlanmış olmasıdır, örneğin, normal çalışma koşullarında veya bilinen anormal koşullarda patlayıcı buharların bulunduğu bir ortam.

Cihazın zorlu ortamlarda da çalışması gereken birçok durum vardır. Son derece soğuk ve sıcak koşullarda kullanım için tasarlanmış çeşitli cihaz türleri vardır. Cihaz bu koşullara hazır değilse, bir kabinin veya başka bir binanın içinde yapay bir ortam olması gerekli değildir. Bu, yalnızca ilk tasarım için değil, aynı zamanda devam eden bakım için de artan maliyetlerle sonuçlanır.

Cihaz ayrıca, ortamındaki ortam veya diğer elektrikli ekipman üzerinde herhangi bir istenmeyen etkiye sahip olmadığından emin olmak için geçerli EMC (Elektromanyetik Uyumluluk) standartlarına da uymalıdır [158]. Yukarıdakilere dayanarak, ayrı sinyaller üretebilen bazı cihaz türlerinden bahsedilecektir, örneğin [149].


2.1.2.4. SCADA Sistemlerinin Nesilleri

SCADA sistemi çok sayıda bileşenden oluşur ve SCADA sistemlerinin mimarisine bağlı olarak çeşitli tiplere ayrılırlar. Temel dört SCADA sistemi nesli şunlardır [180].

1. Birinci Nesil: Monolitik veya Erken SCADA sistemleri,
2. İkinci Nesil: Dağıtılmış SCADA sistemleri,
3. Üçüncü Nesil: Ağ bağlantılı SCADA sistemleri,
4. Dördüncü Nesil: Nesnelerin İnterneti teknolojisi, SCADA sistemleri.

Monolitik veya Erken SCADA Sistemleri

Daha önce SCADA sistemlerini işlemek için mini bilgisayarlar kullanılıyordu. Daha önceki zamanlarda, SCADA sistemlerinin ilk nesli sırasında, karşılıklı ağ hizmetlerinden yoksun monolitik sistemler yaratıldı. Bu nedenle, diğer sistemlerle bağlantısı olmayan serbest sistemlerdir.




Şekil 2. 8. Monolitik veya erken SCADA sistemleri

Tüm uzak terminal üniteleri, birincil merkezi sistemin arızalanması durumunda kullanılan SCADA sisteminin ilk yedeklemesini gerçekleştirmek için bir yedek merkezi sistemle iletişim kuracaktı. İlk nesilde, monolitik SCADA sistemlerinin görevleri sistemdeki sensörleri gözlemlemek ve programlanmış alarm ölçeklerini aşan herhangi bir işlemi bilgilendirmekle sınırlıydı [181].

Dağıtılmış SCADA Sistemleri

İkinci nesil SCADA sistemlerinde kontrol görevlerine katılım, bir Yerel Alan Ağı (LAN) üzerinden birbirine bağlı birden fazla sisteme dağıtılır. Bu nedenle, bunlara dağıtılmış SCADA sistemleri denir. Bu tek istasyonlar, gerçek zamanlı verilere ve talimatlara katılmak, olası sorunlar için alarm ölçeklerini izlemek üzere kontrol işlevlerini ele almak için kullanılırdı.


İstasyonu boyutu ve maliyeti, her ikinci nesil sistem, azaltılmış maliyet ve boyutla belirli bir işlevi yerine getirmek üzere tasarlandığından, birinci nesil sisteme kıyasla azaltıldı. Ancak, ağ protokolleri ikinci nesil sistemler arasında da birleştirilmedi. Geliştiricilere ek olarak, protokollerin tescilli olduğunun farkında olan bazı kişiler, SCADA kurulumunun güvenliğini veya emniyetini önceliklendirdi; ancak, SCADA kurulumunun güvenliği genellikle ihmal edildi [170].



Şekil 2. 9. Dağıtılmış SCADA sistemleri

Ağ Bağlantılı SCADA Sistemleri

Mevcut SCADA sistemlerinin çoğu, genellikle telefon hatları veya veri hatları aracılığıyla Geniş Alan Ağı (WAN) sistemleri kullanılarak iletişim kurulur ve ağ oluşturulur. Bu sistemlerde, verileri düğümler arasında tekrar tekrar taşımak için fiber optik bağlantılar veya Ethernet kullanılır. Programlanabilir mantık denetleyicileri (PLC'ler), rutini izlemek ve değiştirmek ve operatörleri yalnızca temel karar gereksinimleri karşılandığında bilgilendirmek için SCADA sistemlerinin oluşturulmasında kullanılır.




Şekil 2. 10. Ağ Bağlantılı SCADA sistemleri

Birinci ve ikinci nesil SCADA sistemlerini, tek bina ağları veya tek bir konumla sınırlı oldukları için kapalı sistemler olarak tanımladılar. Bu sistemlerde, ağ mimarisinde tek bir denetleyici altında birden fazla paralel, dağıtılmış SCADA sistemi varsa güvenlik riskleri yaratan internete bağlı üçüncü nesil SCADA sistemine kıyasla hiçbir tehlike yoktur [182].

Nesnelerin İnterneti

Ticari olarak mevcut bulut bilişimini de içeren Nesnelerin İnterneti teknolojisinin kullanılması, dördüncü nesil SCADA sistemlerinin altyapı maliyetlerini düşürmüştür. Dördüncü nesil SCADA sistemlerinin bakımı ve entegrasyonu diğer nesillere göre daha kolaydır [158].

Bulut bilişim tesisinden yatay ölçeğin kullanılması, bu SCADA sistemlerinin durumları gerçek zamanlı olarak bildirmesini sağlar ve klasik PLC'lerde yürütme için neredeyse yeterli olan daha karmaşık kontrol algoritmalarının yürütülmesine olanak tanır.



Şekil 2. 11. Nesnelerin İnterneti

Özel ağ protokollerinin heterojen bir kombinasyonu gibi merkezi olmayan SCADA yürütmeleriyle ilişkili güvenlik riskleri, yönetilebilir ve anlaşılır güvenlik sınırları sağlamak için Nesnelerin İnterneti'nde köklü olan TLS gibi açık ağ protokollerinin kullanılmasıyla azaltılabilir.

2.1.3. MATLAB ve GUI

2.1.3.1. MATLAB: Genel Bakış

MATLAB, MATrix LABoratory'nin kısaltmasıdır ve öncelikli olarak sayısal hesaplama, veri analizi, algoritma geliştirme ve görselleştirme için tasarlanmış üst düzey bir programlama dili ve ortamıdır. MATLAB, 1980'lerde Cleve Moler tarafından geliştirilmiştir ve başlangıçta daha karmaşık programlama dillerine ihtiyaç duymadan doğrusal cebir ve matris işlemlerine kolay erişim sağlamak için tasarlanmıştır. Zamanla, özellikle mühendislik, bilimsel araştırma ve veri analizi uygulamaları için akademik, endüstriyel ve araştırma ortamlarında en yaygın kullanılan araçlardan biri haline gelmiştir. MATLAB, veri analizi, görüntü ve sinyal işleme, kontrol sistemleri, kablosuz iletişim ve robotik dahil olmak üzere mühendislik ve bilimsel uygulamalar için kullanılan bir programlama ve sayısal hesaplama platformudur. MATLAB, bir programlama dili, etkileşimli uygulamalar, son derece uzmanlaşmış kütüphaneler ve otomatik kod oluşturma araçları içerir. MATLAB ayrıca karmaşık çok alanlı sistemleri simüle etmek için bir blok diyagram ortamı olan Simulink'in de temelidir. MATLAB ve SIMULINK, mühendislik ve bilim uygulamalarında araştırma ve geliştirme için birincil modelleme ve simülasyon araçları olarak kullanılır. Bu, havacılık, enerji, tıbbi cihazlar, telekomünikasyon, elektronik, finansal hizmetler, endüstriyel otomasyon, makine, yer ve okyanus bilimleri, biyoteknoloji ve ilaçlar dahil olmak üzere çok çeşitli endüstrileri ve uygulamaları kapsar. Matlab ve Simulink, çeşitli mühendislik sistemlerinin tasarımını, geliştirilmesini ve işletilmesini sağlar [183, 184].

2.1.3.2. MATLAB'ın Temel Özellikleri

Sayısal Hesaplama

MATLAB'ın temel gücü, karmaşık matematiksel hesaplamaları kolayca gerçekleştirme becerisinde yatar. Matris işlemleri, sayısal doğrusal cebir, diferansiyel denklemler ve optimizasyon için yerleşik destek içerir. Birçok programlama dilinin aksine, MATLAB'ın sözdizimi matrisler ve vektörlerle çalışmak için optimize

edilmiştir ve bu da onu mühendislik ve bilimsel uygulamalar için özellikle güçlü hale getirir [185].

Araç Kutuları

MATLAB, çeşitli alanlarda işlevselliğini artıran çok çeşitli özel araç kutuları sunar.

En popüler araç kutularından bazıları şunlardır [85]:

1. Kontrol Sistemleri Araç Kutusu: Kontrol sistemlerini tasarlamak ve analiz etmek için,
 2. Sinyal İşleme Araç Kutusu: Sinyalleri analiz etmek, işlemek ve görselleştirmek için,
 3. İstatistik ve Makine Öğrenimi Araç Kutusu: Veri kümelerine makine öğrenimi algoritmaları ve istatistiksel yöntemler uygulamak için,
 4. Simulink: Çok alanlı dinamik sistemleri modellemek ve simüle etmek için MATLAB tabanlı bir ortam.
3. Görselleştirme: MATLAB, 2B ve 3B çizimler, grafikler ve etkileşimli şekiller aracılığıyla verileri görselleştirmede mükemmeldir. Dahili çizim işlevleri, karmaşık simülasyonların veya deneylerin sonuçlarını analiz etmek için gerekli olan görselleştirmelerin hızlı bir şekilde oluşturulmasını sağlar.

Programlama

MATLAB, özel algoritmaların ve uygulamaların geliştirilmesini destekler. Karmaşık işlemlerin kodlanmasını basitleştiren üst düzey işlevlere sahip, okunması kolay bir programlama diline sahiptir. Ek olarak, kullanıcılar gerçek zamanlı olarak süreçleri kontrol etmek ve izlemek için komut dosyaları, işlevler ve hatta tam grafiksel kullanıcı arayüzleri (GUI'ler) oluşturabilir.

Harici Sistemlerle Arayüzleme

MATLAB, çeşitli araçlar aracılığıyla harici donanım ve yazılım sistemleriyle arayüzleme yeteneğine sahiptir. Örneğin, gerçek zamanlı veri toplama için sensörlere veya veri toplama sistemlerine bağlanabilir veya C, Python ve Java gibi diğer programlama dilleriyle etkileşime girebilir.

Simulink

Bir MATLAB eklenti ürünü olan Simulink, dinamik sistemleri modellemek, simüle etmek ve analiz etmek için yaygın olarak kullanılır. Özellikle kontrol sistemleri, sinyal işleme ve iletişim sistemi tasarımında oldukça kullanışlı olan, denklem sistemlerini temsil eden blok diyagramlarının oluşturulmasına yönelik grafiksel bir arayüz sunmaktadır.

2.1.3.3. MATLAB Uygulamaları

MATLAB, [186] ile sınırlı olmamak üzere çok çeşitli alanlarda uygulanır:

1. Kontrol Sistemleri: MATLAB, havacılık, otomotiv, robotik ve proses mühendisliği gibi alanlarda kontrol sistemlerinin tasarımı, simülasyonu ve analizinde yoğun olarak kullanılır. Kontrol Sistemleri Araç Kutusu ve Simulink, sistem dinamiklerinin modellenmesine, kararlılık analizine ve denetleyici tasarımına olanak tanır,
2. Sinyal İşleme: MATLAB'deki Sinyal İşleme Araç Kutusu, ses, konuşma ve görüntü gibi sinyalleri analiz etmek ve işlemek için kullanılır. Genellikle telekomünikasyon, tıbbi görüntüleme ve ses işlemede uygulanır,
3. Makine Öğrenimi ve Veri Analizi: MATLAB, veri ön işleme, model eğitimi ve doğrulama için araçlar sağlayarak makine öğrenimi iş akışlarını destekler. Hem akademik araştırmalarda hem de veri analizi ve desen tanıma görevleri için endüstri uygulamalarında yaygın olarak kullanılır,
4. Finans: MATLAB'ın finansal araç kutusu, finansal verileri analiz etme, portföyleri modelleme ve fiyatlandırma seçenekleri için işlevler sağlar. Genellikle nicel finans ve risk yönetiminde kullanılır.

5. Akademik Araştırma: Araştırma ortamlarında MATLAB, çok yönlülüğü ve fizik, biyoloji ve kimya gibi çeşitli bilimsel disiplinler için özel araç kutularının kullanılabilirliği nedeniyle tercih edilen bir araçtır. Araştırmacılar MATLAB'ı deneyleri simüle etmek, verileri işlemek ve görselleştirmeler oluşturmak için kullanırlar,
6. Gömülü Sistemler: Gerçek zamanlı sistemler ve gömülü donanım desteğiyle MATLAB, genellikle gömülü cihazlar için algoritmalar tasarlamak için kullanılır. MATLAB Kodlayıcı, C ve C++ kodu üreterek algoritmaların donanım sistemlerine sorunsuz bir şekilde entegre edilmesini sağlar.

2.1.3.4. Avantajlar ve Sınırlamalar

Avantajlar:

1. Kullanım Kolaylığı: MATLAB'ın sezgisel sözdizimi ve etkileşimli ortamı, hem acemi hem de uzman kullanıcılar için erişilebilir hale getirir,
2. Kapsamlı Dokümantasyon: MATLAB kapsamlı dokümantasyon, eğitimler ve aktif bir kullanıcı topluluğu sunarak öğrenmeyi ve uygulamayı kolaylaştırır,
3. Diğer Dillerle Entegrasyon: MATLAB, C, C++, Python ve Java gibi dillerle sorunsuz bir şekilde entegre olur, işbirliğini ve MATLAB'ın mevcut yazılım sistemleriyle entegrasyonunu kolaylaştırır,
4. Kapsamlı Araç Kutuları: Çok çeşitli uzmanlaşmış araç kutuları, MATLAB'ın hemen hemen her bilimsel veya mühendislik disiplinine uygulanabilmesini sağlar.

Sınırlamalar:

1. Performans: MATLAB güçlü olsa da, hesaplama açısından yoğun görevler için C veya C++ gibi düşük seviyeli dillerden daha yavaş olabilir. Ancak, MATLAB'ın MATLAB Coder ile C/C++ kodu üretme yeteneği, bazı durumlarda bu sınırlamayı hafifletmeye yardımcı olur,

2. Maliyet: MATLAB, bazı kullanıcılar veya kurumlar için aşırı pahalı olabilen ticari bir üründür. Öğrenci sürümleri olmasına rağmen, tam özellikli profesyonel sürüm maliyetli olabilir.

MATLAB, sayısal hesaplama, veri analizi ve simülasyon için lider bir araç olarak konumunu sağlamlaştırmıştır. Çok yönlülüğü, kullanım kolaylığı ve kapsamlı araç kutuları onu mühendislik, bilim ve endüstrideki profesyoneller için başvurulacak bir çözüm haline getirir. Özellikle hesaplama açısından yoğun görevler için performans açısından belirli sınırlamalar olsa da MATLAB karmaşık sorunları çözmek ve çeşitli alanlarda çözümler geliştirmek için vazgeçilmez bir araç olmaya devam etmektedir [187, 188].

2.1.3.5. Grafiksel Kullanıcı Arayüzü (GUI)

Grafiksel kullanıcı arayüzü veya GUI, kullanıcıların menüler, düğmeler ve hareketler gibi grafiksel semboller ve görsel göstergeler aracılığıyla elektronik cihazlarla etkileşime girmesine olanak tanıyan kullanıcı tarafından tasarlanmış bir arayüz biçimidir. Endüstriyel ortamlar dahil olmak üzere birçok uygulamada, yazılı komut etiketlerine veya metin gezintisine dayanan metin tabanlı bir kullanıcı arayüzü yerine grafiksel kullanıcı arayüzü (GUI) kullanılır. GUI, bir bilgisayar klavyesinde komut yazmayı gerektiren komut satırı arayüzlerinin (CLI'ler) [189-191] algılanan dik öğrenme eğrisine yanıt olarak tanıtıldı. GUI'lerdeki eylemler genellikle grafiksel öğelerin doğrudan işlenmesi yoluyla gerçekleştirilir [192-194]. Bilgisayarların ötesinde, GUI'ler MP3 çalarlar, taşınabilir medya oynatıcılar, oyun cihazları, akıllı telefonlar ve daha küçük ev ve endüstriyel kontroller dahil olmak üzere çeşitli taşınabilir cihazlarda kullanılır. GUI terimi, video oyunları (baş üstü ekranların (HUD'ler) tercih edildiği [195]) gibi diğer düşük çözünürlüklü arayüz türlerine uygulanma eğiliminde değildir veya hacimsel ekranlar [196] gibi düz ekranları içermez çünkü terim, bilgisayar duyuşal bilimi geleneğinde genel bilgileri tanımlayabilen 2B ekranların aralığıyla sınırlıdır.

2.1.3.6. Grafiksel Kullanıcı Arayüzü ve Etkileşim Tasarımı

Grafiksel kullanıcı arayüzü (GUI), bir bilgisayar ekranında sunulur (görüntülenir). İşlenmiş kullanıcı girdisinin sonucudur ve genellikle insan-makine etkileşimi için birincil arayüz görevi görür. Dokunmatik ekranlı kullanıcı arayüzü, küçük mobil cihazlarda yaygındır ve görsel çıktının görsel girdi üzerine bindirilmesidir. Grafiksel kullanıcı arayüzünün (GUI) görsel yapılandırmasının ve zamansal davranışının tasarımı, insan-bilgisayar etkileşimi alanında yazılım uygulama programlamasının önemli bir yönüdür. Amacı, depolanan bir programın altında yatan mantıksal tasarımın verimliliğini ve kullanılabilirliğini artırmaktır; bu, kullanılabilirlik adı verilen bir tasarım disiplini. Kullanıcı merkezli tasarım yöntemleri, tasarımda sunulan görsel dilin görevlere iyi uyarlanmış olmasını sağlamak için kullanılır. Bir uygulamanın görsel GUI özellikleri bazen renk veya grafik kullanıcı arayüzü olarak adlandırılır [197-199].

Kullanıcılar genellikle sahip oldukları veri türüne uygun etkileşimlere izin veren görsel kullanıcı arayüzü öğelerini işleyerek bilgiyle etkileşim kurarlar. İyi tasarlanmış arayüz öğeleri, kullanıcıların hedeflerine ulaşmak için gerekli eylemleri desteklemek üzere seçilir. Model-görünüm-denetleyici (MVC), arayüzün uygulamanın işlevselliğinden bağımsız olduğu ve dolaylı olarak ilişkili olduğu esnek yapılara izin verir ve GUI'yi özelleştirmeyi kolaylaştırır. Bu, kullanıcıların istedikleri zaman farklı bir görünüm veya tema seçmelerine veya tasarımlarına olanak tanır ve tasarımcıyı kullanıcı ihtiyaçları geliştikçe arayüzü değiştirme işinden kurtarır. İyi GUI tasarımı daha kullanıcı merkezli ve daha az sistem merkezlidir. Windows gibi daha büyük araçlar genellikle bir web sayfası, e-posta mesajı veya grafik gibi ana sunum içeriği için bir çerçeve veya kapsayıcı sağlar. Daha küçük olanlar genellikle kullanıcı giriş aracı olarak hizmet eder.


Bir GUI, bir uygulamanın GUI'si olarak dikey pazar gereksinimleri için tasarlanabilir. Örnekler arasında otomatik vezne makineleri (ATM'ler), restoranlardaki Satış Noktası (POS) ekranları [200] perakende mağazalarında kullanılan self servis ödeme noktaları, havayolu self-bilet ve check-in iletişimleri ve bir tren istasyonu veya müze gibi halka açık bir alanda bilgi ağları ve endüstriyel gömülü bir sistemde (RTOS) monitörler veya kontrol ekranları yer alır.

Cep telefonları ve elde taşınabilir oyun sistemleri de belirli dokunmatik ekran uygulamaları kullanır. Modern otomobiller, navigasyon sistemlerinde ve multimedya merkezlerinde veya bu sistemlerle birlikte grafiksel kullanıcı arayüzleri (GUI'ler) kullanır.

Bir GUI, kullanıcıların bilgi toplama ve üretme gibi görevler için etkileşim kurmasını sağlayan bir platform sağlamak için teknolojilerin ve cihazların bir kombinasyonunu kullanır. Görsel bir dile uyan bir dizi öge, bilgisayarlarda depolanan bilgileri temsil etmek üzere gelişmiştir. Bu, az bilgisayar becerisine sahip kişilerin bilgisayar yazılımlarıyla çalışmasını ve bunları kullanmasını kolaylaştırır. Bu tür öğelerin GUI'lerde en yaygın kombinasyonu, özellikle kişisel bilgisayarlarda Windows, Simgeler, Metin Alanları, Tuvaller, Menüler, İşaretçi (WIMP) paradigmasıdır [201].

WIMP etkileşim stili, bir işaretleme aygıtının arayüzünün konumunu temsil etmek için sanal bir giriş aygıtı kullanır, çoğunlukla bir fare ve bilgileri simgelerle temsil edilen pencerelerde düzenler. Mevcut komutlar menülerde bir araya getirilir ve eylemler işaretleme aygıtıyla hareketler yapılarak gerçekleştirilir. Bir pencere yöneticisi, pencereler, uygulamalar ve pencereleme sistemi arasındaki etkileşimleri kolaylaştırır. Pencereleme sistemi, işaretleme aygıtları, grafik donanımı ve işaretçinin konumlandırılması dahil olmak üzere donanım aygıtlarını yönetir.


Kişisel bilgisayarlarda, tüm bu öğeler, ekranın bir masaüstünü temsil ettiği ve üzerine belgelerin ve klasörlerin yerleştirilebileceği bir masaüstü ortamı adı verilen bir simülasyon üretmek için bir masaüstü metaforu aracılığıyla modellenir. Pencere yöneticileri ve diğer yazılımlar, masaüstü ortamını çeşitli gerçekçilik dereceleriyle simüle etmek için bir araya gelir. Girişler, metin ve ayrıntılar için yer açmak üzere bir listede veya daha büyük simgeler ve metin için altta minimum alanla kompaktlık için bir ızgarada görünebilir. Birden fazla sütunlu öğelerden oluşan bir liste ve metin satırlarının simgeden yanlara doğru uzandığı bir öge ızgarası gibi varyasyonlar mevcuttur [202].



Şekil 2. 12. Grafiksel kullanıcı arayüzünün katmanlarının şeması [203].

2.1.4. İşlem Birimi

Raspberry Pi 5, Raspberry Pi ailesinin en son ve en popüler üyesi olan dört çekirdekli bir mini bilgisayardır ve küçük boyut, yüksek performans ve masaüstü bilgisayarın gücü ve performansına sahiptir.



Şekil 2. 13. Raspberry Pi 5 İşlem Birimi

Raspberry Pi işlemcisinin yeni nesli, Raspberry Pi 4'ün verileri kontrol etme ve yönetme ve yapay zeka algoritmalarıyla başa çıkma konusundaki büyük başarısı üzerine inşa edilmiştir. Raspberry Pi işlemcisinin beşinci nesli, 2,4 GHz'de çalışan 64 bit dört çekirdekli Arm Cortex-A76 işlemciye ek olarak kamera ve ekran giriş/çıkışı ile USB iletişimde iyileştirmeler içeren bir dizi iyileştirmeye sahiptir (toplam USB bant genişliği iki katından fazla artırılmıştır). Raspberry Pi 5, daha akıcı bir masaüstü deneyimi ve gelişmiş performans sunarak endüstriyel müşteriler için yeni uygulamalara olanak tanır. Raspberry Pi 5, Raspberry Pi 4'e kıyasla CPU performansında 2-3 kat artışın yanı sıra 800MHz VideoCore VII GPU'dan gelen grafik performansında önemli bir iyileştirme sağlıyor. Diğer iyileştirmeler arasında kamera G/Ç, ekran ve USB arayüzünde iyileştirmeler yer alıyor ve Toplam USB bant genişliği iki katından fazla artırıldı. Raspberry Pi 5, daha akıcı bir masaüstü deneyimi ve gelişmiş performans sunarak endüstriyel müşteriler için yeni uygulamalara olanak tanıyor.

Bu arayüz iyileştirmeleri, Raspberry Pi'de şirket içinde tasarlanan RP1 G/Ç denetleyici çipi tarafından sağlanıyor. Raspberry Pi silikonu ilk kez bir amiral gemisi ürününde yer alıyor! Raspberry Pi 5, LPDDR4X-4267 SDRAM, Gigabit Ethernet, PoE+ desteği,

USB 3.0, kablosuz 0, Bluetooth 5.0 ve daha fazlasına sahip, 2 x 4 K monitöre kadar çalıştırabilen dört çekirdekli bir bilgisayardır. Masaüstü bilgisayarlarda tipik olarak bulunan tüm özelliklere ve ham performansa sahiptir. Raspberry Pi 5 şu anda hem 4 GB hem de 8 GB versiyonlarında mevcuttur. İlk kez, Pi artık kendi yerleşik açma/kapama anahtarına sahip.

Yeni Pi, tüm yetenek seviyeleri için mükemmel kodlama ortamı sunar ve çeşitli projeler için çok sayıda çevrimiçi kılavuz mevcuttur. Wi-Fi, USB 2.0/3.0, Gigabit Ethernet ve Bluetooth dahil olmak üzere yerleşik bağlantı, isteyebileceğiniz tüm ağ seçeneklerini sağlar. 40 pimli GPIO konektörleri, kartı HAT'ler aracılığıyla genişletmenizi ve çok çeşitli ek cihazları bağlamanızı sağlar [204].

Raspberry Pi 5, kodlama, Linux, IoT sistemleri, medya akışı, oyun, otomatik ev ve endüstriyel uygulamalar ve diğer birçok kullanım arasında eksiksiz bir masaüstü çözümü dahil olmak üzere öğrenme ve öğretme için mükemmel bir platform sunarak eğitim için %100 hazırdır [205].

1. Güç Dağıtımı desteğine sahip bir USB-C,
2. GPIO: Raspberry Pi standart 40 pimli başlık (Geriye dönük uyumlu),
3. RTC: Harici bir pille çalışan Gerçek Zamanlı Saat (RTC),
4. Açma/Kapatma Anahtarı: Yerleşik güç düğmesi.

İçerikler:

- 1 x Raspberry Pi 5 (4 GB veya 8 GB).

Pi 5 Aşağıdaki Sürümlerde Mevcuttur:

1. Raspberry Pi 5 4 GB - SKU: 5047,
2. Raspberry Pi 5 8 GB - SKU: 5048.

Olası Uygulamalar Şunlardır [206]:

1. Medya akışı (Müzik, Video, Twitch),
2. Kodlama öğrenme/öğretme,
3. IoT öğrenme/öğretme,
4. Linux öğrenme/öğretme,
5. Bir PC ile rekabet edebilecek bir ev masaüstü bilgisayar çözümü,
6. Retro oyunları çalıştırma ve konsol emülasyonu dahil oyun oynama,
7. Sunucu,
8. NAS.

2.1.5. Hidroelektrik Santrallerinde Kullanılan Saha Ekipmanları

2.1.5.1. Genel Bileşenler

Limit Anahtarları

Limit anahtarı, bir makine bileşeninin hareketi veya bir nesnenin varlığıyla çalıştırılan bir anahtardır. Bir kontrol sistemi içindeki makineleri kontrol etmek, bir güvenlik kilidi olarak veya hatta gerçek bir noktadan geçen nesneleri saymak için kullanılırlar. Bir limit anahtarı, iki kontakla mekanik olarak ilişkilendirilmiş bir aktüatör içeren bir elektromekanik cihaz olabilir. Bir nesne aktüatörle bağlantı kurduğunda, bu cihazlar bir güç bağlantısı oluşturmak veya kesmek için kontakları çalıştırır. Çeşitli ortamların ve uygulamaların sağlamlığı nedeniyle, kurulum prosedürünü kolay ve güvenilir hale getiren limit anahtarları kullanılır. Bir nesnenin yokluğunu veya varlığını, hareketini, konumunu ve seyahat sonunu belirleyebilirler.

Bir lamba veya solenoid valf gibi son bir çalışma cihazının doğrudan bir endüstriyel limit anahtarının kontakları tarafından kontrol edilmesi nadirdir. Yine de, daha tipik olarak, limit anahtarı bir kontrol rölesi, bir motor kontak kontrol devresi veya programlanabilir bir mantık denetleyicisine giriş olarak bağlanır. Bunlar öncelikle bir nesnenin yolculuğunun sınırını tanımlamak için kullanıldı ve buna bağlı olarak "Limit Anahtarı" adı ortaya çıktı [159].



Şekil 2. 14. Limit anahtarları

Basmalı Düğme

Bir basmalı düğme (basmalı düğme olarak da bilinir) veya basitçe bir düğme, bir cihazın veya işlemin bazı yönlerini kontrol etmek için kullanılan basit bir anahtarlama mekanizmasıdır. Düğmeler genellikle plastik veya metal gibi katı malzemelerden yapılır. Yüzey genellikle düz veya insan parmağına veya eline uyacak şekilde şekillendirilmiştir ve bu sayede kolayca basılabilir veya itilebilir. Düğmeler genellikle önyargılı anahtarlardır, ancak birçok önyargsız düğme, fiziksel yapıları nedeniyle basılmamış durumlarına geri dönmek için yine de bir yay gerektirir. "Basmalı düğme" hesap makinelerinde, ankesörlü telefonlarda, mutfak aletlerinde ve hem ev hem de ticari birçok mekanik ve elektronik cihazda kullanılmıştır.

Endüstriyel ve ticari uygulamalarda, basmalı düğmeler mekanik bir bağlantı ile birbirine bağlanabilir ve bir düğmeye basma eyleminin diğerini serbest bırakmasına izin verir. Bu şekilde, bir durdurma düğmesi başlatma düğmesinin çalışmasını "zorlayabilir". Bu bağlantı yöntemi, cihazın veya işlemin elektrik kontrol devresine sahip olmadığı basit manuel işlemlerde kullanılır. Basmalı düğmeler ayrıca, kullanım kolaylığı ve makinenin kapatılmasını kolaylaştırmak için mantar kafalar olarak bilinen büyük başlıklara sahip olabilir. Bu basmalı düğmelere acil durdurma düğmeleri denir ve artırılmış güvenlik için birçok yargı bölgesinde elektrik kodları tarafından zorunlu

tutulur. Bu büyük mantar şekli, işlerinde eldiven giymeleri gereken ve normal bir gömme basmalı düğmeyi çalıştıramayan operatörler tarafından kullanılan basmalı düğmelerde de bulunabilir.

Endüstriyel veya ticari uygulamalarda operatörlere ve kullanıcılara yardımcı olmak için, genellikle kullanıcının dikkatini çekmek ve düğmeye basıldığında geri bildirim sağlamak için bir pilot ışık eklenir. Bu ışık genellikle basmalı düğmenin ortasında bulunur ve sabit merkez diskin yerini bir mercek alır. Işığı aydınlatmak için güç kaynağı doğrudan basmalı düğmenin arkasındaki kontaklara değil, basmalı düğmeyi kontrol eden eyleme bağlıdır. Bu şekilde, başlat düğmesi basıldığında işlemi veya makineyi başlatır ve işleme veya operasyona entegre edilmiş ikincil bir kontak, basmalı düğme eyleminin ortaya çıkan işlemi veya eylemi tetiklediğini gösteren pilot ışığı etkinleştirir.

Operatörün yanlışlıkla yanlış düğmeye basmasını önlemek için, basmalı düğmeler genellikle işlevleriyle ilişkilendirilecek şekilde kodlanır. Genellikle kullanılan renkler, bir cihazı veya işlemi durdurmak için kırmızı ve bir cihazı veya işlemi başlatmak için yeşildir. Popüler kültürde, "Düğme" ifadesi (bazen büyük harfle yazılır) bir askeri veya hükümet liderinin nükleer silahları fırlatmak için basabileceği (genellikle kurgusal) bir düğmeye atıfta bulunur [160].



Şekil 2. 15. Basmalı düğmeler

Şamandıra Anahtarları

Şamandıra anahtarı, bir kabın içindeki sıvı miktarını belirlemek için kullanılan bir cihaz olan bir seviye sensörü türüdür. Anahtar, bir pompayı kontrol etmenizi sağlar, bir gösterge görevi görür, bir alarm işlevi görür veya diğer aletleri kontrol eder. Bir tür şamandıra anahtarı, menteşeli şamandırada bir cıva anahtarı kullanır [161].



Şekil 2. 16. Şamandıra anahtarı

Röle Konağı

Röleler, devreleri elektronik veya elektromekanik olarak açıp kapatan anahtarlardır. Röleler, farklı devrelerdeki kontakları açıp kapatarak tek bir elektrik devresini kontrol eder. Bir röle konağı normalde açık (NO) olduğunda, röle aktif olmadığında bile açık kalabilir. Bir röle konağı Normalde Kapalı (NC) olduğunda, röle aktif olmadığında kapalı bir durumda bulunur. Bu durumlarda, kontaklara elektrik akımı uygulanması, durumlarının yerine geçecektir. Röleler genellikle bir kontrol devresindeki küçük akımları anahtarlamak için kullanılır ve genellikle düşük amper çeken küçük motorlar ve Solenoidler dışında güç tüketen cihazları kontrol etmezler.

Bununla birlikte, röleler, bir röle bobinine uygulanan küçük bir voltaj, kontaklar tarafından anahtarlendiğinde önemli bir voltaj üretebildiğinden, yükseltici bir etkiye sahip olarak daha büyük amperleri ve voltajları kontrol edebilir. Koruyucu röleler, aşırı yükler, ters akımlar, aşırı akımlar ve düşük akımlar dahil olmak üzere elektriksel

anormallikleri tespit ederek ekipmanı hasardan koruyabilir. Sadece bunlar değil, röleler ayrıca marş bobinlerini, sesli alarmları, pilot ışıklarını ve ısıtma elemanlarını anahtarlama için de yaygın olarak kullanılmaktadır [162].



Şekil 2. 17. Relay contact

Seçici Anahtarlar

Seçici Anahtar, panelin önünde basit bir seçici anahtar ve muhafazanın içinde geniş bir potansiyel temas kombinasyonu (temas blokları aracılığıyla) içeren genel bir ilkeye göre çalışır. Basmalı düğme ile seçici anahtar arasındaki temel fark, basmalı düğmenin her iki temas pistonunu aynı anda aşağı iten bir plakası varken, seçici anahtarın sırtları ve düz yüzeyleri olan dönen bir kamı olması ve bunların bağımsız olarak çalışmasına izin vermesidir [163].



Şekil 2. 18. Seçici anahtar


Öte yandan, sinyal türlerine göre, SCADA sistemlerinin işlemek üzere tasarlandığı analog sinyaller üreten ekipmanlar vardır. Örneğin, sıcaklık sensörleri, basınç sensörleri ve Seviye sensörleri, vb.

2.1.5.2. Mekanik ve Hidrolik İzleme

Akış Sensörleri

Akış sensörleri, akış ölçerler olarak da bilinir, türbinlerden geçen su akış hızını ölçmek için hidroelektrik santrallerinde olmazsa olmaz araçlardır. Doğru akış ölçümü, türbin performansını optimize etmek, operasyonel verimliliği sağlamak ve olası mekanik arızaları önlemek için çok önemlidir.

Türbin Akış Ölçerler: Bu ölçerler, akışkan akış yoluna yerleştirilmiş mekanik bir rotor kullanır. Su türbinden geçerken rotorun dönmesine neden olur. Rotorun dönüş hızı, su akışının hızıyla doğru orantılıdır ve bu da hassas ölçüm sağlar. Türbin akış ölçerler, hidroelektrik santralleri de dahil olmak üzere çeşitli endüstriyel uygulamalarda yüksek doğrulukları ve güvenilirlikleri nedeniyle değerlidir [164].



Şekil 2. 19. Akış Sensörü

Hidroelektrik Türbinlerinde Kullanılan Akış Sensörü Türleri:

1. Türbin Akış Ölçerler: Bu ölçerler, akışkan akışına dik açılarda monte edilmiş çok kanatlı bir rotordan oluşur. Su geçerken, rotorun dönmesine neden olur ve dönüş hızı suyun hızıyla doğru orantılıdır. Bu, hacimsel akış hızının hassas bir şekilde ölçülmesini sağlar. Türbin akış ölçerler, hidroelektrik santralleri de dahil olmak üzere çeşitli endüstriyel uygulamalarda yüksek doğrulukları ve güvenilirlikleri nedeniyle değerlidir,
2. Ultrasonik Akış Ölçerler: Ultrasonik sinyalleri kullanan bu ölçerler, ultrasonik darbelerin akışkanı hem yukarı hem de aşağı yönde geçmesi için gereken süreyi ölçerek akış hızını belirler. Geçiş sürelerindeki fark, akış hızını hesaplamak için kullanılır. Ultrasonik akış ölçerler müdahaleci değildir ve borulara harici olarak monte edilebilir, bu da olası bakım sorunlarını azaltır,
3. Elektromanyetik Akış Ölçerler: Faraday'ın Elektromanyetik İndüksiyon Yasası'na dayanan bu ölçerler, iletken bir sıvının manyetik alandan geçmesiyle oluşan voltajı algılayarak akış hızını ölçer. Özellikle su akışını ölçmek için etkilidirler ve çeşitli endüstriyel uygulamalarda yaygın olarak kullanılırlar.

Uygulamalar ve Önem:

Hidroelektrik santrallerinde, türbinlerden geçen su akışının izlenmesi birkaç nedenden dolayı hayati önem taşır:

1. İşletme Verimliliği: Hassas akış ölçümleri, operatörlerin optimum performansı korumak için türbin ayarlarını ayarlamasını, elektrik üretimini en üst düzeye çıkarırken aşınma ve yıpranmayı en aza indirmesini sağlar,
2. Önleyici Bakım: Akış hızlarını sürekli izleyerek, anormallikler erken tespit edilebilir, bu da proaktif bakıma olanak tanır ve beklenmeyen türbin arızaları riskini azaltır,
3. Güvenlik: Doğru akış verileri, türbinlerin güvenli parametreler dahilinde çalışmasını sağlayarak hem ekipmanı hem de personeli korur.

Seviye Sensörleri.

Su seviyesi sensörleri, özellikle barajlarla ilişkili olanlar olmak üzere hidroelektrik santrallerinde, optimum enerji üretimi ve yapısal güvenliği sağlamak için su seviyelerini izleyip düzenledikleri için temel bileşenlerdir. Doğru su seviyesi ölçümleri, verimli türbin çalışması ve olası su baskınlarını veya yapısal hasarı önlemek için çok önemlidir [166].



Şekil 2. 20. Su Seviye Sensörleri

Hidroelektrik Santrallerindeki Su Seviyesi Sensörlerinin Türleri:

1. Ultrasonik Seviye Sensörleri: Bu sensörler, sensör ile su yüzeyi arasındaki mesafeyi ölçmek için ultrasonik dalgalar kullanır. Ultrasonik darbenin su yüzeyine gidip geri dönmesi için geçen süreyi hesaplayarak sensör su seviyesini belirler. Ultrasonik sensörler temassız cihazlardır ve bu nedenle su ile doğrudan temas olmadan rezervuarlarda ve su alma yapılarında su seviyelerini ölçmek için uygundur,
2. Basınç Dönüştürücüler: Basınca dayalı sensörler, sensörün üzerindeki su sütunu tarafından uygulanan hidrostatik basıncı ölçer. Ölçülen basınç doğrudan su

seviyesiyle ilişkilendirilir ve hassas izleme sağlar. Bu sensörler genellikle rezervuarların veya su kanallarının dibine yerleştirilir.

3. Radar Seviye Sensörleri: Mikrodalga radar teknolojisiyle çalışan bu sensörler, su yüzeyine doğru radar dalgaları yayar ve dalgaların geri dönmesi için geçen süreyi ölçer. Radar sensörleri son derece doğrudur ve çeşitli çevre koşullarında çalışabilir, bu nedenle büyük rezervuarlar ve baraj uygulamaları için uygundurlar,
4. Şamandıra Tabanlı Sensörler: Bu sensörler, mekanik veya elektronik bir göstergeye bağlı yüzen bir cihaz kullanır. Su seviyesi değiştikçe, şamandıra buna uygun şekilde hareket ederek su seviyesinin doğrudan ölçülmesini sağlar. Tasarım olarak basit olsalar da, şamandıra tabanlı sensörler güvenilirdir ve genellikle daha küçük ölçekli uygulamalarda kullanılır.

Uygulamalar ve Önem:

1. Rezervuar Yönetimi: Rezervuarlardaki su seviyelerinin izlenmesi, barajda taşma veya yapısal stresi önlemek için güvenli depolama sınırlarını korurken enerji üretimi için yeterli su olduğundan emin olur,
2. Türbin Verimliliği: Verimli türbin çalışması için optimum su seviyelerinin korunması çok önemlidir. Uygun su seviyeleri, türbinlerin tasarlanmış parametreleri dahilinde çalışmasını, enerji çıkışını en üst düzeye çıkarmasını ve aşınma ve yıpranmayı azaltmasını sağlar,
3. Taşkın Kontrolü: Doğru su seviyesi izleme, operatörlerin su tahliye programlarını ayarlayarak olası taşkın olaylarını tahmin etmelerini ve yönetmelerini sağlar, böylece aşağı akıştaki toplulukları ve ekosistemleri korur,
4. Çevresel Uyumluluk: Sürekli su seviyesi izleme, su seviyelerinin sulak alanları korumak ve ekolojik dengeyi korumak için yönetilmesini sağlayarak hidroelektrik santrallerinin çevre düzenlemelerine uymasına yardımcı olur.

Hidroelektrik santrali operasyonlarına güvenilir su seviyesi sensörlerinin dahil edilmesi, enerji üretimini optimize etmek, yapısal bütünlüğü sağlamak ve çevre ve insan sağlığını korumak için önemlidir.

Sıcaklık Sensörleri.

Sıcaklık sensörleri, ekipmanın optimum performansını, güvenliğini ve uzun ömürlülüğünü sağlamak için kritik sıcaklıkları izledikleri için hidroelektrik santrallerinde, özellikle türbin sistemlerinde hayati bileşenlerdir. Doğru sıcaklık izleme, anormalliklerin erken tespitini sağlar, önleyici bakımı kolaylaştırır ve olası arızaları önler.

Hidroelektrik santrallerinde, türbin bileşenlerinin hassas sıcaklık izlemesi, operasyonel verimliliği korumak ve güvenliği sağlamak için çok önemlidir. Sıcaklık sensörlerini Programlanabilir Mantık Denetleyicileri (PLC'ler) ile entegre etmek, gerçek zamanlı veri toplamayı geliştirir ve otomatik kontrolü kolaylaştırır [167].



Şekil 2. 21. Sıcaklık Sensörleri

Hidroelektrik Türbinlerinde Kullanılan Sıcaklık Sensörlerinin Türleri:

1. Direnç Sıcaklık Dedektörleri (RTD'ler): Sıcaklık değişimleriyle metallerin elektriksel direncindeki öngörülebilir değişimi kullanır, yüksek doğruluk ve kararlılık sunar,
2. Termokupllar: Bir uçtan birleştirilmiş iki farklı metalden oluşur, sıcaklık farklarıyla ilişkili bir voltaj üretir, geniş bir sıcaklık aralığı için uygundur,

3. Termistörler: Sıcaklık dalgalanmalarına yanıt olarak önemli direnç değışiklikleri gösteren sıcaklığa duyarlı dirençler, bu da onları belirli sıcaklık aralıklarında hassas ölçümler için ideal hale getirir.

PLC Entegrasyonunun Avantajları:

1. Gerçek Zamanlı İzleme: PLC'ler sıcaklık verilerini anında işleyerek sıcaklık sapmalarına anında yanıt vermeyi kolaylaştırır,
2. Otomatik Kontrol: Sensör girişlerine dayanarak PLC'ler soğutma sistemlerini ayarlayabilir, türbin işlemlerini düzenleyebilir ve alarmları otonom olarak tetikleyebilir,
3. Veri Kaydı ve Analizi: Sürekli veri toplama, trend analizi, öngörücü bakım ve türbin performansının optimizasyonunu sağlar.

Uygulama Hususları:


1. Sensör Yerleşimi: Doğru izleme için sensörleri rulmanlar ve sargılar gibi kritik türbin bileşenlerine stratejik olarak yerleştirin,
2. Sinyal Uyumluluğu: Sensör çıkışlarının sinyal koşullandırması gerektirebilecek PLC giriş modülleriyle uyumlu olduğundan emin olun,
3. Çevresel Faktörler: Hidroelektrik santralinin zorlu ortamına dayanacak uygun giriş koruma derecelerine sahip sensörleri ve PLC'leri seçin.

Hidroelektrik türbinlerinde sıcaklık sensörlerini PLC'lerle entegre etmek operasyonel verimliliği, güvenliği ve bakım stratejilerini geliştirir.


Yer Değıştirme Sensörleri.

Yer değıştirme sensörleri, konum sensörleri olarak da bilinir, özellikle baraj yapılarına entegre edilen hidroelektrik santrallerindeki türbinlerin verimliliğinin izlenmesi ve sürdürülmesinde önemli bir rol oynar. Türbin bileşenlerinin konumunu veya hareketini doğru bir şekilde ölçerek, bu sensörler özellikle Programlanabilir Mantık

Denetleyicileri (PLC'ler) ile entegre edildiğinde, hassas kontrol ve olası sorunların erken tespitini sağlar. [168].



Şekil 2. 22. Deplasman Sensörleri



Şekil 2. 23. Hidroelektrik Santralindeki sensör konumları.

Hidroelektrik Türbinlerinde Kullanılan Deplasman Sensörlerinin Türleri:

1. Doğrusal Değişken Diferansiyel Transformatörler (LVDT'ler): Bu sensörler, bir çekirdek doğrusal olarak hareket ederken bobinler arasındaki elektromanyetik kuplajdaki değişiklikleri algılayarak doğrusal deplasmanı ölçer. LVDT'ler zorlu ortamlarda yüksek doğrulukları ve güvenilirlikleriyle bilinir ve bu da onları türbin bileşenlerini izlemek için uygun hale getirir,
2. Eddy Akımı Sensörleri: Elektromanyetik alanları kullanan bu temassız sensörler, sensör ile iletken bir hedef arasındaki mesafedeki değişiklikleri algılar. Küçük deplasmanları ölçmede etkilidirler ve genellikle türbinlerdeki shaft titreşimlerini ve yatak konumlarını izlemek için kullanılırlar,
3. Kapasitif Sensörler: Bu sensörler, bir hedef nesnenin hareketinin neden olduğu kapasitans değişikliklerini ölçer. Son derece hassastırlar ve küçük deplasmanları algılayabilirler, bu da onları hassas konum bilgisinin kritik olduğu bileşenleri izlemek için kullanışlı hale getirir. PLC'lerle Entegrasyon:

PLC'lerle yer değiştirme sensörlerinin birleştirilmesi, hidroelektrik santrallerinin izleme ve kontrol yeteneklerini geliştirir:

1. Gerçek Zamanlı İzleme: PLC'ler, türbin bileşeni konumları hakkında anında veri sağlamak için yer değiştirme sensörlerinden gelen girdiyi işler ve normal çalışmadan herhangi bir sapmaya hızlı yanıtlar sağlar,
2. Otomatik Kontrol: Sensör verilerine dayanarak, PLC'ler optimum performansı korumak için türbin ayarlarını otomatik olarak ayarlayabilir ve böylece manuel müdahalelere olan ihtiyacı azaltabilir,
3. Tahmini Bakım: Sürekli veri toplama, aşınma modellerinin veya yanlış hizalamaların tanımlanmasını sağlayarak kritik arızalar meydana gelmeden önce bakımı kolaylaştırır.

Hidroelektrik Türbinleri için Uygulamalar:

1. Şaft Titreşim İzleme: Yer değiştirme sensörleri, dengesizlik veya yanlış hizalama gibi sorunları gösterebilen türbin şaftlarındaki titreşimleri algılar. PLC analiziyle erken tespit, kapsamlı hasarın önlenmesine yardımcı olur,
2. Yatak Pozisyonu Takibi: Yatakların pozisyonunun izlenmesi, belirtilen toleranslar dahilinde çalışmasını sağlayarak aşırı ısınma veya arıza riskini azaltır,
3. Kanat Pozisyon Ölçümü: Ayarlanabilir kanatlı türbinlerde, sensörler su akışını ve enerji dönüşüm verimliliğini optimize etmek için kanat açılarını izler.

Hidroelektrik türbinlerinde PLC'lerle entegre edilmiş yer değiştirme sensörlerinin uygulanması, ekipmanın operasyonel verimliliğini, güvenliğini ve uzun ömürlülüğünü artırır. Bu entegrasyon, otomatik ayarlamalar ve proaktif bakım stratejilerine olanak tanır ve güvenilir güç üretimi sağlar.

Basınç Sensörleri.

Basınç sensörleri, hassas basınç ölçümü ve izleme sağlayarak endüstriyel otomasyon, HVAC sistemleri, tehlikeli ortamlar ve yüksek basınç uygulamalarında kritik bir rol oynar. Indspare'deki Basınç Sensörleri kategorisi, Genel Endüstriyel Basınç Vericileri, Tehlikeli Alan Basınç Vericileri, Yüksek Basınç Vericileri, HVAC Basınç Vericileri ve Dalgıç Basınç Sensörleri dahil olmak üzere kapsamlı bir yüksek kaliteli sensör yelpazesi sunar. Bu sensörler, doğru basınç okumaları, uzun vadeli kararlılık ve aşırı koşullara karşı direnç sağlayarak, petrol ve gaz, HVAC, su arıtma, otomotiv ve üretim dahil olmak üzere çeşitli endüstriler için idealdir. WIKA gibi güvenilir markalar tarafından üretilen bu sensörler, değişen çalışma koşullarına dayanacak şekilde tasarlanmıştır, yüksek hassasiyet, sağlam dayanıklılık ve birden fazla işlem bağlantısıyla uyumluluk sunar. Endüstriyel otomasyon, akışkan kontrolü veya çevresel izlemede kullanılsın, bu basınç sensörleri güvenilir performans, gelişmiş sistem verimliliği ve güvenlik standartlarına uyumluluk sağlar. Belirli uygulamanız için en uygun olanı bulmak için kapsamlı basınç vericileri ve sensörleri yelpazemizi keşfedin [165].



Şekil 2. 24. Basınç Sensörleri

Hava Boşluğu Sensörü

Hava boşluğu sensörü, jeneratörünüzün rotoru ve statoru arasındaki gerçek zamanlı hava boşluğunu ölçmek için bir standart olarak kullanılır; yük altında hidroelektrik jeneratör türbin ünitelerinin davranışını anlamak için hayati önem taşır. Santrifüj, termal ve manyetik kuvvetlerin birleşik etkileri nedeniyle, jeneratör hizmet dışı olduğunda hava boşluğu boyutları, rotor ve stator şekilleriyle birlikte etkili bir şekilde ölçülemez. Kısacası, Bally Nevada 4000 Serisi Jeneratör Hava Boşluğu Sensörü gibi bir izleme ve kontrol sistemi oluşturmak için gerçek, kullanılabilir veriler elde etmek için gerçek zamanlı izleme gereklidir.

Hidro sensörler ayrıca birden fazla değişkeni kaydeder; yalnızca bir değişkeni değil; böylece ünite titreşim sorunları hakkında daha doğru bir anlayış elde edilebilir. Artan veri ve anlayışla birlikte sorunları daha doğru bir şekilde teşhis etme ve buna göre tepki verme yeteneği gelir; bu da maliyetli duruş sürelerini, yanlış teşhisleri ve bazı durumlarda aksi takdirde gerekli olacak gereksiz incelemeleri önler [169].



Şekil 2. 25. Hava Boşluğu Sensörü

2.1.5.3. Titreşim ve Yapısal Sağlık İzleme

Titreşim Sensörleri (İvmeölçerler).

Titreşim sensörleri, bu faktörün önemli etkisi göz önüne alındığında, hidroelektrik santrallerindeki izleme ve karar alma sürecinin temel taşıdır. Türbinlerdeki titreşimi ölçmek için kullanılan manyetik hız sensörü olan STA-SZ6, titreşim sinyallerini voltaj sinyallerine etkili bir şekilde dönüştürebilen bir atalet sensörüdür. Bu dönüştürme işlemi sırasında, voltaj büyüklüğü titreşim hızıyla doğru orantılıdır. Bu sensör, mermilerin veya uzayda taşınan yapıların atalet titreşimini ölçmede mükemmel bir performans gösterir. Kompakt yapısı nedeniyle, doğrudan ekipmanın dışına monte edilebilir ve bu da kurulum karmaşıklığını ve bakım maliyetlerini önemli ölçüde azaltır [170].



Şekil 2. 26. Hidro Türbin Titreşim İzleme için Hidro Sensörler

Ürün Özellikleri:

1. Son derece hassas: Sensör, küçük titreşim sinyallerini yakalamasını sağlayan gelişmiş manyetoelektrik indüksiyon teknolojisini kullanır ve böylece yüksek sıcaklıklar ve yüksek basınçlar gibi zorlu ortamlarda bile yüksek ölçüm doğruluğunu korur,
2. Güçlü anti-parazit yeteneği: Manyetoelektrik hız sensörleri, yüksek elektromanyetik uyumluluk sergileyerek yüksek elektromanyetik parazit ortamlarında bile kararlı çalışma sağlar,
3. Kolay kurulum: Sensör, kapsamlı ekipman değişiklikleri gerektirmeden doğrudan makinenin dışına kurulum sağlayan kompakt bir yapıya sahiptir,
4. Kolay bakım: Sensör, basit sorun giderme ve bakım işlemlerine olanak tanıyan modüler bir tasarıma sahiptir ve bu da bakım maliyetlerini önemli ölçüde azaltır,
5. Geniş sıcaklık aralığı: Sensör, çeşitli iklim koşullarına uygun hale getiren geniş bir çalışma sıcaklığı aralığına sahiptir,
6. Uzun kullanım ömrü: Sensör, yüksek kaliteli malzemelerden ve işlemlerden yapılmıştır ve iyi dayanıklılık ve uzun bir hizmet ömrü sağlar.

Sensör Uygulamaları:


Esas olarak elektrik, çelik, su koruma, yapı malzemeleri, raylı ulaşım, kimya mühendisliği vb. alanlarda, çeşitli döner makinelerin titreşimini, salınımını, eksenel yer değiştirmesini, diferansiyel genleşmesini, eksantrikliğini, hızını, anahtar kelimesini, hidrolik motorunu, senkronizatörünü, sıcaklığını vb. sürekli olarak izlemek ve ölçmek için kullanılır, kullanıcıların makinelerin çalışma koşullarını korumasını ve gereksiz ekonomik kayıplardan kaçınmasını kolaylaştırır. İzleme ve koruma cihazı, yüksek ve düşük geçişli filtreler ve izolasyon bariyerleri içeren yüksek performanslı bir anahtarlama güç kaynağı kullanır ve bu da anti-parazit yeteneğini önemli ölçüde artırır. Kararlı performans, güvenlik ve güvenilirlik ve yüksek maliyet etkinliği.

Yakınlık Probları.

Eddy akımı sensörleri olarak da bilinen yakınlık probları, özellikle baraj yapıları içinde bulunan hidroelektrik santrallerindeki türbinlerin operasyonel bütünlüğünün izlenmesinde ayrılmaz bileşenlerdir. Bu sensörler, elektromanyetik bir alan oluşturarak ve yakındaki iletken malzemelerin neden olduğu bozulmaları ölçerek fiziksel temas olmaksızın metalik nesnelerin yakınlığını algılar. Bu temassız ölçüm, şaft titreşimi, yer değiştirme ve konum gibi parametreleri değerlendirmek ve böylece türbinlerin verimli ve güvenli bir şekilde çalışmasını sağlamak için çok önemlidir [171].



Şekil 2. 27. Yakınlık Probları Sensörü



Şekil 2. 28. Yakınlık Probları Sensör konumu

Hidroelektrik Türbinlerinde Uygulamalar:

1. Şaft Titreşim İzleme: Yakınlık probları genellikle türbin şaftlarının titreşimini izlemek için kullanılır. Aşırı titreşim, dengesizlik, yanlış hizalama veya yatak arızaları gibi olası sorunları gösterebilir. Şaft hareketi hakkında gerçek zamanlı veri sağlayarak, bu sensörler anormalliklerin erken tespitini sağlayarak zamanında bakım yapılmasını kolaylaştırır ve felaketle sonuçlanacak arızaları önler,
2. Yatak Boşluğu Ölçümü: Türbin şaftları ile yataklar arasında uygun boşluğun korunması, aşınma ve yıpranmayı en aza indirmek için hayati önem taşır. Yakınlık probları bu boşluğu doğru bir şekilde ölçer ve önemli bir hasar meydana gelmeden önce ayarlamalar yapılmasını sağlar,
3. Türbin Kanat Konumlandırması: Bazı türbin tasarımlarında, yakınlık probları türbin kanatlarının konumunu izleyerek optimum hizalama ve performansı garanti eder.


Programlanabilir Mantık Denetleyicileri (PLC'ler) ile Entegrasyon:

Yakınlık problemlerini PLC'lerle entegre etmek, hidroelektrik santrallerinin izleme ve kontrol yeteneklerini geliştirir:

1. Gerçek Zamanlı Veri Toplama: Yakınlık problemleri, PLC'lere sürekli veri iletir ve normal çalışma koşullarından herhangi bir sapmaya anında analiz ve yanıt sağlar,
2. Otomatik Kontrol: PLC'ler, türbin işlemlerini otomatik olarak ayarlamak için yakınlık problemlerinden gelen verileri işleyebilir, performansı optimize edebilir ve manuel müdahaleyi azaltabilir,
3. Tahmini Bakım: Yakınlık problemlerinden toplanan verilerdeki eğilimleri analiz ederek, PLC'ler olası bileşen arızalarını tahmin edebilir, proaktif bakım planlamasına olanak tanır ve planlanmamış duruş süresini azaltır.

Gerinim Ölçerler.

Gerinim ölçerler, özellikle baraj yapılarına entegre edilen hidroelektrik santrallerindeki türbinlerin yapısal bütünlüğünü ve performansını izlemede temel araçlardır. Türbin bileşenlerinin operasyonel yükler altında gerinim veya deformasyonunu ölçerek, gerinim ölçerler bakım kararlarını bilgilendiren ve genel verimliliği artıran kritik veriler sağlar. Programlanabilir Mantık Denetleyicileri (PLC'ler) ile entegre edildiğinde, bu veriler otomatik sistemlerde gerçek zamanlı izleme ve kontrol için kullanılabilir [172].



Şekil 2. 29. Gerinim Ölçer Sensörü

Hydroelektrik Türbinlerinde Uygulamalar:

1. Türbin Kanat Optimizasyonu: Gerinim ölçerler, çalışma sırasında türbin kanatlarındaki gerilim dağılımını ölçmek için kullanılır. Bu veriler, maksimum verimlilik elde etmek için kanat tasarımını optimize etmek için çok önemlidir. Örneğin, Iron Gate Barajı'nda, gerinim ölçer ölçümleri, türbin kanat performansını değerlendirmek ve geliştirmek için kullanıldı. HBM,
2. Yapısal Sağlık İzleme: Gerinim ölçerleri türbin koşucusu ve şaft gibi kritik bileşenlere bağlayarak, mühendisler gerilim seviyelerini izleyebilir ve yorulma veya yapısal zayıflıkların erken belirtilerini tespit edebilir. Bu proaktif yaklaşım, felaket niteliğindeki arızaları önlemeye yardımcı olur ve ekipmanın ömrünü uzatır,
3. Dinamik Yük Analizi: Gerinim ölçerler, özellikle değişen çalışma koşulları altında türbinlerin maruz kaldığı dinamik yüklerin ve gerilimlerin ölçülmesini kolaylaştırır. Bu bilgi, türbinin farklı yük senaryoları sırasındaki davranışını anlamak ve bilinçli operasyonel kararlar almak için hayati önem taşır.

PLC'lerle Entegrasyon:

Gerilim ölçer verilerini PLC sistemlerine dahil etmek, türbin operasyonlarını etkili bir şekilde izleme ve kontrol etme yeteneğini artırır:

1. Gerçek Zamanlı İzleme: PLC'ler, aşırı stres veya alışılmadık yük kalıpları gibi anormalliklerin anında tespit edilmesine olanak tanıyan gerinim ölçerlerden gelen verileri gerçek zamanlı olarak işleyebilir,
2. Otomatik Tepkiler: Gerinim verilerine dayanarak PLC'ler, operasyonel parametreleri ayarlama veya hasarı önlemek için kapatma prosedürlerini başlatma gibi otomatik tepkileri tetikleyebilir,
3. Veri Kaydı ve Analizi: Sürekli veri toplama, tahmini bakım stratejileri ve zaman içinde türbin performansını optimize etmek için gerekli olan trend analizini mümkün kılar.

Hidroelektrik türbin izlemede gerinim ölçerlerin uygulanması, modern baraj operasyonlarının kritik bir yönüdür. PLC'lerle entegre edildiğinde, gerinim ölçerler türbin bileşenlerinin yapısal sağlığı ve performansı hakkında değerli bilgiler sağlayarak proaktif bakımı kolaylaştırır, verimliliği artırır ve ekipmanın uzun ömürlü olmasını sağlar.

2.1.5.4. Elektriksel Performans İzleme

Voltaj ve akım sensörleri, hidroelektrik santrallerindeki türbin jeneratörlerinin elektrik performansının izlenmesinde kritik bir rol oynar. Bu sensörler, sürekli olarak elektrik parametrelerini ölçerek optimum verimliliği garanti eder, arızaları tespit eder ve öngörücü bakımı mümkün kılar. Programlanabilir Mantık Denetleyicileri (PLC'ler) ile entegre edildiklerinde, güç üretim sistemleri için gerçek zamanlı veri toplama, otomatik kontrol ve koruma mekanizmalarını kolaylaştırırlar.

Gerilim sensörleri

Gerilim sensörleri, özellikle baraj yapıları içindeki türbin operasyonlarının izlenmesi ve kontrolünde hidroelektrik santrallerinde temel bileşenlerdir. Bu sensörler jeneratör sistemlerindeki potansiyel elektrik farkını ölçerek verimli enerji üretimi ve sistem kararlılığı sağlar. Programlanabilir Mantık Denetleyicileri (PLC'ler) ile entegre edildiğinde, gerilim sensörleri gerçek zamanlı izleme, otomasyon ve koruma mekanizmalarını kolaylaştırır [173].

Hidroelektrik Türbinlerinde Kullanılan Gerilim Sensör Türleri:

- 1 Kapasitif Gerilim Sensörleri: Bu sensörler, gerilim değişimlerinden kaynaklanan kapasitans değişikliklerini ölçerek gerilim seviyelerini algılar. Yüksek gerilim uygulamaları için uygundurlar ve temassız ölçüm yetenekleri sunarlar,
- 2 Dirençli Gerilim Bölücüler: Bir dizi direnç kullanan bu sensörler, giriş gerilimini ölçülebilir bir seviyeye böler. Hassas gerilim ölçümleri sağlarlar ve çeşitli elektrik uygulamalarında yaygın olarak kullanılırlar,
- 3 Hall Etkisi Gerilim Sensörleri: Hall Etkisi prensibine dayanan bu sensörler, akım akışı tarafından oluşturulan manyetik alanı algılayarak gerilimi ölçer. İzole ve hassas ölçümler sundukları için türbin sistemlerindeki voltajın izlenmesi için uygundurlar.

PLC'lerle Entegrasyon:

PLC'lerle voltaj sensörlerinin birleştirilmesi, hidroelektrik santrallerinin operasyonel verimliliğini ve güvenliğini artırır:

1. Gerçek Zamanlı İzleme: Voltaj sensörleri, voltaj dalgalanmaları veya dengesizlikler gibi anormalliklerin anında tespiti edilmesini sağlayarak verileri sürekli olarak Programlanabilir Mantık Denetleyicilerine (PLC'ler) iletir,

2. Otomatik Kontrol: PLC'ler, türbin işlemlerini otomatik olarak ayarlamak, performansı optimize etmek ve değişen yük taleplerine yanıt vermek için voltaj verilerini işler,
3. Koruyucu Fonksiyonlar: Anormal voltaj seviyeleri durumunda, PLC'ler hasarı önlemek için ekipmanı kapatmak veya arızalı bölümleri izole etmek gibi koruyucu önlemleri başlatabilir.

Hidroelektrik Türbinleri için Uygulamalar:

1. Jeneratör Voltaj Düzenlemesi: Voltaj sensörleri, jeneratörlerin çıkış voltajını izleyerek, kararlı bir güç kaynağı için belirtilen sınırlar içinde kalmasını sağlar,
2. Güç Kalitesi İzleme: Bu sensörler, voltaj seviyelerini değerlendirerek güç kalitesinin korunmasına yardımcı olur ve ekipman performansını etkileyebilecek voltaj düşüşleri veya yükselmeleri gibi sorunları tespit eder,
3. Arıza Tespiti: Gerilim sensörleri, düzensiz voltaj düzenlerini algılayarak kısa devre veya topraklama sorunları gibi arızaların belirlenmesine yardımcı olur ve böylece hızlı bakım işlemlerinin yapılmasını sağlar.

Akım Trafoları (CT'ler)

Akım sensörleri, özellikle baraj tabanlı türbin sistemlerinde, verimli ve güvenli operasyonları sağlamak için elektrik parametrelerini izledikleri hidroelektrik santrallerinde temel bileşenlerdir. Programlanabilir Mantık Denetleyicileri (PLC'ler) ile entegre edildiğinde, bu sensörler gerçek zamanlı veri toplamayı ve otomatik kontrolü kolaylaştırır ve hidroelektrik tesislerinin performansını optimize eder [174].



Şekil 2. 30. Akım Trafoları (CT).

Hidroelektrik Türbinlerinde Kullanılan Akım Sensörlerinin Türleri:

1. Akım Trafoları (CT'ler): Bu cihazlar, devredeki akıma orantılı olarak azaltılmış bir akım üreterek yüksek alternatif akımları ölçer, ölçüm ve koruma uygulamaları için uygundur,
2. Rogowski Bobinleri: Geniş bir frekans aralığında AC akımlarını algılayan esnek, hava çekirdekli bobinler, kolay kurulum ve doygunluk olmadan büyük akımları ölçme yeteneği gibi avantajlar sunar,
3. Şönt Dirençleri: Akım akışına orantılı bir voltaj düşüşü üreten düşük dirençli dirençler, genellikle hassas DC akım ölçümleri için kullanılır,
4. Hall Etkisi Sensörleri: Akım akışı tarafından üretilen manyetik alanları algılamak için Hall etkisi ilkesini kullanır ve hem AC hem de DC akımlarının temassız ölçülmesini sağlar.

PLC'lerle Entegrasyon:

PLC'lerle akım sensörlerinin birleştirilmesi, hidroelektrik santrallerinin izleme ve kontrol yeteneklerini artırır:

1. Gerçek Zamanlı İzleme: Akım sensörleri PLC'lere anlık veri sağlayarak, elektrik parametrelerinin sürekli değerlendirilmesine ve anormalliklerin erken tespitine olanak tanır,

2. Otomatik Kontrol: PLC'ler, deęişen yük koşulları altında optimum performansı koruyarak türbin işlemlerini dinamik olarak ayarlamak için sensör verilerini kullanır,
3. Tahmini Bakım: PLC'ler mevcut eğilimleri analiz ederek olası ekipman arızalarını tahmin edebilir, proaktif bakımı kolaylaştırabilir ve duruş süresini azaltabilir.

Hidroelektrik Türbinlerindeki Uygulamalar:

1. Yük Yönetimi: Akım sensörleri, PLC'lerin şebeke genelinde gücü verimli bir şekilde dağıtmak için kullandığı verileri sağlayarak elektrik yüklerinin dengelenmesine yardımcı olur,
2. Arıza Algılama: Sensörler kısa devre veya topraklama sorunları gibi düzensizlikleri tespit eder ve PLC'leri önleyici tedbirleri başlatmaya yönlendirir,
3. Enerji Verimlilięi Analizi: Doğru ölçümlerin türbin verimlilięini deęerlendirmesini sağlar ve enerji üretimini iyileştirmek için ayarlamalara rehberlik eder.

PLC'lerle Akım Sensörleri Kullanmanın Avantajları:

1. Gelişmiş Operasyonel Verimlilik: Doğru izleme, türbin operasyonlarının ince ayarını sağlayarak optimum enerji üretimine yol açar,
2. Gelişmiş Güvenlik: Elektrik arızalarının erken tespiti, ekipman hasarını önlemeye yardımcı olur ve tesis personelinin güvenlięini sağlar,
3. Veri Kaydı ve Analizi: Sürekli veri toplama, trend analizini destekleyerek bilinçli karar alma ve stratejik planlamayı kolaylaştırır.

Güç Ölçerler

Güç ölçerler, özellikle baraj tabanlı türbin sistemlerinde, verimli ve güvenli operasyonları sağlamak için elektrik parametrelerini izleyip ölçtükleri için hidroelektrik santrallerinde temel araçlardır. Programlanabilir Mantık Denetleyicileri

(PLC'ler) ile entegre edildiğinde, bu ölçerler gerçek zamanlı veri toplamayı ve otomatik kontrolü kolaylaştırır ve hidroelektrik tesislerinin performansını optimize eder [175].

Hidroelektrik Türbinlerinde Güç Ölçerlerin Rolü:

1. Elektriksel Parametre İzleme: Güç ölçerler, voltajı, akımı, güç faktörünü, frekansı ve toplam harmonik bozulmayı ölçerek türbinlerin elektrik performansına ilişkin kapsamlı bir genel bakış sağlar,
2. Arıza Tespiti: Sürekli izleme, aşırı yük veya dengesizlik gibi anormalliklerin erken tespitini sağlayarak hızlı düzeltici eylemlere olanak tanır,
3. Enerji Yönetimi: Enerji üretiminin doğru ölçümü verimliliği, hücre bakımını ve proses optimizasyonunu değerlendirir.

PLC'lerle Entegrasyon:

Güç sayaçlarını PLC'lerle birleştirmek, hidroelektrik santrallerinin izleme ve kontrol yeteneklerini geliştirir:

1. Gerçek Zamanlı Veri Toplama: Sayaçlar PLC'lere gerçek zamanlı veriler sağlayarak parametrelerin değerlendirilmesini ve anormalliklerin erken tespitini sağlar.
2. Otomatik Kontrol: PLC'ler, türbin operasyonlarını dinamik olarak ayarlamak için güç sayaçlarından gelen verileri kullanır ve değişen yük koşulları altında optimum performansı korur.
3. Tahmini Bakım: PLC'ler, elektrik parametrelerindeki eğilimleri analiz ederek olası ekipman arızalarını tahmin edebilir, proaktif bakımı kolaylaştırabilir ve duruş süresini azaltabilir.

Frekans sensörleri

Frekans sensörleri, özellikle baraj tabanlı türbin sistemlerinde, elektrik şebekesiyle senkronizasyonu sağlamak için türbinlerin dönüş hızını izledikleri için hidroelektrik santrallerinde önemlidir. Programlanabilir Mantık Denetleyicileri (PLC'ler) ile entegre

edildiğinde, bu sensörler gerçek zamanlı veri toplama ve otomatik kontrolü kolaylaştırır, hidroelektrik tesislerinin performansını ve güvenilirliğini optimize eder [176].

Hidroelektrik Türbinlerinde Kullanılan Frekans Sensörlerinin Türleri:

1. Takometreler: Türbin şaftının dönüş hızını ölçen ve türbin frekansı hakkında veri sağlayan cihazlar,
2. Yakınlık Probları: Türbin şaftının konumunu ve hareketini algılayan ve frekansın hesaplanmasını sağlayan temassız sensörler,
3. Kodlayıcılar: Türbin şaftının mekanik konumunu elektrik sinyallerine dönüştüren ve hassas frekans ölçümü sağlayan sensörler.

PLC'lerle Entegrasyon:

Frekans sensörlerini PLC'lere dahil etmek, hidroelektrik santrallerinin izleme ve kontrol yeteneklerini geliştirir:

1. Gerçek Zamanlı İzleme: Frekans sensörleri PLC'lere anlık veri sağlar ve türbin hızının sürekli değerlendirilmesine ve şebekeyle senkronizasyona olanak tanır,
2. Otomatik Kontrol: PLC'ler, değişen yük koşulları altında optimum performansı koruyarak türbin operasyonlarını dinamik olarak ayarlamak için frekans verilerini kullanır,
3. Tahmini Bakım: PLC'ler, frekans eğilimlerini analiz ederek olası ekipman sorunlarını tahmin edebilir, proaktif bakımı kolaylaştırabilir ve duruş süresini azaltabilir.

Hidroelektrik Türbinleri İçin Uygulamalar:

1. Şebeke Senkronizasyonu: Frekans sensörleri, türbinlerin elektrik şebekesiyle uyum içinde çalışmasını sağlayarak güç kalitesi sorunlarını önler,
2. Yük Yönetimi: Doğru frekans ölçümleri, elektrik yüklerinin dengelenmesine yardımcı olarak şebeke genelinde güç dağıtımını optimize eder,

3. Arıza Tespiti: Frekans deęişimlerinin izlenmesi, mekanik dengesizlikler veya elektrik arızaları gibi düzensizlikleri belirlemeye yardımcı olarak zamanında düzeltici eylemler yapılmasını sağlar.

PLC'lerle Frekans Sensörleri Kullanmanın Avantajları:

1. Gelişmiş Operasyonel Verimlilik: Doğru izleme, türbin operasyonlarının ince ayarını sağlayarak optimum enerji üretimi sağlar,
2. Gelişmiş Güvenlik: Frekans anomalilerinin erken tespiti, ekipman hasarını önlemeye yardımcı olur ve tesis personelinin güvenliğini sağlar,
3. Veri Kaydı ve Analizi: Sürekli veri toplama, trend analizini destekleyerek bilgili karar vermeyi ve stratejik planlamayı kolaylaştırır.

Faz Açısı Sensörleri

Faz açısı sensörleri, özellikle Programlanabilir Mantık Denetleyicileri (PLC'ler) ile entegre edildiklerinde, hidroelektrik santrallerindeki türbinlerin performansının izlenmesi ve kontrol edilmesinde önemli bir rol oynar. Bu sensörler, iki periyodik sinyal arasındaki faz farkını ölçerek, türbin operasyonlarının hassas kontrolü ve senkronizasyonu için temel veriler sağlar [175].

Hidroelektrik Türbinlerinde Faz Açısı Sensörlerinin İşlevi:

1. Senkronizasyon: Faz açısı sensörleri, türbinin dönme fazının jeneratörün elektrik fazıyla doğru bir şekilde hizalanmasını sağlayarak, istikrarlı ve verimli güç üretimi sağlar,
2. Hız ve Yön İzleme: Faz kaymalarını tespit ederek, bu sensörler türbinin dönme hızını ve yönünü izler ve performansı optimize etmek için gerçek zamanlı ayarlamalar yapılmasını sağlar,
3. Arıza Tespiti: Faz ilişkilerindeki anormallikleri belirlemek, mekanik sorunların erken tespit edilmesine, olası hasar ve duruş sürelerinin önlenmesine yardımcı olur.

PLC'lerle Entegrasyon:

Faz açısı sensörlerinin PLC'lerle entegre edilmesi hidroelektrik santrallerinin operasyonel verimliliğini artırır:

1. Gerçek Zamanlı Veri İşleme: PLC'ler sensörlerden gelen faz verilerini işleyerek değişen operasyonel koşullara anında yanıt vermeyi kolaylaştırır,
2. Otomatik Kontrol: Sensör girişlerine dayalı olarak PLC'ler türbin operasyonlarını otomatik olarak ayarlayarak optimum senkronizasyon ve performans sağlar,
3. Veri Kaydı ve Analizi: PLC'ler faz verilerini zaman içinde kaydederek trend analizi ve bakım ve operasyonel stratejilerle ilgili bilinçli karar alma olanağı sağlar.

Hidroelektrik Santrallerindeki Uygulamalar:

1. Şebeke Entegrasyonu: Türbin ile şebeke arasındaki faz hizalamasını korumak, istikrarlı güç dağıtımı için önemlidir,
2. Performans Optimizasyonu: Sürekli faz izleme, türbin operasyonlarının maksimum verimlilik için ince ayarını sağlar,
3. Güvenlik Geliştirmeleri: Faz tutarsızlıklarının erken tespiti hem ekipman hem de personelin güvenliğine katkıda bulunur.

PLC'lerle Faz Açısı Sensörlerinin Kullanılmasının Avantajları:

1. Gelişmiş Verimlilik: Hassas faz kontrolü, gelişmiş enerji dönüşüm verimliliğine yol açar.
2. Artan Güvenilirlik: Sürekli izleme ve otomatik ayarlamalar, operasyonel arızaların olasılığını azaltır.
4. Operasyonel Esneklik: Sistemin gerçek zamanlı verilere tepkisi, değişen koşullar altında uyarlanabilir operasyonlara olanak tanır.

2.1.5.5. Regülatör Kontrol Sistemi

Hidroelektrik santrallerindeki Regülatör Kontrol Sistemi, türbinlere giden su akışını kontrol ederek türbin hızını ve güç çıkışını düzenlemek için tasarlanmış kritik bir sistemdir. Sistem, türbinin güvenli ve verimli sınırlar içinde çalışmasını sağlamak için kapı veya vana açıklıklarını ayarlayarak türbinden geçen su miktarını kontrol eder [177, 178].

Hız Regülatörü

1. Türbin hızını izler ve belirli bir hızı korumak için su akışını ayarlar,
2. Tarihsel olarak santrifüjlü regülatörler (fly-ball regülatörler) kullanılmıştır, ancak modern sistemler hassas kontrol için genellikle elektronik regülatörler kullanır.

Hidrolik Amplifikatör

1. Buhar veya su giriş vanasını kontrol etmek için regülatörden gelen sinyali yükseltir,
2. Düşük güç sinyallerini yüksek güç eylemlerine dönüştüren bir pilot vana ve bir ana pistondan oluşur.

Hız Değiştirici

1. Sistemin bu kısmı, türbine sabit bir güç ayarı sağlamak ve sabit koşullar altında sabit bir çıkış sağlamak için kullanılır. Alçaltılabilen veya yükseltilebilen bir kolu vardır. Kolun konumunu değiştirmek, Buhar Giriş valfinin konumunu değiştirir,
2. Sabit durum koşulları altında türbine sabit bir güç ayarı sağlar,
3. Buhar akışını düzenlemek için buhar giriş valfinin konumunu ayarlar.

Regülatör Mekanizması:

Bu yönetim sisteminde bir flyball Regülatörü kullanılır. Buna santrifüj Regülatörü de denir. Sistemin bu kısmı frekanstaki değişiklikleri algılar.

İşlev:

1. Değişen yük koşulları altında, regülatör türbin hızındaki değişiklikleri algılar,
2. Hidrolik amplifikatör aracılığıyla buhar veya su giriş vanasının konumunu ayarlayarak türbine giden akışı kontrol eder,
3. Bu düzenleme türbinin hızını korur ve güç çıkışını dengeler.

Modern Gelişmeler:

Değişken Hızlı Hidroelektrik Santralleri (VSHP), şebeke kararlılığını artıran hızlı frekans rezervleri sağlamak için regülatör kontrol sistemlerini kullanır.

2.1.5.6. Uyarım Sistemi

Bir uyarım sistemi, senkron jeneratörlerin alan sargılarına düzenlenmiş doğru akım (DC) sağladığı için elektrik enerjisi üretiminde çok önemlidir. Bu kontrollü DC akımı, jeneratörün çalışması için gerekli manyetik alanı oluşturur ve böylece çıkış voltajını ve reaktif gücünü düzenler [179].

Temel İşlevler:

1. Voltaj Düzenlemesi: Uyarım sistemi, alan akımını ayarlayarak jeneratörün terminal voltajını istenen sınırlar içinde tutar, yük değişimlerini telafi eder ve kararlı voltaj çıkışı sağlar,
2. Reaktif Güç Kontrolü: Sistem, jeneratörün uyarım seviyesini kontrol ederek reaktif gücü (volt-amper reaktif, VAR cinsinden ölçülür) yönetir. Uyarımı artırmak, jeneratörün şebekeye VAR'lar sağlamasını sağlarken, uyarımı azaltmak VAR'ları emmesini sağlar ve böylece güç faktörü düzeltilmesini ve voltaj kararlılığını etkiler.

Uyarım Sistemleri Türleri:

1. Dönen Uyarıcılar: Bunlar, ana jeneratörle aynı şaftta monte edilmiş küçük bir jeneratörün (uyarıcı) gerekli uyarım akımını sağladığı fırçasız ve fırçalı tipleri içerir,
2. Statik Uyarıcılar: Tristörler veya IGBT'ler gibi güç doğrultucularını kullanan statik uyarıcılar, alternatif akımı (AC) DC'ye dönüştürerek, dönen bileşenler olmadan hassas uyarım kontrolü sağlar.

Tipik Bir Uyarım Sisteminin Bileşenleri:

1. Voltaj Regülatörü: Jeneratörün terminal voltajını izler ve ayarlanan voltaj seviyesini korumak için uyarım akımını ayarlar,
2. Uyarıcı: Jeneratörün alan sargılarına DC akımı sağlar,
3. Güç Sistemi Stabilizatörü (PSS): Güç salınımlarını azaltmak için uyarımı modüle ederek sistem kararlılığını artırır.

Güç Sistemi Kararlılığının Önemi:

Uyarım sistemleri, güç sistemlerinin kararlılığını artırmada kritik bir rol oynar. Jeneratör voltajını ve reaktif gücü düzenleyerek statik, dinamik ve geçici kararlılığı artırır; bu da kararlı voltaj profillerinin korunması ve kesintiler sırasında şebekenin desteklenmesi için hayati önem taşır.

2.2. TAHMİN VE ÖNGÖRÜ

2.2.1. Tahmin ve Öngörü Kavramı

Bir tahmin (Latince præ-, "önce" ve dictum, "söylenen bir şey"[207]) veya öngörü, gelecekteki bir olay veya gelecekteki veriler hakkında bir ifadedir. Tahminler genellikle, ancak her zaman değil, tahmincilerin deneyimine veya bilgisine dayanır. "Tahmin" ve "tahmin" arasındaki kesin fark konusunda evrensel bir fikir birliği yoktur; farklı yazarlar ve disiplinler bu terimlere farklı çağrışımlar yükler. İstatistiksel

olmayan bir anlamda, "öngörü" terimi genellikle bilgili bir tahmin veya görüşe atıfta bulunmak için kullanılır.

Bu tür bir tahmin, tahmin eden kişinin tümevarımsal akıl yürütmesi, tümdengelimli akıl yürütmesi, tümdengelimli akıl yürütmesi ve deneyimi tarafından bilgilendirilebilir; tahmin eden kişi alanda bilgili bir kişiyse yararlı olabilir [208].

İstatistikte, tahmin istatistiksel çıkarımın bir parçasıdır. Bu tür çıkarımlara yönelik belirli bir yaklaşım, öngörücü çıkarım olarak bilinir, ancak öngörü, istatistiksel çıkarımlara yönelik çeşitli yaklaşımlardan herhangi biri dahilinde gerçekleştirilebilir. Aslında, istatistiklerin olası bir tanımı, bir popülasyonun bir örneği hakkındaki bilgiyi tüm popülasyona ve diğer ilgili popülasyonlara aktarmanın bir yolunu sağlamasıdır; bu, zaman içinde tahminler yapmakla aynı şey değildir. Bilgiler zaman içinde, genellikle belirli zaman noktalarına aktarıldığında, bu süreç tahmin olarak bilinir [209].

Tahmin için kullanılan istatistiksel teknikler arasında regresyon ve doğrusal regresyon, genelleştirilmiş doğrusal modeller (lojistik regresyon, Poisson regresyonu ve Probit regresyonu dahil) gibi çeşitli alt kategorileri bulunur. Tahminde, otoregresif hareketli ortalama modelleri ve vektör otoregresif modelleri kullanılabilir. Bu ve/veya ilgili genelleştirilmiş regresyon kümeleri veya makine öğrenimi yöntemleri ticari uygulamalarda kullanıldığında, alan öngörücü analitik olarak bilinir [210].

Zaman serisi analizi gibi birçok uygulamada, gözlemleri üreten modelleri tahmin etmek mümkündür. Modeller transfer fonksiyonları veya durum alanı parametreleri olarak ifade edilebiliyorsa, yumuşatılmış, filtrelenmiş ve tahmin edilmiş veri tahminleri hesaplanabilir [211].

Tahmin için regresyon analizini kullanmak için, tahmin edilecek değişken, yani bağımlı değişken veya yanıt değişkeni olarak bilinen ve değerlerinin onu etkilediği varsayılan bir veya daha fazla değişken, yani bağımsız değişkenler veya açıklayıcı değişkenler olarak adlandırılan veriler toplanır. Genellikle doğrusal olan bir fonksiyonel form, varsayılan nedensel ilişki için varsayılır ve fonksiyonun

parametreleri verilerden tahmin edilir; yani, fonksiyonun veriye uyumunu bir şekilde optimize etmek için seçilir, böylece parametrelendirilir. Bu, tahmin adımıdır. Tahmin adımı için, bağımlı değişkenin gelecekteki (veya mevcut ancak henüz gözlemlenmemiş) değerleriyle ilgili olduğu düşünülen açıklayıcı değişken değerleri, bağımlı değişken için tahminler üretmek üzere parametrelendirilmiş fonksiyona girilir [212].


Matematiksel denklemler ve modeller, bilgisayar modelleri gibi, sıklıkla bir sürecin o modelin sınırları içindeki geçmiş ve gelecekteki davranışını tanımlamak için kullanılır. Bazı durumlarda, belirli bir sonuçtan ziyade bir sonucun olasılığı tahmin edilebilir. Doğru tahmin ve öngörü, doğal afetler, pandemiler, demografi, nüfus dinamikleri ve meteoroloji gibi belirli alanlarda özellikle zordur [213]. Örneğin, güneş döngülerinin oluşumunu tahmin etmek mümkündür, ancak bunların tam zamanlaması ve büyüklüğü önemli ölçüde daha zordur. Malzeme mühendisliğinde, bir malzemenin ömrünü matematiksel bir modelle tahmin etmek de mümkündür [214]. Tıp biliminde, öngörücü ve prognostik biyobelirteçler, çeşitli tedavilere yanıt olarak hasta sonuçlarını veya bir klinik olayın olasılığını tahmin etmek için kullanılabilir [215].

Tahmin genellikle büyük veri analitiği ve öngörücü analitik ile ilişkilendirilir. Günümüzde, birçok tahmin tekniği, tahminleri daha verimli ve doğru bir şekilde geliştirmek için yapay zeka (AI) ve makine öğrenimi yöntemlerinden yararlanır. AI modelleri, geleneksel elektronik tablo tabanlı analitik yöntemlere göre net avantajlara sahiptir. Örneğin, tedarik zinciri yönetimine yapay zeka destekli tahmin uygulanması hataları yüzde 50'ye kadar azaltabilir ve bunun sonucunda satış kayıplarında ve ürün bulunamama oranında yüzde 65'e kadar azalma sağlanabilir [216].

2.2.2. Tahmin Süreci

Tahmin süreci, tahminlerin doğru olduğundan ve etkili karar almayı kolaylaştırdığından emin olmak için bir dizi adımı içerir. Tahmin sürecindeki temel adımlar şunlardır [217-219]:

1. Net hedefler belirleyin: Tahmin edilecek belirli bir iş koşulu veya ölçüt belirtilir, tahminin amacı dikkate alınır, ilgili varsayımlar ve uygulanabilir değişkenler dikkate alınır ve kısa vadeli, orta vadeli veya uzun vadeli bir zaman dilimi seçilir,
2. Veri toplayın: Bu adım, geçmiş satış rakamları, piyasa eğilimleri, ekonomik göstergeler veya belirli bir makinenin durumu gibi tahminle ilgili ilgili geçmiş verileri toplamayı içerir. Doğru, güvenilir ve güncel olan geçmiş veriler zaten mevcutsa, mümkün olan en iyi tahmini elde etmek için en uygun veri kümelerini belirleme meselesidir,
3. Bir tahmin yöntemi seçin: Uygun tahmin yöntemi yalnızca iş durumu veya metrik için değil, aynı zamanda mevcut belirli değişkenler, varsayımlar, hedefler ve veri kümeleri için de seçilir. Nitel yöntemler (uzman görüşü gibi) ve nicel yöntemler (istatistiksel modeller ve algoritmalar gibi) dahil olmak üzere farklı yöntemler vardır,
4. Veri Analizi ve Tahmin Oluşturma: Veri analizi, verileri incelemek ve kalıpları, eğilimleri veya ilişkileri belirlemek için seçilen yöntem kullanılarak gerçekleştirilir. Bu analiz, gelecekteki olaylar veya sonuçlar hakkında bilgilendirilmiş tahminler yapılmasını sağlar,
5. Tahmini yapın: Analizinize dayanarak, gelecekte ne olabileceği hakkında eğitimli tahminlerde bulunun. Tahminlerinizi yaparken tahminin sınırlamalarını ve geleceğin belirsizliğini aklınızda bulundurun,
6. Tahmini doğrulayın: Tahminler, doğruluklarını değerlendirmek için gerçek sonuçlarla veya geçmiş verilerle doğrulanır. Bu adım, tahmin sürecindeki herhangi bir sorunu veya yanlışlığı belirlemeye ve gelecekte daha doğru tahminler oluşturmak için herhangi bir iyileştirme yapılıp yapılamayacağını belirlemeye yardımcı olur,
7. Gözden geçirin ve ayarlayın: Tahminlerinizi düzenli olarak gözden geçirin ve yeni bilgiler mevcut oldukça veya koşullar değiştikçe güncelleyin. Esnek kalın ve tahminlerinizi ve planlarınızı gerektiği gibi değiştirmeye hazır olun.



Şekil 2. 31. Tahmin Sürecindeki Adımlar

2.2.3. Tahmin Teknikleri

Tahmin teknikleri, işletmelerin ve yöneticilerin gelecek hakkında bilinçli kararlar almaları için önemli araçlardır. Bu teknikleri kullanarak, gelecekteki eğilimleri öngörebilir ve uzun vadeli başarı için planlar geliştirebilirsiniz. Tahmin çeşitli şekillerde gerçekleştirilebilir ve bu yöntemler iki temel tekniğe ayrılabilir: nitel tahmin ve nicel tahmin [217, 220, 221].

2.2.3.1. Nitel Tahmin

Nitel tahmin, tüketici görüşleri, uzman görüşleri ve üst düzey yöneticilerin görüşleri de dahil olmak üzere insan yargısına dayanır. Bu tahmin yöntemi, nitel bilgileri nicel verilere dönüştürmenin sistematik bir yolu olarak bir derecelendirme mekanizmasına uygulanır.

1. Panel Konsensüs Yöntemi: Bir grup görüş arasında bir fikir birliğine varmak veya en iyi eylem yolunu belirlemek için kullanılan bir tekniktir, belirli bir ilgili konuda deneyim ve bilgiye sahip bir grup uzmanın bir araya gelerek görüş ve deneyimlerini danışması ve paylaşması esasına dayanır, bu komite ele alınması gereken bir sorunu ele almak için oluşturulur. Komitenin her üyesinin deneyim ve bilgilerine dayalı olarak kendi görüşlerini ve kişisel önerilerini sunmasıyla

başlar. Daha sonra, komitenin farklı görüşleri tartışılarak en iyi yolun belirlenmesi ve üzerinde bir anlaşmaya varılır. Bu teknik, kamu politikası, işletme yönetimi, sağlık hizmetleri ve çok sayıda başka uzmanlık alanı dahil olmak üzere çeşitli alanlarda uygulanır. Çok miktarda seri verinin olmadığı alanlarda. Bu teknik, soruna net bir çözüm olmadığı ve birden fazla bakış açısının dikkate alınması gereken durumlarda özellikle yararlıdır,

2. Delphi Tekniği: Bir grup uzman, Delphi Tekniğinin bir parçası olarak belirli bir konu veya konu hakkında düşüncelerini ve fikirlerini sunar, bir karar alma sürecidir. Bu stratejinin amacı, bir eylem planı üzerinde fikir birliğine varmak için organize ve yinelemeli bir süreç kullanmaktır. Bu senaryoda, bir grup uzmana bir kolaylaştırıcı tarafından bir sorun veya soru sunulur ve düşüncelerini ve önerilerini paylaşırlar. Yanıtları topladıktan sonra, kolaylaştırıcı bunları anonim olarak gruba iletir. Yanıtları inceledikten sonra, uzmanlar yorum, düzenleme veya eklemeler sağlar. Bir anlaşmaya varılana kadar, bu prosedür tekrarlanır,
3. Morfolojik Analiz: "Morfolojik analiz" olarak bilinen sorunları ele alma tekniği, karmaşık bir sorunu veya sistemi daha küçük parçalara veya "morfolojik değişkenlere" ayırmaktır. Bundan sonra, olası düzeltmeleri veya stratejileri bulmak için bu faktörler incelenir. Sistemde soruna neden olan faktörleri belirlemek için önce bir grup uzman veya paydaş bir araya getirilir. Teknoloji, insan davranışı veya çevre koşulları gibi faktörleri içerebilen bu değişkenler, beyin fırtınası veya diğer yöntemlerle tanımlanabilir,
4. Tarihsel Analoji: Tarihsel Analoji, geçmişteki olayları veya durumları şimdiki veya gelecekteki olaylarla karşılaştırmayı içeren bir akıl yürütme yöntemidir. Bu yöntem, geçmişteki benzer olayları veya durumları inceleyerek güncel olaylar hakkında fikir edinmek veya gelecekteki olaylar hakkında tahminlerde bulunmak için kullanılır. Tarihsel analojinin öncülü, tarihin kendini tekrar ettiği ve geçmiş olayları inceleyerek bu olaylara yol açan faktörleri ve benzer durumlarda nasıl ortaya çıkabileceklerini anlayabileceğimizdir. Örneğin, siyasi analistler belirli bir ülkedeki mevcut siyasi iklimi anlamak için 1930'larda Avrupa'da faşizmin yükselişinden bir analoji çıkarabilirler.

Nitel tahminin avantajları ve sınırlamaları

Nitel tahminin şu avantajları vardır:

1. Veriler sınırlı olduğunda, örneğin yeni ürün veya teknolojilerin pazar kabul oranını veya pazar penetrasyon oranını değerlendirirken kullanılabilir,
2. İşletme ve teklifleri hakkında oldukça bilgili uzmanlardan ve kişilerden gelen bilgileri, nicel verilerin yakalaması pek olası olmayan şekilde entegre eder,
3. Genellikle kriz veya felaket gibi tek seferlik olaylar veya atipik senaryolar olarak düşünülebilir. Bu, nitel tahminin koşulların sürekli değiştiği durumlar için uygun bir seçenek olabileceği anlamına gelir.

Yine de, bu tür tahminin dezavantajları da vardır:

1. İnsan yargısına dayandığı için nitel tahmin öznel olabilir ve aşırı vurgulanan veya göz ardı edilen faktörlere ve varsayımlara yol açan önyargıları içerebilir,
2. Nitel bilgiler bazen yalnızca en son olayları veya birinci elden deneyimleri dikkate alabilir, bu nedenle geçmiş verilerden gelen uzun vadeli eğilimler veya kalıplar gözden kaçabilir.

2.2.3.2. Nicel Tahmin

Nicel tahmin, tahminler üretmek için matematiksel modeller ve istatistiksel yöntemler kullanan sayısal verilere dayanır. Birçok nicel tahmin tekniği, süreci bilgilendirmek için veri bilimi, yapay zeka ve makine öğrenimini kullanır. Nicel tahmin, aşağıdaki gibi bir dizi tahmin stratejisini içerir:

Zaman Serisi Analizi

Genellikle sosyal bilimlerde, mühendislikte, ekonomide ve finans alanında kullanılan zamana bağlı, sıralı bir veri analizi tekniğidir. Bu teknik kullanılarak, tarihsel bir veri serisi, trendler, döngüsel bileşenler, mevsimsel bileşenler ve rastgele bileşenler dahil olmak üzere çeşitli bileşenlere ayrılır. Verilerdeki temel kalıpları ve eğilimleri

belirleyebilir ve bir zaman serisini parçalarına ayırarak gelecekteki değerleri tahmin edebiliriz. Mevsimsel bileşen, önceden belirlenmiş bir zaman dilimi içinde meydana gelen tutarlı, tekrarlayan kalıpları gösterirken, trend bileşeni verilerin uzun vadeli ilerlemesini gösterir. Döngüsel bileşen, belirli bir dönemle ilgisi olmayan daha uzun vadeli, düzensiz kalıpları temsil ederken, rastgele bileşen her zaman serisinde bulunan öngörülemeyen, rastgele dalgalanmaları temsil eder.

Zaman serisi tahmini birkaç yöntemi kapsar:

1. Saf. Saf yöntem, bir sonraki dönemin tahmini olarak önceki dönemdeki veri noktasını kullanır. Bu, onu en basit zaman serisi tahmin yöntemi yapar ve genellikle bir ön ölçüt olarak kabul edilir,
2. Basit hareketli ortalama. Basit hareketli ortalama tekniği, son T dönemindeki veri noktalarının ortalamasını hesaplar. Bu ortalama daha sonra bir sonraki dönemin tahmini olarak işlev görür,
3. Ağırlıklı Hareketli Ortalama. Bu yöntem, basit hareketli ortalama tekniğine dayanır, ancak son T döneminin her veri noktasına bir ağırlık uygulanır,
4. Üstel düzeltme. Üstel düzeltme, zaman serisi verilerine üssel olarak ağırlıklı bir ortalama uygulayarak çalışır. Ağırlıklar, veriler eskidikçe üssel olarak azalır; veriler ne kadar yeniyse ağırlığı da o kadar fazla olur. Bir düzeltme katsayısı, bir düzeltme faktörü veya düzeltme parametresi olarak da bilinir, geçmiş ve güncel verilere atanan ağırlıkları kontrol eder. Bu ağırlıklar kullanılarak, ağırlıklı hareketli ortalama hesaplanır ve tahmin olarak işlev görür. Bu tahmin, dalgalanmaları, gürültüyü, aykırı değerleri ve verilerdeki rastgele değişimleri ortadan kaldırarak bir zaman serisinin yumuşatılmış bir versiyonu haline gelir. Üstel yumuşatma genellikle büyük bir veri kümesi gerektirmez ve bu da onu kısa vadeli projeksiyonlar için uygun bir tahmin yöntemi haline getirir. Ayrıca, güncel verilere daha fazla ağırlık verdiği için, üssel yumuşatma yeni veya değişen trendlere hızla uyum sağlayabilir,
5. Mevsimsel endeks. Mevsimsel endeks, mal veya hizmet üretimi veya talebi mevsimlere bağlı olan işletmeler için değerli olabilir.

Ekstrapolasyon

Mevcut verilerde görülen eğilimi, mevcut veri aralığının ötesinde bir değişkenin değerlerini tahmin etmek için genişleten veya yansıtan istatistiksel bir tekniktir. Genellikle ekonomi, finans, mühendislik ve sosyal bilimler gibi disiplinlerde gelecekteki eğilimleri ve kalıpları tahmin etmek için kullanılır. Zaman serisi analizi, üstel düzeltme ve doğrusal regresyon dahil olmak üzere ekstrapolasyon gerçekleştirmek için çeşitli yöntemler vardır. Mevcut verilerde gözlemlenen eğilim, doğası ile birlikte, kullanılacak stratejiyi belirler.

Regresyon Analizi

Regresyon analizi, bir veya daha fazla bağımsız değişken ile bağımlı değişken arasındaki ilişkiyi analiz etmek için kullanılan istatistiksel bir yöntemdir. Bağımlı değişken, tahmin etmek veya açıklamak istediğimiz değişkendir; bağımsız değişkenler ise tahmin veya açıklama yapmak için kullandığımız değişkenlerdir. Bağımlı değişken ile bağımsız değişkenler arasındaki ilişkinin gücünü belirlemek ve ölçmek ve ayrıca bağımsız değişkenlerin değerlerine dayanarak bağımlı değişkenin gelecekteki değerleri hakkında tahminlerde bulunmak için kullanılabilir.

Girdi-Çıktı Analizi

Girdi-Çıktı Analizi, bir ekonominin farklı sektörleri arasındaki karşılıklı bağımlılığı, aralarındaki mal ve hizmet akışlarını inceleyerek analiz etmek için kullanılan bir yöntemdir. Bu yöntem, her ekonomideki üretim, tüketim ve yatırımdaki değişikliklerin ekonomik etkisini ölçmeye yardımcı olur. Girdi-Çıktı Analizinin temel ilkesi, bir ekonominin her sektörünün mal ve hizmet tedariki için diğer sektörlerle bağlı olması ve ayrıca diğer sektörlerle mal ve hizmet sağlamasıdır. Bu karşılıklı bağımlılıklar, bir girdi-çıktı tablosu kullanılarak temsil edilebilen sektörler arasında bir işlem ağı oluşturur.

İşletme Barometreleri


İşletme Barometreleri, bir işletmenin veya endüstrinin genel sağlığını ve performansını ölçmek ve değerlendirmek için kullanılan istatistiksel araçlardır. Bu barometreler, satış rakamları, üretim verileri, istihdam oranları ve tüketici harcama kalıpları gibi çeşitli ekonomik göstergelere dayanır. Bir işletme barometresinin temel amacı, bir işletmenin veya endüstrinin mevcut ve gelecekteki durumu hakkında nesnel ve nicel bir ölçüm sağlamaktır. Bu ekonomik göstergeleri analiz ederek, işletme sahipleri ve yöneticiler operasyonları ve stratejileri hakkında bilinçli kararlar alabilirler.

Nicel tahmin şu avantajları sunar:

1. Sayılara ve matematiğe dayanır, bu da daha nesnel tahminlerle sonuçlanabilir,
2. Belirli zaman dilimleri boyunca analizi kolaylaştırmaya yardımcı olan tutarlı, tekrarlanabilir ve yapılandırılmış çıktılar sağlar.

Bununla birlikte, bu tahmin yaklaşımının bazı tuzakları da vardır:

1. Uzman görüşlerini, içeriden alınan bilgileri ve diğer nitel verileri nicel tahminlerle birleştirmek zordur,
2. Güvenilir tahminler üretmek için yeterli tarihsel veriye ihtiyaç duyar.



Şekil 2. 32. Tahmin Adımları

2.2.4. Tahminlemenin Sınırlamaları

Tahminleme sürecinin bir dizi sınırlaması vardır, bunlardan ilki geleceğin içsel belirsizliği, varsayımlara güvenilmesi ve verilerin potansiyel yanlışlığıdır. Tahminin doğruluğu ve güvenilirliği bu faktörlerden doğrudan etkilenir ve bu nedenle planlama ve karar almada esnek ve uyarlanabilir olmalıdır.

Aşağıda tahminlemenin bazı sınırlamaları verilmiştir:

1. Belirsizlik: Gelecek doğası gereği tahmin edilemez olduğundan, tahmin kesin tahminler sağlayamaz. Öngörülemeyen olaylar veya koşullardaki değişiklikler doğruluklarını önemli ölçüde etkileyebileceğinden, planlama ve karar alma için tahminlere tamamen güvenmek zor olabilir,

2. Yanlış veriler: Kullanılan verilerin kalitesi buna göre belirlenir. Girdi verileri veya geçmiş veriler yanlış veya eksikse üretilen tahminler güvenilir olamaz. Tahminlerin doğruluğunu artırmak dikkatli veri toplama ve analizi gerektirir,
3. Varsayımlar: Varsayımlar geleceği tahmin etmenin doğruluğunu doğrudan etkiler. Bu varsayımlar yanlışsa veya zamanla değişirse tahminler yanlış olabilir. Doğru projeksiyonları sürdürmek için varsayımlar düzenli olarak gözden geçirilmeli ve güncellenmelidir,
4. Karmaşıklık: Algoritmaların doğruluğu istatistiksel modeller ve karmaşık algoritmalar kullanılarak iyileştirilir,
5. Zaman alıcı: Doğru tahminin uzun zaman alması muhtemeldir, rutin olarak toplanan verilerin analizini ve güncellenmesini gerektirir, bu da kuruluş içindeki bazı verileri temel görevlerinden uzaklaştırır ve sonuçta genel verimliliği etkiler,
6. Sınırlı kapsam: Tahminler genellikle dar bir odak noktasına sahiptir ve her olası unsur veya çevresel değişikliği dikkate alamaz. Örneğin, ortaya çıkan rakiplerin veya teknik ilerlemelerin etkilerini öngöremeyebilirler.

2.2.5. Planlama ve Tahmin

Planlama ve tahmin, iş, finans ve ekonomide bilinçli kararlar alma ve geleceğe hazırlanmada önemli bir rol oynayan iki birbiriyle bağlantılı süreçtir. Bu, planlama, hedef belirleme, bu hedeflere ulaşmak için en iyi yaklaşımı belirleme ve kaynakları (zaman, para ve insan) akıllıca kullanma anlamına gelir. Planlama, kuruluşların ve bireylerin öncelikleri belirlemesini, riskleri yönetmesini ve hedeflerine odaklanmasını sağlar. Planlama, söz konusu zaman dilimine bağlı olarak kısa vadeli, orta vadeli veya uzun vadeli olabilir. Aynı zamanda tahmin, geçmiş bilgileri, kalıpları ve istatistiksel çalışmaları kullanarak gelecekteki olaylar veya eğilimler hakkında eğitimli tahminlerde bulunmak anlamına gelir. Olası sonuçlara ilişkin içgörüler sunarak kuruluşların ve bireylerin bilinçli kararlar almasını, riskleri etkili bir şekilde yönetmesini ve geleceğe hazırlanmasını sağlar.

Planlama ve tahmin arasındaki bağlantı, etkili karar alma ve kaynak kullanımı için hayati önem taşır. Tahmin, planlama sürecini yönlendiren gerekli bilgileri ve

öngörülerini sağlar. Sırayla planlama, kuruluşların ve bireylerin önceliklerini belirlemesine ve kaynakları bu tahminlere göre tahsis etmesine yardımcı olur.

Bu nedenle, planlama ve tahminin, kuruluşların ve bireylerin bilinçli kararlar almasını, riskleri etkili bir şekilde yönetmesini ve kaynakları verimli bir şekilde kullanmasını sağlayan birbirine bağlı süreçler olduğu sonucuna varabiliriz. Bu süreçleri birleştirerek, geleceğe daha iyi hazırlanabilir ve değişikliklere uyum sağlayabilirler.



Şekil 2. 33. Tahminin önemi

2.2.6. Üretim ve İşletmede Tahminin Önemi

Tahmin, risk yönetimi, etkili planlama ve bilgili karar alma için elzem olduğu için işletme ve üretim süreçlerinde önemli bir rol oynar. Gelecekteki eğilimleri tahmin

etmelerine, kaynakları etkili bir şekilde tahsis etmelerine ve deęiřen kořullara uyum saęlamalarına yardımcı olarak hem insanların hem de kuruluřların geliřimine ve geniřlemesine katkıda bulunur.

Tahmin, ařaęıdakiler gibi bir dizi önemli karara katkıda bulunur:

1. Karar alma: Tahmin, bireylerin ve kuruluřların bilgili ve kritik kararlar almasını saęlamada önemli bir rol oynar. Gelecek vizyonu, karar almaya bilgi veren öngörülen olaylara ve eğilimlere dayanarak oluřturulur ve olası sonuçlar ve mevcut bilgiler dikkate alınarak řirketler ve bireyler en iyi yolu ve seęimleri belirler.
2. Kaynak tahsisi: řirketlerin zamanlarını, fonlarını ve iř güçlerini etkili bir şekilde tahsis etmelerine yardımcı olur. řirketler, gelecekteki pazar kořullarını veya talebi tahmin ederek rekabetçi kalmak ve müşteri taleplerini karřılamak için bütçelerini, iř gücü seviyelerini ve üretim kapasitelerini ayarlayabilirler.
3. Risk yönetimi: Herhangi bir iřletme veya kuruluř için potansiyel belirsizlikleri ve riskleri belirlemek elzemdir. İřletmeler, tahminleri kullanarak tedarik zinciri kesintileri, tüketici talebindeki deęiřimler ve ekonomik gerilemeler gibi olası kesintileri öngörebilirler. Kuruluřlar, bu risklerin farkında olarak olumsuz etkileri en aza indirmek için acil durum planları ve önlemleri oluřturabilirler.
4. Hedefler ve amaçlar belirleme: Kuruluřlar ve bireyler için gerçekte ve ulařılabilir hedefler belirlemek, operasyonları için doęru yolda kalmalarına yardımcı olur. Ulařılabilir hedefler belirlemek ve gelecekteki olayları tahmin ederek zaman içindeki ilerlemelerini ölçmek, hedeflerine ulařma yolunda kalmalarına yardımcı olur.
5. Bütçeleme ve finansal planlama: Finansal operasyonlar, finansal planlamada doęrulukları açısından büyük önem taşıyan tahminlere baęlıdır. Maliyetleri, giderleri, gelirleri ve nakit akıřlarını tahmin etmede önemli bir rol oynarlar. Bu tahminlere dayanarak, bütçelerin büyüklüęü, kaynak yönetimi ve geleceęe yönelik planlama daha doęru ve etkili bir şekilde belirlenir.
6. Tedarik Zinciri Yönetimi: Arz ve talep arasındaki uygun dengeyi korumak için, tedarik zinciri yönetimi ortamında tahmin yapmak çok önemlidir. İřletmeler, doęru talep projeksiyonları yardımıyla envanter seviyelerini optimize ederek,

elde tutma maliyetlerini en aza indirerek ve stok tükennmelerini azaltarak müşteri memnuniyetini artırabilir ve tedarik zinciri verimliliğini iyileştirebilir.

2.3. YAPAY ZEKA ve TAHMİN

Yapay Zeka tahmini, zaman serisi tahmini ve regresyon modelleri gibi niceliksel tahmin yöntemlerini uygulamak için AI ve makine öğrenimi algoritmalarını kullanır. AI tahmini, büyük miktarda veriyi işleyebilir, hızlı hesaplamalar yapabilir, karmaşık tahminleri ele alabilir ve korelasyonları hızla ortaya çıkarabilir [220].

AI tahmini, makine öğrenimi modelleri ve tekniklerinin bir kombinasyonunu kullanır.

1. Karar ağaçları
2. Derin öğrenme
3. Tahmin performansını iyileştirmek için birden fazla öğreneni birleştiren topluluk öğrenimi
4. KNN (k-en yakın komşular) algoritması
5. Sinir ağları

AI tahmini kullanılırken, modelin organizasyonun tahmin hedefleriyle uyumu değerlendirilir ve performansı düzenli olarak izlenerek yeni veriler üzerinde yeniden eğitilmesi veya performansını iyileştirmek için ayarlanması gerekıp gerekmediği belirlenir.

Ayrıca, tüm paydaşların tahminlerin nasıl yapıldığını ve nasıl yorumlanacağını anlayabilmesi için modelin yorumlanabilir olup olmadığı da dikkate alınır.

2.3.1. AI Tahmin Uygulamaları

2.3.1.1. Finansal Planlama

Kuruluşlar, gelecekteki maliyetleri, geliri ve diğer finansal sonuçları tahmin etmek için tahminden yararlanabilir ve böylece bütçeleme ve yatırım kararlarını bilgilendirebilir.

Finansal planlamada, tahmin yalnızca bir işletmenin mevcut durumunu değil aynı zamanda ekonomik koşullar gibi dış faktörleri de dikkate alır.

2.3.1.2. Üretim Planlaması

Üretim şirketleri, üretim planlamalarını geliştirmek için tahminden yararlanır. Tahmin yazılımı, üretim hacmi ve talebi gibi çeşitli amaçlar için tahminleri düzenli olarak güncellemek ve olası gelecekteki arızaları belirlemek için kullanılır. Üretim kontrolörleri ayrıca programları önceliklendirmek, iş yüklerini dengelemek, üretimi optimize etmek ve hataları azaltmak için günlük veya gerçek zamanlı tahminler kullanır.


2.3.1.3. Satış Tahmini

Hem nitel hem de nicel teknikler, gelecekteki satışları, satış büyüme oranlarını ve diğer satış rakamlarını tahmin etmek için uygulanabilir. Regresyon modelleri ayrıca ekonomik koşullar, pazarlama harcamaları ve satışlar arasındaki ilişkiyi analiz etmek için de kullanılabilir.

2.3.1.4. Tedarik Zinciri Tahmini

Tahmin yöntemleri, tedarik zincirinin yönetilmesine yardımcı olmak ve doğru ürünlerin planlanan varış noktalarına zamanında ulaşmasını sağlamak için kullanılabilir.

Tahminin Uygulanması



Şekil 2. 34. En Popüler Tahmin Uygulamalarından Bazıları

2.3.2. Tahmin Yazılımı

Tahmin yazılımı, birden fazla kaynaktan gelen verilerin entegrasyonu ve çeşitli değişkenler arasındaki etkileşimlerin analizi dahil olmak üzere gelişmiş özellikler sunar. Bu araçlar, işletmelerin güvenilir tahminler geliştirmesine ve tahmin modellerini ve simülasyonlarını verimli bir şekilde güncellemesine ve yönetmesine yardımcı olabilir. Diğer tahmin araçları ayrıca iş akışlarını otomatikleştirmek, doğruluğu artırmak ve süreci hızlandırmak için yerleşik AI yeteneklerine sahiptir [221].

Yapay Zeka (AI), planlama, fizibilite çalışmaları, deşarj tahmini, enerji üretimi tahmini ve bakım planlamasında kullanılabilir. AI, aşağıdaki alt bölümlere ayrılabilir.

2.3.2.1. Makine Öğrenimi

Makine Öğrenimi, gerçek dünya sorunlarını çözmek için verileri algılamak, işlemek ve analiz etmek için bilgisayarların bir uygulamasıdır. Verilerden bilgi 'öğrenmek' için hesaplama yöntemlerini kullanır. Öğrenme için örnek sayısını artırmak performansı

artırır. İki tür öğrenme vardır, denetlenen ve denetlenmeyen öğrenme. Gözetimli öğrenme, bilinen girdi ve çıktı verilerine dayanarak gelecekteki etkileri tahmin etmek için bir modeli eğitirken, gözetimsiz öğrenme bilinen girdi verilerindeki gizli kalıpları keşfeder.

2.3.2.2. Derin Öğrenme

Daha karmaşık sorunları çözmek için içgörüler elde etmek amacıyla yüksek boyutlu verileri uygulama sürecidir. Derin öğrenme, bir modelin sınıflandırma görevlerini gerçekleştirmek için doğrudan görüntülerden, metinden veya sestten öğrendiği bir makine öğrenmesi türüdür. Derin öğrenme, genellikle bir sinir ağının mimarisi kullanılarak gerçekleştirilir. "Derin" terimi, ağdaki katman sayısını ifade eder.

2.3.2.3. Yapay Sinir Ağı (YSA)

Tipik bir yapay nöron ağı yapılandırması, gösterilmiştir; burada girişler X_n , ağırlıklarını (W_n) çarparak $W_n X_n$ ürününü üreten nöronlara bağlanır. Daha sonra tüm ağırlıklı girdiler toplanır. Sonuç, transfer fonksiyonunun (f) argümanıdır. En yaygın YSA mimarileri bir giriş katmanından ve bir çıkış katmanından oluşurken, bir çıktı üretmek için birden fazla gizli katman kullanılır. Genellikle girdiyi çıktıya eşleyerek başlar. Girdilerin uygun çıktılara eşlenmesi, girdi ve çıktı arasındaki uygun bahşiş sayısının belirlenmesini gerektirir.

2.3.3. Sinir Ağı ve Tahmin

Sinir ağı (yapay sinir ağı veya sinir ağı, kısaltılmış ANN veya NN), insan beynindeki biyolojik sinir ağlarının yapısı ve işlevinden esinlenen bir makine öğrenme programı veya modelidir ve biyolojik nöronların fenomenleri tanımlamak, seçenekleri değerlendirmek ve sonuçlara ulaşmak için birlikte çalışma şeklini taklit eden süreçleri kullanarak insan beyni gibi kararlar alır.

Her sinir ağı, düğüm katmanlarından veya yapay nöronlardan oluşur; bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı. Her düğüm diğerlerine bağlanır

ve ilişkili ağırlığı ve eşiği vardır. Herhangi bir bireysel düğümün çıktısı belirtilen eşik değerinin üzerindeyse, bu düğüm etkinleştirilir ve verileri ağına bir sonraki katmanına gönderir. Aksi takdirde, ağına bir sonraki katmanına hiçbir veri iletilmez.

Sinir ağları, zamanla öğrenmek ve doğruluklarını artırmak için eğitim verilerine güvenir. Doğruluk açısından ince ayar yapıldıktan sonra, bilgisayar bilimi ve yapay zekada güçlü araçlar haline gelirler ve verileri yüksek hızda sınıflandırmalarını ve kümelemelerini sağlarlar. Konuşma tanıma veya görüntü tanıma görevleri, insan uzmanların manuel tanımlamasına kıyasla saatler yerine dakikalar sürebilir.

Yapay sinir ağları, yapay zekada öngörücü modelleme, uyarlanabilir kontrol ve problem çözme dahil olmak üzere çeşitli görevler için kullanılır. Deneyimden öğrenebilir ve karmaşık ve görünüşte ilgisiz bir bilgi kümesinden sonuçlar çıkarabilir. Sinir ağları bazen yapay sinir ağları (YSA) veya simüle edilmiş sinir ağları (SNN) olarak adlandırılır. Bunlar makine öğreniminin bir alt kümesidir ve derin öğrenme modellerinin merkezinde yer alır.

Yapay sinir ağları ayrıca girdi ve çıktı desenlerinin karmaşık ilişkilere sahip olduğu durumlarda kullanılabilen doğrusal olmayan modelleme araçları olarak da tanımlanır. Bunlar şu şekilde tanımlanabilir:


Mimari, nöronları (düğümüleri) arasındaki bağlantı türüdür; eğitim Algoritması, her düğümle ilişkili ağırlığı hesaplama metodolojisidir ve son olarak aktivasyon fonksiyonlarının türleridir. Biyolojik ve yapay ağlar arasında birçok fark vardır. Genel olarak, "yapay sinir ağları" fiziksel, biyolojik sistemlerden ziyade yazılım tabanlı algoritmaları ve sabit kablolu yapıları ifade eder.

2.3.4. Sinir Ağları ve Derin Öğrenme

Derin Öğrenme ve sinir ağları, konuşmalarda sıklıkla birbirinin yerine kullanılır ve bu kafa karıştırıcı olabilir. Sonuç olarak, derin öğrenmedeki "derin" teriminin bir sinir ağındaki katmanların derinliğini ifade ettiğini belirtmekte fayda var. Girişler ve çıktılar dahil olmak üzere üçten fazla katmandan oluşan bir sinir ağı, derin öğrenme

algoritması olarak kabul edilebilir. Sadece iki veya üç katmandan oluşan bir sinir ağı, temel bir sinir ağı olarak kabul edilir.

Derin sinir ağı



Şekil 2. 35. Derin sinir ağları

Sinir Ağlarının Tarihi

Sinir ağlarının tarihi çoğu insanın düşündüğünden daha uzundur. "Düşünen bir makine" fikri Antik Yunanlılara kadar uzansa da, yıllar içinde popülerliği azalıp artan sinir ağları etrafındaki düşüncenin evrimine yol açan temel olaylara odaklanacağız:

1. 1943: Warren S. McCulloch ve Walter Pitts "Sinirsel aktiviteye içkin fikirlerin mantıksal hesaplaması"nı yayınladı (bağlantı ibm.com dışındadır). Bu araştırma, insan beyninin birbirine bağlı beyin hücreleri veya nöronlar aracılığıyla karmaşık desenleri nasıl ürettiğini anlamaya yönelikti. Bu çalışmadan elde edilen temel içgörülerden biri, ikili eşikli nöronların Boole mantığına, özellikle 0/1 veya doğru/yanlış ifadelerine karşılaştırılmasıydı.
2. 1958: Frank Rosenblatt, "Perceptron: Beyinde Bilgi Depolama ve Organizasyonu için Olasılıksal Bir Model" (bağlantı ibm.com dışındadır) adlı araştırmasında belgelenen algılayıcının geliştirilmesiyle tanınır. McCulloch ve Pitt'in çalışmalarını bir adım öteye taşıyarak denkleme ağırlıklar ekler. Bir IBM

704'ten yararlanan Rosenblatt, bir bilgisayarın sol tarafta işaretlenen kartlarla sağ tarafta işaretlenen kartları nasıl ayırt edeceğini öğrenmesini sağladı.

3. 1974: Çok sayıda araştırmacı geri yayılım fikrine katkıda bulunurken, Paul Werbos, doktora tezinde (bağlantı ibm.com dışındadır) sinir ağları içindeki uygulamasını belirten ABD'deki ilk kişiydi.
4. 1989: Yann LeCun, geri yayılımda kısıtlamaların kullanımının ve sinir ağı mimarisine entegrasyonunun algoritmaları eğitmek için nasıl kullanılabileceğini gösteren bir makale yayınladı (bağlantı ibm.com dışındadır). Bu araştırma, ABD Posta Servisi tarafından sağlanan el yazısıyla yazılmış posta kodu rakamlarını tanımak için bir sinir ağını başarıyla kullandı.

2.4. TEKRARLAYAN SİNİR AĞI ve LSTM


Tekrarlayan sinir ağı (RNN), ardışık veri girişlerini belirli ardışık veri çıktılarına dönüştürmek ve işlemek üzere eğitilmiş derin öğrenme modelidir. Bu tür sinir ağı, ardışık bileşenlerin karmaşık semantik ve sözdizimi kurallarına göre birbirine bağlandığı ardışık verileri işleme konusunda uzmanlaşmıştır. İleri beslemeli ağlardan türetilen bu ağlar, insan beyinlerinin çalışma şekline benzer davranışlar sergiler. RNN'ler, insanların ardışık veri dönüşümlerini nasıl gerçekleştirdiğini taklit eden birçok birbirine bağlı bileşenden oluşan yazılım sistemleridir [53, 54, 55].

RNN'ler büyük ölçüde, ardışık verileri işlemede daha verimli olan dönüştürücü tabanlı yapay zeka (AI) ve büyük dil modelleri (LLM'ler) ile değiştirilmektedir. Bu ağlar, diğer algoritmaların üretemediği ardışık verilerde tahmin edici sonuçlar üretmesiyle karakterize edilir; bu, güçlü ve sağlam bir sinir ağı türüdür ve kullanılan en umut verici algoritmalarından biridir çünkü aldığı girdilerin dahili belleğindeki girdileri hatırlamasını sağlayan dahili bir belleğe sahip olan tek sinir ağı türüdür ve tahminlerinde çok doğru olmasını sağlar. Bu nedenle, zaman serisi, konuşma, metin, finansal veriler, ses, video, hava durumu ve diğer birçok veri türü gibi ardışık veriler için tercih edilen algoritmadır. Tekrarlayan sinir ağları, dizi ve bağlamı hakkında diğer algoritmalarından çok daha derin bir anlayış oluşturabilir [224].

Tekrarlayan sinir ağıları, Siri ve Google Translate dahil olmak üzere günlük yaşamın çeşitli yönlerinde ve elektrik üretimi, sinyal işleme ve fiyat tahmini gibi tahmin uygulamalarında kullanılır. RNN algoritmaları, çeşitli alanlarda ve derin öğrenme uygulamalarında birçok dikkate değer başarının arkasındadır.

2.4.1. Tekrarlayan Sinir Ağı Mimarisi

RNN'ler, karmaşık görevleri gerçekleştirmek için birlikte çalışan nöronlardan ve veri işleme düğümlerinden oluşur. Nöronlar, giriş, çıkış ve gizli katmanlar halinde düzenlenir. Giriş katmanı işlenecek bilgileri alır ve çıkış katmanı sonucu sağlar. Veri işleme, analiz ve tahmin gizli katmanda gerçekleşir [224].



Şekil 2. 36. Bir RNN'nin diyagramını gösterir.

Gizli Katman

RNN'ler, aldıkları ardışık verileri gizli katmanlara adım adım ileterek çalışır. Ancak, aynı zamanda kendi kendini döngüleyen veya tekrarlayan bir iş akışına da sahiptirler: gizli katman, kısa süreli bellek bileşeninde gelecekteki tahminler için önceki girdileri

hatırlayabilir ve kullanabilir. Bir sonraki diziyi tahmin etmek için geçerli girişı ve depolanan belleęi kullanır [222].

2.4.2. Tekrarlayan Sinir Ağlarının Çalışma Prensibi


RNN'ler, "düzenli" ileri beslemeli sinir ağları ve ardışık veriler kavramı üzerinde çalışır. Sıralı veriler, esasen finansal veriler, bir makinedeki sıralı değişkenler veya DNA dizileri gibi ilgili öğelerin birbirini takip ettięi sıralı verilerdir. Sıralı verilerin en yaygın türü, kronolojik sırayla listelenen bir dizi veri noktası olan zaman serisi verileridir [224].

2.4.3. Tekrarlayan Sinir Aęı ve Evrişimli Sinir Ağları

Evrişimli sinir ağları, mekansal verileri işlemek için tasarlanmış bir yapay sinir aęı türüdür. Evrişimli sinir ağları, sinir aęındaki bir dizi evrişimli ve birleştirilmiş katmandan geçirilerek videolardan ve görüntülerden mekansal bilgi çıkarmak için kullanılabilir. RNN'ler, sıralı verilerdeki uzun vadeli baęımlılıkları yakalamak için tasarlanmıştır [222]. Tipik bir RNN, solma olarak bilinen bir unutmaya eğilimli olan kısa vadeli belleęe sahiptir. Tipik bir ileri beslemeli sinir aęı, "nöron" kelimesi verildiğinde, kelimeyi harf harf işler ve "r" harfine geldiğinde, "n", "e" ve "u" harflerini çoktan unutmuş olur; bu da bu tür sinir aęının bir sonraki harfin ne olacağını tahmin etmesini neredeyse imkansız hale getirir.

2.4.4. Tekrarlayan Sinir Aęı ve İleri Beslemeli Sinir Aęı


İleri beslemeli sinir ağları, bilgiyi mimarının bir ucundan diğerine ileten yapay sinir ağlarıdır. Bilgi yalnızca bir yönde hareket eder - giriş katmanından, gizli katmanlardan geçerek çıktı katmanına. Bilgi doğrudan aę üzerinden geçer.



Şekil 2. 37. Tekrarlayan Sinir Ağı

İleri beslemeli bir sinir ağı basit sınıflandırma, regresyon veya tanıma görevleri gerçekleştirir, ancak işlediği önceki girdileri hatırlayamaz. Aldığı girdilerin hafızası yoktur ve bu nedenle tahmin etmede kötüdür. İleri beslemeli bir ağ yalnızca geçerli girdiyi dikkate aldığından, o anki sistem hakkında bilgi eksikliği vardır. Geçmişte ne olduğu hakkında eğitimi dışında hiçbir şey hatırlayamaz [222].

Bir RNN karar verdiğinde, bilgi hem geçerli girdiyi hem de önceki girdilerden öğrendiklerini hesaba katarak bir döngüde dolaşır. Aşağıdaki iki resim, tekrarlayan bir sinir ağı (RNN) ile ileri beslemeli bir sinir ağı arasındaki bilgi akışındaki farkı göstermektedir. RNN'ler ve ileri beslemeli sinir ağları, adlarını bilgileri yönlendirme şekillerinden alırlar.



Şekil 2. 38. Tekrarlayan Sinir Ağı ve İleri Beslemeli Sinir Ağı

Normal bir RNN, bir LSTM entegre edilerek artırılmış ve güçlendirilmiş kısa süreli bir belleğe sahiptir ve ayrıca uzun süreli bir belleğe sahiptir. Normal bir sinir ağının belleği, girdi olarak birkaç harften (beş harf) oluşan belirli bir kelime verildiğinde, kelimenin harflerini tek tek işleyen normal bir ileri beslemeli sinir ağı ilkesine göre çalışır. "Dördüncü" harfe ulaştığında, kendisinden önceki harfleri çoktan unutmuş olur ve bu da bu tür bir sinir ağının bir sonraki harfi tahmin etmesini neredeyse imkansız hale getirir. Ancak, tekrarlayan bir sinir ağı, dahili belleği sayesinde bu harfleri hatırlayabilir. Bir çıktı üretir, bu çıktıyı kopyalar ve ağı geri iletir. Basitçe söylemek gerekirse, tekrarlayan sinir ağları yakın geçmiş bugüne dahil eder [224].

Bu nedenle, bir RNN'nin iki girdisi vardır: şimdiki zaman ve yakın geçmiş. Bu önemlidir çünkü veri dizisi, bundan sonra ne olacağı hakkında önemli bilgiler içerir, bu nedenle bir RNN diğer algoritmaların yapamadığı görevleri gerçekleştirebilir. İleri beslemeli bir sinir ağı, diğer tüm derin öğrenme algoritmaları gibi girdilerine bir ağırlık matrisi atar ve ardından bir çıktı üretir. RNN'lerin akışa ve önceki girdiye ağırlık uyguladığını unutmayın. Dahası, yinelemeli sinir ağı, zaman içinde hem eğitim inişi hem de geri yayılım için ağırlıkları ayarlayacaktır.


2.4.5. Eğitim

Makine öğrenimi (ML) mühendisleri, model eğitim verilerini besleyerek ve performansını iyileştirerek tekrarlayan sinir ağları (RNN'ler) gibi derin sinir ağlarını eğitir. Makine öğreniminde (ML), nöronun ağırlıkları, eğitim sırasında öğrenilen bilgilerin çıktının tahmini üzerindeki etkisini belirlemek için sinyal görevi görür. RNN'deki her katman aynı ağırlıkları paylaşır.

ML mühendisleri ayrıca tahmin doğruluğunu artırmak için ağırlıkları ayarlar. Modelin hatasını hesaplamak ve ağırlıklarını buna göre ayarlamak için zaman içinde geri yayılım (BPTT) adı verilen bir teknik kullanırlar. BPTT, çıktıyı önceki zaman adımına geri döndürür ve hata oranını yeniden hesaplar. Bu şekilde, dizideki büyük bir hataya neden olan gizli durum tanımlanabilir ve ağırlıklar hata payını azaltmak için yeniden ayarlanabilir [222].

2.4.6. Tekrarlayan Sinir Ağları Türleri

Tekrarlayan sinir ağlarının ana türleri arasında bire bir, bire çok, çoktan bire ve çoktan çokça mimariler bulunur. İleri beslemeli sinir ağları bir girişi bir çıktıya eşlerken, RNN'ler birden çokça, çoktan çokça (çeviri için kullanılır) ve çoktan bire (ses sınıflandırması için kullanılır) eşleyebilir [225].



Şekil 2. 39. Tekrarlayan Sinir Ağlarının Ana Türleri

2.1.1.1. Bire Bir

Bire bir RNN modelleri bir girdi ve bir çıktıya sahiptir. Vanilya sinir ağı olarak da bilinen bire bir mimari, geleneksel sinir ağlarında ve görüntü sınıflandırması gibi genel makine öğrenimi görevlerinde kullanılır.

2.1.1.2. Bire Çok

Bire çok RNN'lerin bir girdisi ve birkaç çıktısı vardır. Bu, tek bir girdi (anahtar kelime gibi) kullanarak birden fazla çıktı (cümle veya paragraf gibi) ürettiği için görüntü altıyazısı veya müzik oluşturma yeteneklerini etkinleştirir.

2.1.1.3. Çoktan Bire

Çoktan bire modelin birden fazla girdisi ve tek bir çıktısı vardır. Duygu analizi veya metin sınıflandırması gibi görevler genellikle çoktan bire mimarileri kullanır. Örneğin, bir girdi dizisi (bir cümle gibi) tek bir kategoriye sınıflandırılabilir (örneğin, cümlenin olumlu mu yoksa olumsuz bir duyguyu mu ifade ettiği).

2.1.1.4. Çoktan Çoğa

Çoktan çoğa modeller, çeşitli girdileri çeşitli çıktılara eşler. Makine çevirisi ve isim varlık tanıma, birden çok sözcük veya cümlenin birden çok farklı çıktıya (yeni bir dil veya çeşitli kategoriler gibi) yapılandırılabilirdiği çoktan çoğa RNN'ler tarafından desteklenir.

2.4.7. Tekrarlayan Sinir Ağlarının Avantajları

Tekrarlayan sinir ağlarının avantajları, tüm zorlukları gölgede bırakır. İşte RNN'lerin makine öğrenimi inovasyonunu hızlandırmasının birkaç nedeni:

1. Kapsamlı bellek: RNN'ler önceki girdileri ve çıktıları hatırlayabilir ve bu yetenek LSTM ağlarının yardımıyla geliştirilir.
2. Daha fazla doğruluk: RNN'ler geçmiş deneyimlerden öğrenebildikleri için doğru tahminlerde bulunabilirler.
3. Sıralı veri uzmanlığı: RNN'ler verilerin zamansal yönünü anlar ve bu da onları sıralı verileri işlemek için ideal hale getirir.
4. Geniş çok yönlülük: RNN'ler zaman serisi, ses ve konuşma gibi sıralı verileri işleyebilir ve bu da onlara çok çeşitli uygulamalar sunar.

2.4.8. Tekrarlayan Sinir Ağlarının Zorlukları

RNN'ler derin öğrenme alanında fark yaratan bir unsur olsa da, akılda tutulması gereken bazı sorunlar vardır:


1. Patlayan eğimler: Bu, algoritmanın çok fazla sebep olmaksızın ağırlıklara aptalca yüksek bir önem vermesidir. Neyse ki, bu sorun eğimleri keserek veya ezerek kolayca çözülebilir.
2. Kaybolan eğimler: Bunlar, bir eğimin değerleri çok küçük olduğunda ve model öğrenmeyi bıraktığında veya sonuç olarak çok uzun sürdüğünde meydana gelir. Neyse ki, bu Sepp Hochreiter ve Juergen Schmidhuber tarafından LSTM kavramıyla çözüldü.
3. Karmaşık eğitim süreci: RNN'ler verileri sırayla işlediğinden, bu sıkıcı bir eğitim sürecine yol açabilir.
4. Uzun dizilerle ilgili zorluk: Dizi ne kadar uzun olursa, RNN'lerin geçmiş bilgileri hatırlamak için o kadar çok çalışması gerekir.
5. Verimsiz yöntemler: RNN'ler verileri sırayla işler, bu da yavaş ve verimsiz bir yaklaşım olabilir.

2.4.9. Tekrarlayan Sinir Ağlarında Zaman İçinde Geri Yayılım

Sinir ağlarında, modelin çıktısını almak için ileri yayılım yaparsınız ve hatayı almak için bu çıktının doğru mu yanlış mı olduğunu kontrol edersiniz. Geri yayılım, ağırlıklara göre hatanın kısmi türevlerini bulmak için sinir ağında geriye doğru gitmekten başka bir şey değildir, bu da bu değeri ağırlıklardan çıkarmanıza olanak tanır.

Bu türevler daha sonra belirli bir işlevi yinelemeli olarak en aza indirebilen bir algoritma olan gradyan inişi tarafından kullanılır. Daha sonra hatayı en aza indirmek için ağırlıkları yukarı veya aşağı ayarlar. Bir sinir ağının eğitim süreci sırasında öğrenmesi tam olarak böyledir [226].


Geri yayılımla, eğitim sırasında modelin ağırlıklarını ayarlamaya çalışırsınız. Aşağıdaki resim, ileri beslemeli bir sinir ağında ileri yayılım ve geri yayılım kavramını göstermektedir:



Şekil 2. 40. Gelişmiş bir sinir ağında yayılma ve yayılma kavramı

BPTT, esasen açılmamış yinelemeli sinir ağında geri yayılım gerçekleştirmek için kullanılan süslü bir terimdir. Açma, ağı içinde neler olduğunu anlamana yardımcı olan bir görselleştirme ve kavramsal araçtır. Çoğu zaman, popüler programlama çerçevelerinde yinelemeli bir sinir ağı uygularken, geri yayılım otomatik olarak işlenir. Geliştirme süreci sırasında ortaya çıkabilecek sorunları gidermek için, RNN'yi geri yayılım kullanarak sırayla eğittiğiniz bir dizi sinir ağı olarak görebilirsiniz.

Aşağıdaki görüntü, açılmamış bir RNN'yi göstermektedir. Solda, RNN eşittir işaretinden sonra açılır. Eşittir işaretinden sonra bir döngü olmadığını, farklı zaman adımları görselleştirildiğini ve bilginin bir zaman adımından diğerine aktarıldığını fark edin. Bu çizim ayrıca bir RNN'nin neden bir dizi sinir ağı olarak görülebileceğini de göstermektedir.



Şekil 2. 41. Resimde Açılmamış Bir RNN Gösterilmektedir

BPTT gerçekleştirirseniz, belirli bir zaman adımının hatası önceki zaman adımının hatasına bağlı olduğundan, açmayı kavramsallaştırmanız gerekir. BPTT içinde, tüm zaman adımları açılırken hata sondan ilk zaman adımına geri yayılır. Bu, her zaman adımı için hatanın hesaplanmasını sağlar ve bu da ağırlıkların güncellenmesini sağlar. Çok sayıda zaman adımı söz konusu olduğunda BPTT'nin hesaplama açısından pahalı olabileceğini unutmayın.

2.4.10. Uzun Kısa Süreli Bellek (LSTM)

Uzun Kısa Süreli Bellek (LSTM) ağı 1997'de önerildi. LSTM, geleneksel RNN'lerin karşılaştığı kaybolan gradyan sorununu ele almak için tasarlanmış bir tür yinelemeli sinir ağıdır (RNN) [226]. Birden fazla kapıdan uzun süreler boyunca bilgiyi tutmasına izin veren karmaşık bir mimari ile tasarlanan bu ağ, diğer RNN'lere, gizli Markov modellerine ve çeşitli ardışık öğrenme yöntemlerine göre en büyük avantajı, boşluk uzunluğuna karşı göreceli duyarsızlığıdır. LSTM, binlerce zaman adımı boyunca devam edebilen RNN'ler için bir tür kısa süreli bellek sağlamayı amaçlar, dolayısıyla "uzun kısa süreli bellek" terimi kullanılır. Bellek ve onunla ilişkisi, bilişsel psikologlar tarafından 20. yüzyılın başlarından beri incelenmektedir [227].

Bir LSTM birimi tipik olarak bir hücre ve üç kapıdan oluşur: bir giriş kapısı, bir çıkış kapısı [228] ve bir unutma kapısı [229]. Hücre, keyfi zaman aralıklarında değeri korurken, kapılar hücreye giren ve hücreden çıkan bilgi akışını kontrol eder. Unutma kapıları, 0 ile 1 arasında bir değer üretmek için mevcut girdiye göre eşleyerek önceki


durumdan hangi bilginin atılacağını belirler. Yuvarlatılmış 1 değeri bilginin tutulduğunu, 0 değeri ise atıldığını belirtir. Giriş kapıları, unutma kapılarıyla aynı mekanizmayı izleyerek mevcut hücre durumunda hangi yeni bilgi parçalarının kaydedileceğine karar verir. Çıkış kapıları, mevcut hücre durumunda hangi bilgi bitlerinin üretileceğini belirler ve hem önceki hem de mevcut durumlara göre bilgiye 0 veya 1 değeri atar. Mevcut durumdan ilgili bilgileri seçici olarak çıktı olarak vererek, LSTM ağı hem mevcut hem de gelecekteki zaman adımlarında tahminler yapmak için yararlı uzun vadeli bağımlılıkları başarıyla sürdürür.

LSTM, sınıflandırma [230, 231], veri işleme, zaman serisi analizi [232], konuşma tanıma [233, 234], makine çevirisi [235, 236], konuşma etkinliği algılama [237], robot kontrolü [238, 239], video oyunları [240, 241], sağlık hizmetleri [242] ve insan eylemi tanıma [243] alanlarında kapsamlı uygulamalara sahiptir.

LSTM'nin birimleri, genellikle LSTM ağı olarak adlandırılan bir RNN'nin katmanları için yapı taşları olarak kullanılır. LSTM'ler, RNN'lerin girdileri uzun süre hatırlamasını sağlar. Bunun nedeni, LSTM'lerin bir bilgisayarın belleğine çok benzeyen bir bellekte bilgi içermesidir. LSTM, belleğindeki bilgileri okuyabilir, yazabilir ve silebilir.

Bu bellek, kapılı bir hücre olarak görülebilir; burada 'kapılı', hücrenin bilgilere verdiği öneme göre bilgileri depolamaya mı yoksa silmeye mi (yani kapıları açmaya mı yoksa kapatmaya mı) karar verme yeteneğini ifade eder. Önem atama, algoritma tarafından da öğrenilen ağırlıklar aracılığıyla gerçekleşir. Bu, zamanla hangi bilgilerin önemli olduğunu ve hangilerinin olmadığını öğrendiği anlamına gelir.


Uzun süreli ve kısa süreli bellek hücresinin üç kapısı vardır: bir giriş kapısı, bir unutma kapısı ve bir çıkış kapısı. Bu kapılar yeni girdiye izin verilip verilmeyeceğini (giriş kapısı), önemli olmadığı için bilgilerin silineceğini (unutma kapısı) veya mevcut zaman adımında çıktıyı etkilemesine izin verilip verilmeyeceğini (çıkış kapısı) belirler. İşte üç kapısı olan bir RNN'nin diyagramı [144].



Şekil 2. 42. RNN Scheme with Three Gates

LSTM'deki kapılar sigmoidlere benzerdir, yani sıfırdan bire kadar değişirler. Analog olmaları, geri yayılım yapmalarını sağlar.

Kaybolan eğimlerin sorunlu sorunu, dik eğimleri koruduğu için LSTM ile ele alınır ve bu da nispeten kısa eğitim süreleri ve yüksek doğrulukla sonuçlanır [245]. LSTM hücresi Şekil 2.42.'de gösterilmiştir.



Şekil 2. 43. Uzun süreli kısa süreli bellek blok diyagramı yapısı.

Şekil 2.43.'de gösterildiği gibi, LSTM mimarisi üç kapı tarafından kontrol edilen bir bellek hücresinden oluşur: giriş kapısı, unutma kapısı ve çıkış kapısı. Bu kapılar, bellek hücresine hangi bilgilerin ekleneceğine, hangi bilgilerin çıkarılacağına ve hangi bilgilerin bellek hücresine çıkarılacağına karar verir.

1. Giriş Kapısı: Gelen bilgileri filtreleyerek ilgili verilerin bellek hücresine girmesine izin verir.
2. Unutma Kapısı: Aşın artık ihtiyaç duyulmayan daha önce depolanmış bilgileri unutmasına yardımcı olur ve yeni verilere odaklanmayı sürdürür.
3. Çıkış Kapısı: Bellek hücresindeki bilgilerin çıktı olarak mı yoksa saklanarak mı çıkarılacağına karar verir.

Bu kapılar, LSTM ağlarının bilgileri seçici olarak toplamasını, saklamasını ve atmasını sağlayarak zaman serisi verilerini ve uzun süreli bağımlılıkları işlemede oldukça verimli hale getirir. Bu yetenekler nedeniyle, LSTM'ler dil çevirisi, konuşma tanıma ve elektrik yükü tahmini gibi ardışık veri analizi ve gelecekteki olayların tahmini gerektiren alanlarda yaygın olarak kullanılır. Hidroelektrik santrali durum tahmini gibi belirli uygulamalarda, LSTM'ler titreşim, basınç ve sıcaklık gibi etki eden faktörlerin örüntülerinden santral durumunu öğrenebilir, bu durumları bellekte saklayabilir ve edinilen bu bilgiye dayanarak tahminlerde bulunabilir.


Temel Avantajlar

1. RNN'ler: Sıralı verilerdeki kısa vadeli bağımlılıkları içeren görevler için uygundur.
2. LSTM'ler: Uzun vadeli bağımlılıkları verimli bir şekilde ele alarak RNN'lerin sınırlamalarını aşar ve bunları karmaşık sıralı veri görevleri için ideal hale getirir.

RNN'ler ve LSTM'ler, sıralı verileri işlemek için derin öğrenmede temel araçlardır. RNN'ler dizileri anlamak ve tahmin etmek için bir çerçeve sağlarken, LSTM'ler kaybolan gradyan sorununa daha gelişmiş bir çözüm sunarak uzun vadeli bağımlılıkların etkili bir şekilde öğrenilmesini sağlar [246,247].


2.5. HİDROELEKTRİK SANTRALLERİ

Dünya artık elektrik üretimiyle ilgili olanlar da dahil olmak üzere enerji üretiminde artan risklerle karşı karşıyadır. Bu krizin etkisi, özellikle yakıtın çok büyük miktarlarda tüketilmesinin ülkeler ve toplumlar üzerinde artan olumsuz etkileri, bunun sonucunda oluşan maddi hasar ve tüketilen yakıtın atıklarının çevre ve insanların sağlığı üzerindeki yıkıcı etkileri, dünya nüfusunun artması ve yaşamın gerekliliklerini karşılama ihtiyacının artmasıyla belirgindir [248]. Şekil 2.44.'de gösterildiği gibi, zararlı çevresel kalıntılara sahip yakıt kaynakları tarafından yönlendirilen dünya çapında elektrik üretimi son yıllarda artmıştır [249].



Şekil 2. 44. Yakıta göre dünya elektrik üretimi.


Bu arada, Şekil 2.44.'de gösterildiği gibi, elektrik enerjisi üretmek için hidroelektrik kullanımı giderek yaygınlaşmakta ve Şekil 2.45.'de gösterildiği gibi dünya toplam elektrik üretiminin %14,3'ünü oluşturmaktadır [250].



Şekil 2. 45. 2023'e kadar dünya çapında elektrik üretim kaynağı.


2.5.1. Hidroelektrik Kullanarak Elektrik Üretimi

Çoğu ülke, temiz elektrik üretmek ve fosil yakıtlardan enerji üretmenin olumsuz risklerini azaltmak için gelgitler ve akan su gibi hareket eden suda bulunan enerjiye güvenir [251]. Nehirleri olan ülkeler, yenilenebilir bir enerji kaynağı olarak elektrik üretmek, aynı zamanda çevresel faydalar sağlamak ve tarım ve sel kontrolü gibi diğer amaçlara hizmet etmek için barajlara güvenir. Bunun nedeni, su kaynaklarının insan refahı için değerli olması ve gıda üretimini desteklemesidir [252]. Küresel olarak erişilebilir ve tükenmez varlıklardan biri olarak kabul edildiğinden, enerji üretme yeteneğini kısıtlamak, geçim kaynaklarını iyileştirmek ve işletme karlılığını artırmak için sürdürülebilir bir enerji kaynağı sağlayabilir. Şekil 2.46., elektrik üretiminde hidroelektrik güç kullanımının yayılmasını göstermektedir [250].



Şekil 2. 46. Hidroelektrikten elektrik üretiminin payı, 2023.

Hidroelektrik, tesis türüne ve kapasitesine göre iki türe ayrılır. Ayrıca, tesis türü dört türe ayrılır: depolama veya rezervuar, pompalı salımlı (RoR) hidroelektrik santralleri, pompalı depolama hidroelektrik santralleri (HPP'ler) ve akışlı hidroelektrik sistemleri. Kapasite türü üç kategoriye ayrılır: Büyük, Orta ve Küçük - mikro, Mini ve Pico. Şekil 2.47.'ye bakın [253].



Şekil 2. 47. Hidroelektrik Santrallerinin Sınıflandırılması

Bu santraller kapasitelerine göre de sınıflandırılır ve büyük hidroelektrik santralleri büyük depolama rezervuarları ve barajlara yerleştirilir. Bunlar genellikle şebekeye bağlıdır. Bu tür santralleri inşa etmek için yüksek yatırım gerekir. Bu santraller 10 MW ile yüzlerce MW arasında güç üreterek birkaç bin eve güç sağlar. Küçük hidroelektrik santralleri geleneksel olarak akarsular veya nehirler tarafından çalıştırılır ve birkaç MW'a kadar güç üretir. Hidroelektrik santrallerinin potansiyel faydalarına ek olarak, merkezi olmayan güç üretimi bir diğer avantajdır. Bu santraller ayrıca sırasıyla 1 MW, 100 KW ve 5 KW üretim kapasitelerine sahip mini, mikro ve piko olarak sınıflandırılır. Çizelge 2.1.'de gösterildiği gibi [253].

Çizelge 2. 1. Hidroelektrik santral sınıflandırması

Hidro Kategorisi	Güç Aralığı	Güç Sağlanan Ev Sayısı
Büyük	100MW+	100,000+
Orta	10 MW – 100 MW	10,000 – 100,000
Küçük	1 MW – 10 MW	1,000 – 10,000
Mini	100 KW – 1 MW	100 – 1,000
Mikro	5 KW – 100 KW	5 – 100
Piko	0 KW – 5 KW	0 – 5


Farklı ülkelerdeki küçük hidroelektrik kapasitesi Çizelge 2.2.'da gösterildiği gibi sınıflandırılmıştır

Çizelge 2. 2. Hidroelektrik Santralleri Kapasitesi

Ülke	Kapasitesi
Çin	25 MW
Hindistan	15 MW
İsveç	1.5 MW
Kanada	20 ve 25 Mw
Amerika Birleşik Devletleri	30 MW

2.5.2. Hidroelektrik Santrali İşletme Yöntemi ve Karşılaştığı En Önemli Hatalar


Hidroelektrik santralleri, akan veya düşen suyun enerjisini kullanarak elektrik üretir. Bir nehir veya rezervuar suyu sağlar ve barajlar genellikle suyun kontrollü bir şekilde akmasını sağlayan bir rezervuar oluşturmak için inşa edilir. Su barajın rezervuarından bırakıldığında, büyük su borularından akar. Akan suyun kuvveti, yüksek basınçlı suyun bir türbinin kanatlarına çarpması ve dönmelerine neden olması nedeniyle basınç oluşturur. Türbin dönerken, jeneratörü bir şaft aracılığıyla çalıştırır. Jeneratör, elektromanyetik indüksiyon yoluyla elektrik enerjisi üreten güç iletim şaftının dönme kuvvetiyle çalışır [254]. Şekil 2.48. barajın ana bileşenlerini göstermektedir.



Şkil 2. 48. Hidroelektrik Barajı

Türbinler, yüksek sıcaklıklar, artan titreşimler ve hava boşluklarının oluşumuyla birlikte gelen yüksek basınç seviyelerine maruz kalırlar. Yükseklikleri nedeniyle, birkaç ton ağırlığındaki türbin kanatları trajik bir kazada kırılarak ciddi hasara neden olmuştur.

Hidrolik santrallerdeki en yaygın arızalar Şekil 2.49.'de özetlenebilir [255, 256].



2.5.3. Titreşim Kaynakları

Türbinler ve jeneratörler hidroelektrik santrallerinin çekirdeğini oluşturur ve çok pahalı olan en önemli elektromekanik ekipmanlardır [257].

Bu istasyonlardaki titreşimlerin nedenleri aşağıdaki gibi özetlenebilir [258].

1. Elektrikten kaynaklanan titreşimler,
2. Hidrolikten kaynaklanan titreşimler,
3. Mekanikten kaynaklanan titreşimler. Döner ekipmanlarda oluşan titreşimlere ek olarak, dönmeyen ekipmanlar da titreşimlerden muzdariptir. Çeşitli cihazlardaki titreşimlerin nedenleri aşağıda gösterilmiştir.

2.5.3.1. Döner Makinelerde Titreşimlerin Nedenleri

Türbin koşucusu: Aşağıdaki faktörler bir türbin koşucusunda titreşimlere neden olabilir: kaba bölge çalışması, mekanik parçaların yetersiz yağlanması, zayıf yataklar,

yanlış hizalama, kavitasyonlar, mekanik dengesizlik, hidrolik dengesizlik [259], kapı bağlantı kırılması, çatlak veya yontulmuş kanatlar ve şaft [260, 261].

Rotor: Rotor sürtünmeleri, yukarıda belirtilen koşucu nedenlerine ek olarak rotordaki titreşimlerin kaynağı olabilir [262-24].

2.5.3.2. Dönmeyen Ekipman Titreşimlerinin Nedenleri

1. Conta aşınması: su türüne göre değişir,
2. Emiş borusu: Borudaki rezonans, boşluklar,
3. Penstock rezonansı: boşluklar,
4. Transformatör: Manyetomotor kuvvetleri,
5. Jeneratör: Elektromanyetik kuvvet.

Aşındırıcı aşınma, yeniden dolaşım ve mekanik gevşeklik, hem türbinlerde hem de jeneratörlerde titreşimin birincil nedenleridir [263, 264]. Transformatörler, elektrik motorları, türbinler ve jeneratörler titreşimin birincil kaynaklarıdır. Bu titreşim sinyalini gelişmiş sensörler kullanarak tespit ederek, bu ekipman parçalarındaki sorunlar belirlenebilir [265, 266].

2.5.4. Hidro Türbin Verimliliği

Türbin verimliliği dolaylı olarak çalışma koşullarını yansıtır; hidrolik türbinler tasarım dışındaki çalışma koşulları altında çalıştığında veya türbinler eskidiğinde, çalışmaları bozulur ve enerji alanındaki performansları değişir ve performanslarının negatif göstergesine doğru düşer. Türbinlerin yüksek dinamik yükü durumunda boşlukta ciddi erozyona ve yüksek titreşim oluşumuna neden olur ve bu da tüylerin çökmesine, maddi kayıplar ve zaman açısından trajik bir kazaya ve nüfuslara elektrik kesintilerine neden olur; türbinlerin verimliliğini ve mükemmel performansını iyileştirmek için izlenmesi gereken ana sorunlardır [267, 268, 269].

2.5.5. Sıcaklık, Arıza ve Titreşim Arızalarının Teşhisi

Türbinlerdeki titreşime karşılık gelen bir sıcaklık artışı eşlik eder. Bunlar, türbine suyla giren kabarcıklardır [267]. Ek olarak, motorun titreşimi mekanik, aerodinamik ve elektromanyetik tipler olarak sınıflandırılır [270, 271].

2.5.6. Mekanik Titreşim

Türbinin durumu, türbinin gözlem sisteminden elde edilen bilgiler, tasarım özellikleri, kendisine akan suyun miktarları ve basıncı, türbinlerdeki arızaların bakım kayıtları ve onarımı ve türbinleri basınç ve sıcaklık gibi çeşitli faktörler için taşımak üzere şirket tarafından belirlenen tablolar gibi çeşitli faktörlere göre değerlendirilir, burada tüm bu veriler, hatayı oluşmadan önce tahmin etmek, durumu belirlemek ve barajdaki her türbinin durumunu belirlemek ve gerekirse bakımı kolaylaştırmak için etkilenen üniteyi belirlemek için akıllı stratejilere ve algoritmalara getirilir. Aerodinamik ve elektromanyetik gibi başka titreşim nedenleri de vardır [268, 272, 273].

2.5.7. Aerodinamik Titreşim

Aerodinamik sorunlar, ayrı kanat geçiş frekansları, motor içindeki rezonans hacim uyarımları, havalandırma fanları ve geniş bant türbülansından kaynaklanır. Kanatların dönmesiyle oluşan aerodinamik bileşen, genellikle aeroelastik sönümlenme olarak bilinen iskelet ve aerodinamik titreşimlerin bir kombinasyonu tarafından domine edilir. Elektriksel arızalarla ilgili titreşimler, rotor ve stator üzerinde etkili olan dengesiz elektromanyetik kuvvetler tarafından meydana gelir. Bu dengesizlik, hava boşluğu eksantrikliğine, kırık rotor çubuklarına, hava boşluğu akısının eşit olmayan dağılımına, dönüşler arası arızalara, kısa devre yapmış veya açık stator ve rotor sargılarına, eşit olmayan faz akımlarına, manyetostriksiyona ve tork salınımlarına atfedilir [274, 275].

2.5.8. Elektromanyetik titreşim

Jeneratörlerdeki elektriksel arızalar ve hatalar, sabit ve dönen parçalar üzerinde etkili olan dengesiz manyetik kuvvetler nedeniyle ilişkili türbinlerde titreşimlere neden olur ve bunun sonucunda hava boşluğunda havanın eşit olmayan bir şekilde dağılması meydana gelir. Bu, yansıma arızalarına, eşit olmayan faz akımlarına ve manyetizma nedeniyle torkta dalgalanmalara yol açar. Ve elektrik besleme frekansı ile dönme frekansı arasındaki ilişki [276]. Bu, Şekil 2.50'te gösterildiği gibi tüylerde boşlukların oluşmasına yol açar [277, 278].



Şekil 2. 50. Türbin kavitasyon hasarı

BÖLÜM 3

ARAŞTIRMA YÖNTEMİ

3.1. KONTROL SİSTEMİ VE İŞLEME BİRİMİ

3.1.1. SCADA Tarafından Ana İzleme ve Ölçüm

Saldırı koruma evinde, kontrol odasında ve baraj işletme evinde bulunan üç SCADA bilgisayarı, acil bir durumda tüm verileri izlemek ve durumu yönetmek için kurulmuştur. Tüm anlık akışlar, toplam akışlar, meteorolojik gözlemler ve tüm ölçüm sistemlerinden gelen diğer veriler elektronik olarak izlenebilir ve PC istasyonlarında kaydedilebilir. Ayrıca, yetkili personel her konumdaki tüm verilere kendi PC'lerinden erişebilir.

SCADA sisteminde kaydedilen tüm ham veriler baraj işletme amiri tarafından günlük olarak işlenir ve verilerin bir özeti bir Excel elektronik tablosuna kaydedilir [279]. Rezervuar ve savak seviyeleri ve çıkış akış izlemesi, şunlar dahil olmak üzere kullanılan çeşitli araçlardan elde edilir: (a) rezervuar seviyesi için basınç dönüştürücü, (b) savak seviyesi için ultrasonik seviye ölçümü, (c) savak kapısı açıklığı için dijital kodlayıcı, (d) ham su ve telafi akışları için elektromanyetik akış ölçerler (FM) ve (e) ayak tahliye akışı için ultrasonik seviye ve v çentikli baraj.

Rezervuar seviyesi ölçümü, çıkış kapısı yapısının eğiminde deniz seviyesinden nominal 110 m yükseklikte (ASL) kurulan geleneksel bir batık basınç dönüştürücüsü (Tip: Druck PTX 1830) kullanılarak elde edilir. Koruma ve bakım kolaylığı için plastik bir borunun içine geçirilmiştir.

Savak seviyesinin ölçümü, savak yaklaşım kanalında, sıfır noktası 159,95 m ASL olan 10 m menzilli bir ultrasonik seviye sensörü kullanılarak gerçekleştirilir. Bu seviye, savak üzerindeki akışı hesaplamak için savak kapısı açıklık ölçümlerinin her biriyle birlikte kullanılır. Bu nedenle, seviye ölçüm noktası, savak kapılarının altında yüksek akışlara neden olabilecek sıvı seviyesinin "düşüşünü" önlemek için savak kapılarından en az 20 m uzakta olmalıdır. Ultrasonik seviye ölçümü sıcaklıktan etkilenir. Bu nedenle, sensörler sıcaklık telafilidir.

Ancak, seviye sensörüne doğrudan gelen güneş ışığı, sensör sıcaklığını ortam sıcaklığının üzerine çıkararak hatalara yol açacaktır. Bu nedenle, sensör yalıtımlı paslanmaz çelik bir başlıkla korunur. Savak kapısı konumlarının ölçümü, giriş şaftından mevcut kapı açıklık gösterge mekanizmalarına sürülen bir dijital kodlayıcı tarafından gerçekleştirilir.

Çok turlu kodlayıcının dijital çıkışı şartlandırılır ve yerel Programlanabilir Mantık Denetleyicisine (PLC) iletilmek üzere 4–20 mA çıkış sinyaline dönüştürülür. Bu dijital kodlama cihazları son derece doğrudur; ancak savak akışını kontrol etmek için kullanılan kapıların doğası gereği, kapı sıfır noktasının ayarlanması çok önemlidir. Oyun sıfırı, sızıntının kapının altında görünmeye başladığı noktayla çakışmalıdır ve bu da alt contanın dekompresyonunu gösterir. Bu contanın tam olarak sıkıştırılması, hesaplanan akışta belirgin bir artışa yansıtacak olan 5 cm'ye kadar bir sıfır noktası farkı yaratabilir. Rezervuardan çıkış akışları (a) WTP'ye ham su akışı, (b) nehre telafi akışı, (c) savak deşarj akışı, (d) Howell Bunger vana akışı, (e) ayak drenaj akışı ve (f) buharlaşmayı içerir.


Bu akışlardan ham su ve telafi akışları, ABB Kent-Taylor tam çaplı elektromanyetik FM (proje boyunca kullanılanlara benzer) kullanılarak ölçülür. Savak deşarj akışı, savak seviyesi ve savak kapısı açıklığının ölçümlerine dayanarak hesaplanır. Howell-Bunger vana akışı, operatörün vana pozisyonu ve ölçülen rezervuar seviyesi girdisine dayanarak hesaplanır. Ayak drenaj akışı, ayak drenaj şaftının her iki tarafındaki ultrasonik seviye ölçümleriyle birlikte bir çift 60° V-Çentikli baraj kullanılarak ölçülür. Son olarak, buharlaşma hava istasyonundan indirilen verilere dayanarak hesaplanan bir değerdir [280].

3.1.2. Sistem Mimarisi

Hidroelektrik santrallerinin çalışma koşullarını etkileyen faktörlerdeki anlık değişimlerin devasa verilerine dayanarak, örneğin suyun türbinlerden geçtiği hidroelektrik santrallerinin basıncı, titreşimler ve diğer etki eden faktörler, her an tehlike aşamasına ulaşabilir; bu nedenle, tüm durumlarla başa çıkabilen ve tehlike aşamasına ulaşmadan önce bunları çözebilen akıllı, esnek ve kullanılabilir bir izleme ve kontrol sistemi tasarlanmalıdır. Tüm farklı barajlarda kullanılabilir.

Bu istasyonların durumunu etkileyen tüm faktörler için depolanan devasa verilere dayanarak gelecekteki koşulları akıllı bir işlem birimi kullanarak tahmin eden yapay zeka ve akıllı tahmin algoritmalarına dayalı bir kontrol sistemi, çünkü bu sistem doğruluk ve profesyonel verimlilikle çalışır. Bu sistem, gerçek verilere dayalı tahmin algoritmalarından oluşan ve bu gelişmiş sistemi akıllı bir işlem birimine entegre ederek ve bu sistemin mevcut kullanılan izleme sistemleriyle (SCADA sistemleri) entegre edildiği minyatür bir akıllı bilgisayar olarak kabul edilen bu sistemle bazı barajlarda kullanılan izleme ve kontrol sistemleriyle (SCADA sistemleri gibi) birlikte kullanılabilir.

Gelişmiş algoritmalara (RNN, LSTM) dayalı olarak tasarlanan kontrol sistemi, sistemin beyni olarak kabul edilen hidroelektrik santrallerinin gelecekteki durumunu, sistemin kalbi olarak kabul edilen merkezi işlem birimi veya minyatür bilgisayar (Raspberry Pi) aracılığıyla tahmin etmek için çalışır ve ilk aşamada hidroelektrik santrallerinin durumunu veya işinin doğasını etkileyen tüm faktörler (basınç, titreşim, sıcaklık ve geri kalanı gibi) için çeşitli sensörlerden gelen verileri ve sinyalleri alır ve gelecekteki durumu tahmin etmek ve buna dayalı kararı oluşturmak için hazırlanmış eğitilmiş algoritmaya girer ve aynı zamanda bu sinyaller, bu sinyalleri doğrudan ve gerçek zamanlı olarak görüntülemek için tasarlanmış grafiksel kullanıcı arayüzüne gönderilir ve aynı zamanda bu istasyonların gelecekteki durumu görüntülenir. Gözlemci uyarılır ve karar verilir.



Şekil 3. 1. SCADA sistemi


3.1.2.1. Karar, İki Olasılığa Dayalı Olarak İki Aşamada Verilir

İlk olasılık maksimum risktir. Alarmı çalıştırmak için bir uyarı sinyali gönderildiğinde, türbinlere su akışını azaltmak için türbin kapısını kademeli olarak kapatma kararı doğrudan verilir ve etkili faktörlerin sinyalleri ile türbinlerin gelecekteki durumu karşılaştırılarak etkileri azaltılır ve risk durumu sınırlandırılır, bunların en önemlileri basınç ve titreşimdir ve ardından normal çalışmaya geri dönlür.


İkinci olasılık, risk durumundan önce gelen kritik durumdur, veriler analiz edilmek üzere merkezi işlemci veya mikrobilgisayar (Raspberry Pi) aracılığıyla bilgisayara gönderilir ve durum bir risk durumu olmadığından, bu durumda merkezi işlemci tarafından herhangi bir işlem yapılmaz ve aynı zamanda bu sinyaller MATLAB programındaki kontrol programı içinde işlenmek üzere merkezi bilgisayara gönderilir,

bu veriler aracılığıyla sistem izlenir ve sıcaklık sinyali, titreşim, basınç ve diğer faktörler grafiksel kullanıcı arayüzü kullanılarak çizilir ve buna dayanarak iki olasılık vardır [281]:

1. İlk durum, sistemin titreşimi, basıncı ve sıcaklığı ölçtüğü ve bunları buna göre görüntülediği normal durumdur.
2. İkinci durum, bu durumun tahmin algoritmasına göre merkezi işlem birimi (Raspberry Pi) içinde belirlendiği kritik durumdur. Daha sonra, etki eden faktörlerin sinyalleri grafiksel kullanıcı arayüzü aracılığıyla görüntülendiğinde alarmı çalıştırmak için bir sinyal gönderilir ve kontrol seçeneği, türbin kapılarını kapatıp açabilen gözlemciye verilir. Bu faktörleri ölçme süreci periyodik ve sürekli olarak tekrarlanır ve normal duruma ulaşmak için gelecekteki durum tekrar belirlenir ve değişiklikler izlenir.



Şekil 3. 2. Sistem mimarisi



Şekil 3. 3. İzleme sisteminin akış şeması

Kapılar, ön işlemci (Raspberry Pi) veya MATLAB'daki kontrol programı tarafından alınan sinyale göre sabit kurallara göre açılıp kapatılır. Normal, kritik ve tehlikeli durumlar, türbin üreticileri tarafından sağlanan bilgilere göre belirlenir ve Çizelge 3.1.'de gösterildiği gibi tahmin algoritmasına entegre edilir. Bu tablo sistemin stratejisini özetler ve titreşim, basınç ve sıcaklık koşullarına göre kapıların ne zaman açılıp kapanacağını belirtir.

Çizelge 3. 1. Kapıların açılıp kapanma kuralları

Türbin	Dec	Chr	Sensör	Durum	Kapısı
1	48	0	Sıcaklık, Titreşim, Basınç	Risk	Kapalı
1	49	1	Sıcaklık, Titreşim, Basınç	Doğal	Açık
2	50	2	Sıcaklık, Titreşim, Basınç	Risk	Kapalı
2	51	3	Sıcaklık, Titreşim, Basınç	Doğal	Açık


3.1.3. Metodoloji

Önerilen izleme sistemi esas olarak iki bölümden oluşur: donanım bölümü (edinim birimi), tahmin algoritmasına dayalı bir mikrobilgisayar kartına (Raspberry Pi 5) dayalı olarak hidroelektrik santralinin çeşitli sensörlerinden veri alan merkezi bir işlem biriminden ve Şekil 3.3'da gösterildiği gibi bu istasyonların gövdesine yerleştirilmiş titreşim, basınç ve sıcaklık sensörleri gibi farklı tipte dijital ve analog sensörlerden oluşur.

Diğer bölüm, merkezi işlem birimi aracılığıyla istasyonun çalışma doğasını etkileyen faktörleri ölçen sensörlerden gelen edinim verilerini işlemek ve kontrol etmek ve görüntülemek için MATLAB programlamaya ve MATLAB'deki grafiksel kullanıcı arayüzüne (GUI) bağlıdır.

Hidroelektrik santralinin ve türbinlerin durumunu izlemek, esasen her titreşim, basınç ve sıcaklık sensöründen gelen sinyallerin gerçek zamanlı değerlerini bilmeyi ve bunları görüntülemeyi gerektirir; bu da gözlemcinin istasyonun çalışma doğasını izin verilen sınırlar içinde belirlemesini sağlar.

Farklı barajlarda farklı sensörler kullanılmakta ve bu sensörler elektronik sinyaller şeklinde değerler veriyorsa sistem bunlara göre ayarlanmakta veya mekanik sensörler elektronik olanlarla değiştirilerek mekanik ve eski sistemli istasyonlardaki izleme sistemleri güncellenmekte ve sensörlerin kurulum yerlerine bağlı olarak bu istasyonlar ve türbinler için üretici firma tarafından onaylanan aynı belirlenmiş yerde bulunmaktadır [282].




Şekil 3. 4. Sensörlerin konumu

3.2. TEKRARLAYAN SİNİR AĞI RNN VE LSTM

3.2.1. Tekrarlayan Sinir Ağı Modeli

En önemli hedeflerinden biri, RNN'lerin okumalar ve cümleler gibi zaman serilerini işlemek için çalışmasıdır. Sıralı sayısal değerlerle ilgilenen bu algoritmanın en önemli özelliği, cümleler ve kelimelerle ilgilenirken olduğu gibi, önceki değerlerin her zaman sonraki değerler ve sayılar için önemli ve etkili olmasıdır.

Bir RNN'nin temel yapısı, Şekil 3.5'de gösterildiği gibi, bir sonraki durumun bilgisini etkilemek için geçmiş duruma bağımlılığını gösterir. RNN'ler, sıralı olarak bilgi sağlamak için sürekli bir aşama olarak gizli durum vektörleri H_t sağlar. Böylece, bilgi sürekli olarak önceki durumdan aktarılabilir ve RNN aracılığıyla bir sonraki eğitime beslenebilir [283].



Şekil 3. 5. Tekrarlayan bir sinir ağının yapısı

$$y_t = f_2 (Vh_t + c) \quad (3.1)$$

$$h_t = f_1 (Ux_t + Wh_{t-1} + b) \quad (3.2)$$

RNN yapısı bir giriş vektörü x_t , bir çıkış vektörü y_t , ağırlık matrisi V , U ve W , önyargı vektörleri B ve C ve aktivasyon fonksiyonları F_1 ve F_2 'ye sahiptir. Son verilere dayanarak, RNN algoritması bilgiyi doğru bir şekilde tahmin eder. Bengio ve diğerleri [284], RNN algoritmasının, çıkış değişkenlerinin giriş değişkenlerinden etkilenmesi için uzun bir süre sonra, boşluk uzunluğu olarak bilinen, verimli bir şekilde performans göstermediğini buldu. 2. periyodu göz önünde bulundurarak, denklemler 3.1 ve 3.2'den denklem 3.3 türetilir.


$$y_t = f_2 (Vf_1(Ux_t + Wf_1(Ux_{t-1} + Wf_1(Ux_{t-2} + Wh_{t-3} + b) + b) + b) + c) \quad (3.3)$$

Giriş $x_{(t-2)}$ 'nin y_t üzerindeki etkisi Aktivasyon fonksiyonunun iki katmanı tarafından azaltılır ve zayıflatılır. Aktivasyon fonksiyonunun katman sayısı periyotla birlikte artar. Bu, model parametrelerini eğtmek için kullanılan eğimin ortadan kalkmasına neden olur. Bu nedenle, RNN'leri eğtmeyi daha zor hale getirir. Teorik ve deneysel kanıtlar, hata kriterinin kademeli olarak azalmasının, uzun vadeli bağımlılıkları içeren görevlerde RNN'leri eğtmek için yetersiz olabileceğini göstermiştir. [285].

3.2.2. Uzun Kısa Süreli Bellek Ağı Yapısı

LSTM ağı, Hochreiter ve Schmidhuber tarafından 1997'de önerildi. 25, özel bir RNN türüdür [286]. LSTM'nin yapısı, RNN algoritmasının performansını iyileştirmek için açıkça tasarlanmıştır. Yapı olarak RNN'ye benzer olan LSTM, Şekil 3.6.'de gösterildiği gibi sürekli bir tekrarlayan RNN birimi serisidir.

Bu ağ, temel biriminde "kapılar" oluşturan profesyonelce oluşturulmuş bir mimari aracılığıyla "hücreler" adı verilen birimler sağlar. Bu kapılar, ağın hem uzun vadeli hem de kısa vadeli belleği zaman adımları boyunca yakalamasını ve ayrıca standart RNN'lerde kademeli patlama ve/veya solma olarak bilinen RNN'lerin performansını düşüren noktadan kaçınmasını sağlar. Kapılar "unutma kapısı", "giriş kapısı" ve "çıkış kapısı" olarak adlandırılır. LSTM'nin detaylı yapısı Şekil 3.6'te gösterilmiştir.



Şekil 3. 6. LSTM'nin detaylı yapısı

LSTM ünitesinin çalışma yöntemi ve aşamaları aşağıdaki gibi özetlenebilir:

$$i_t = \sigma_g (W_i \cdot x_t + U_i \cdot h_{t-1} + b_i) \quad (3.4)$$

$$f_t = \sigma_g (W_f \cdot x_t + U_f \cdot h_{t-1} + b_f) \quad (3.5)$$

$$\hat{c}_t = \tanh(W_c \cdot x_t + U_c \cdot h_{t-1} + b_c) \quad (3.6)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \hat{c}_t \quad (3.7)$$

$$o_t = \sigma_g(W_o \cdot x_t + U_o \cdot h_{t-1} + b_o) \quad (3.8)$$

$$h_t = o_t \odot \tanh(c_t) \quad (3.9)$$

$$\sigma_g(x) = \frac{1}{(1+e^{-x})} \quad \sigma_g(x) = \frac{1}{(1+e^{-x})} \quad (3.10)$$


$$\tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.11)$$

Burada aktivasyon fonksiyonları (3.10) ve (3.11), w_i w ve U_i U ağırlık parametreleridir ve b^i önyargıdır, $e \odot$ noktasal çarpımı belirtir. Başlangıç değerleri $c_0 = 0$ ve operatör $\odot$, Hadamard ürününü (eleman bazlı ürün) ifade eder [287]. t alt simgesi zaman adımını indeksler.

Bilgi, RNN'deki gizli birimler aracılığıyla önceki durumdan mevcut duruma aktarılır ve bir sonraki duruma katkıda bulunur. RNN'nin derinliği zaman içinde olduğundan, bazı ardışık bilgiler zamanla kaybolur ve bu da hataların tekrarlanmasına neden olur. Buna göre, RNN'nin doğruluğu, RNN'lerin muzdarip olduğu kaybolan gradyan ve patlayan gradyan sorunları olarak bilinen ana sorun nedeniyle periyodun artmasıyla azalır. Bu ağın performansı iyileştirilir ve bu sorun uzun kısa süreli bellek (LSTM) tanıtılarak ele alınır.


Geliştirilen LSTM modeli, birçok farklı uygulamada RNN ağının performansını iyileştirmek için güvenilirdir. Kullanımı uygulamalarda başladı, bunların en önemlileri el yazısı tanıma [288], dil modelleme [289] ve çeviri sürecini iyileştirme [290, 291], ayrıca konuşma akustik modellemesini geliştirme [292], konuşma sentezini [293, 294] ve protein yapı tahmin süreçlerini [295, 296] ve ayrıca ses ve video veri analizinde de kullanıldı [297]. Dahası, modern tek hücreli LSTM mimarisindeki çıktıların kesin zamanlaması, dahili hücreleri ve hücrenin kapılarını birbirine bağlayan tüm bağlantılar

aracılığıyla öğrenilir [298]. Şekil 3.7., LSTM'nin şematik bir gösterimini göstermektedir.



Şekil 3. 7. Bir LSTM biriminin temel bir açıklayıcı gösterimi.

Bilgi, LSTM ağından çıkarılır ve yapısını oluşturan kapılar aracılığıyla hücrelerine eklenir; bu, Şekil 3.8.'te gösterildiği gibi, ana bileşeni olan LSTM yapı çizimindeki üst yatay çizginin yatay zincirini temsil eder.




Şekil 3. 8. Bir LSTM Modelindeki Hücre Durumu.

LSTM modeli, geleneksel sinir ağı katmanları yerine, birden fazla birleştirilmiş ve paylaşılan hücre birimi için tasarlanmıştır. LSTM biriminin özellikleri Şekil 3.9.'te gösterilmiştir.

Ortak bir LSTM modelini, geleneksel sinir ağı katmanları yerine, birden fazla hücre biriminin birleştirilmesi olarak tasarladık. Şimdi LSTM biriminin özelliklerini kısaca inceleyeceğiz. Şekil 3.9.'te gösterildiği gibi, bir LSTM hücresi üç girdiden oluşur: X_t , geçerli zaman noktasındaki girdi gözlemidir, h_{t-1} , önceki LSTM hücresinden üretilen çıktıyı temsil eder ve C_{t-1} , önceki hücrenin belleğini belirtir.

Ayrıca, her LSTM hücresi, gerçek ağın çıkışı ve geçerli birimin belleği olan h_t ve C_t olmak üzere iki çıktı içerir. Üç tip kapıdan oluşur: giriş kapısı, unutma kapısı ve çıkış kapısı (Şekil 3.7.). Her kapı, bir sigmoid sinir ağı katmanı ve noktasal çarpma işlemi içerir. LSTM'ler, zincir benzeri bir yapı olarak açıldığında görülebilir. Başka bir deyişle, farklı bir yapıya sahip döngü tekrarlayan bir modüldür (Şekil 3.9.). Girişe ve dahili geri bildirime (bellek durumu) bağlı olarak, çıkış, kapılara ve dört katmanlı bir yapıya dayalı özel bir şekilde üretilir. Buradaki katmanlar, sigmoid ve tanh'a dayalı aktivasyon birimlerine sahiptir [299].



Şekil 3. 9. Zaman içinde açıldığında bir LSTM'nin şematik gösterimi.

Bu LSTM birimi, gerçek girdiye, önceki çıktıya ve belleğe dayalı bir karar sağlar ve ardından yeni bir çıktı üretir ve belleğini yükseltir.

Giriş kapısı

Giriş kapısının temel rolü, giriş aktivasyonunun bellek hücresine akışını kontrol etmektir. Burada, sigmoid katman, bellek hücresine 0 ile 1 arasında bir çıktı üreterek akışı kontrol eder.

Çıkış kapısı

Çıkış kapısı, hücre aktivasyonu tarafından üretilen çıkış akışını kontrol etmeyi ve bunu ağa enjekte etmeyi amaçlar. Bu kapı, bir sonraki LSTM birimine beslenecek bellek miktarını kontrol eden bir sigmoid katmana sahiptir.

Kapıyı unutmak

Sigmoid katman çıktısı, artık ihtiyaç duyulmayan bilgileri hücre durumundan kaldırır (çıkı 0 olduğunda, aksi takdirde onu saklar). Başka bir deyişle, unutma kapısı, LSTM modellerinin sürekli giriş akışlarını işlemlerini önleyerek zayıflıklarının üstesinden gelir [289]. Blok belleğinin içeriğini ölçeklendirerek hücrenin bellek içeriğini adaptif olarak unuttur.


3.2.2.1 LSTM Uygulama Adımları

Her LSTM döngüsünün girdisi ($t - 1$) bellek durumu C_{t-1} ve gizli katman birimleri h_{t-1} 'dir (çıkı), ancak ilk döngü için sıfır veya rastgele değerlerle başlarız. LSTM'yi uygularken atılan ana adımlar aşağıda açıklanmıştır.

1. LSTM'nin ilk adımı, belirli bir zaman anında hangi bilginin unutulacağına veya saklanacağına karar vermekten oluşur. Bu adım, geçmiş bilginin artık geçerli döngüyle alakalı olmadığına, öncelikli olarak geçerli girdiyle ilgili olduğunda özellikle yararlıdır. Başka bir deyişle, bu adım, ihtiyaç duyulmayan ve hücre durumundan çıkarılabilecek bilgileri ortaya çıkarmayı amaçlar. Sigmoid işlevi bunu başarır. Geçmiş durumu (h_{t-1}) ve gerçek girdi X_t 'yi inceler ve işlevi buna göre hesaplar (Şekil 3.10.).

$$f_t = \sigma(x_t U^f + h_{t-1} W^f), \quad (3.12)$$

burada w_f ağırlıktır ve h_{t-1} önceki zamandan gelen çıktıdır



Şekil 3. 10. LSTM'deki ilk adım: Hangi bilgilerin unutulacağına veya saklanacağına karar verin.


2. LSTM'deki ikinci adım, bellek hücresinin içeriğini güncellemekten oluşur. Bu adım, hücre durumunda depolanacak yeni bilgileri seçer (Şekil 3.11.). İkinci katman (giriş kapısı) iki bileşenden oluşur: sigmoid fonksiyonu ve tanh fonksiyonu. Sigmoid katmanı, hangi değerlerin güncelleneceğini seçer.

1 durumunda, giriş kapısının değeri değişmez ve 0 durumunda düşürülür. Daha sonra, bir tanh katmanı, duruma eklenebilecek yeni aday değerlerden oluşan bir vektör oluşturur. Seçilen değerlere önem düzeylerine göre ağırlık sağlar (-1 ila 1). Bundan sonra, durumu güncellemek için ikisi birleştirilir. $\tilde{C}_t$, hem bellek durumu C_t 'yi hem de C_t 'yi güncellemek için C_{t-1} ile birleştirilir. H_t (çıkış), çıkış kapısı sigmoidine ve C_t 'nin tanh'ına göre hesaplanır:

$$i_t = \sigma(x_t U^i + W h_{t-1} W^i) \quad (3.13)$$

$$\tilde{C}_t = \tanh(x_t U^g + h_{t-1} W^g) \quad (3.14)$$


Aday bellek hücresi, W^i, W^g ağırlık parametreleridir.



Şekil 3. 11. LSTM'deki ikinci adım, bellek hücresinin içeriğini güncellemektir.

3. Bu adımda, eski hücre durumu C_{t-1} , yeni hücre durumu C_t ile gerçekleştirilir ve geçmiş hücre durumu C_{t-1} , yeni hücre durumu C_t ile gerçekleştirilir (Şekil 3.12.). Bunu yapmak için, alakasız bilgileri unutmak için eski durum f_t ile çarpılır ve aday eklenir. Bu, her durum değerini ne kadar güncellemeyi seçtiğimize göre ölçeklenen yeni aday değerlerini temsil eder:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t . \quad (3.15)$$




Şekil 3. 12. LSTM modellemesinde 3. Adım.

4. Son olarak, çıktı iki adımda hesaplanır (Şekil 3.13). İlk olarak, çıktıya iletilecek hücre durumunun ilgili kısımlarını seçmek için bir sigmoid katmanı kullanılır (Denklem (3.16)):

$$o_t = \sigma(x_t U^o + h_{t-1} W^o) \quad (3.16)$$

Daha sonra hücre durumu tanh üzerinden geçirilir (−1 ve 1 aralığındaki değerleri normalleştirmek için) ve sigmoid kapısının çıkışıyla çarpılır; böylece, yalnızca çıktı olarak seçtiğimiz kısımları tutarız (Denklem (3.17)):

$$h_t = \tanh(c_t) \cdot o_t \quad (3.17)$$




Şekil 3. 13. LSTM modellemesinde 4. Adım.

Döngünün sonunda, döngünün çıktısını temsil eden Ht gizli katman birimleri ve Ct bellek durumu bir sonraki döngüde kullanıma hazırdır. Özetle, LSTM modeli üç kapıyı, bellekte hangi bilgilerin tutulabileceğini, ne kadar süreyle saklanabileceğini ve ne zaman okunabileceğini öğrenmeleri için eğitir. Birkaç bellek hücresini bloklara birleştirmek, aynı kapıları paylaşmalarına izin verir ve dolayısıyla uyarlanabilir parametrelerin sayısı azalır [300].

3.2.3. Malzemeler ve Yöntemler

Bu bölüm, çalışmanın uygulandığı modeli, vaka çalışmasının özelliklerini ve tanımlayıcı istatistiklerini, veri keşfinin ikinci adımını ve makine öğrenimi için veri ön işlemenin üçüncü adımını açıklar. Daha sonra, modelin ana bileşenleri olan RNN ve LSTM algoritmaları sunulur (bkz. Şekil 3.14.).




Şekil 3. 14. Araj istasyonu arıza tespit modeli için iş akışı sistemi.

Şekil 3.14. beş temel adımdan geçen iş akışını göstermektedir. İlki, farklı sensörlerden veri toplamayı, ardından veri analizi aşamasını, ardından bazı özelliklerin seçilmesini, normalizasyonu, ardından veri bölme eğitimini ve testini ve tipik modeli belirlemeyi içeren tahmin algoritmasını hazırlamayı ve son adım ise algoritmayı tahmin üzerinde gerçek bir şekilde çalışacak şekilde yüklemeyi içerir.

3.2.3.1. Vaka Çalışması

Obruk Barajı, Çorum'un Durdurga ilçesine 16 km ve Obruk köyüne 2 km uzaklıkta bulunan Kızılırmak Nehri üzerine inşa edilmiştir (Şekil 3.15.). Birçok amaç için kullanılan, en önemlisi elektrik enerjisi üretimi olan, toplam 4 jeneratör ve her biri 52,7 MW olmak üzere toplam 210,8 MW kurulu güce sahip bir barajdır. Obruk Barajı 2009 yılında hizmete girmiş ve elektrik üretmeye başlamıştır. En yüksek su seviyesinde, gölün kapasitesi 661 hm³ ve alanı 50,21 km²'dir. Barajın dört adet savak kapağı ve 5000 m³/s deşarj kapasitesi vardır.



Şekil 3. 15. Türkiye, Çorum İli'ndeki Obruk hidroelektrik santralinin konumu.

Barajın başlıca kullanımları hidroelektrik üretimi, kentsel içme ve sulamadır [17]. Ayrıca, eğlence amaçlı ve taşkın kontrolü için kullanılır.

3..2.3.2. Veri Toplama ve Açıklama

Bu çalışmada, tahmin sürecinde kullanılan veriler Obruk Barajı hidroelektrik santrali için izleme programı tarafından depolanan veritabanından elde edilmiştir. Sistem, yeni okumayı dakika dakika veritabanlarına girer. Veri seti, 1 Ocak 2020'den 31 Aralık 2021'e kadar toplanan 523.373 satır ve 45 sütun veriden oluşmaktadır. Veri setindeki temel özellikler, frekans, sıcaklık, basınç, barajdaki su hacmi, yükseklik, üretim hacmi ve jeneratör frekansı dahil olmak üzere sistemin kararlılığını etkileyen tüm değişkenler için tarih, saat, haftanın günü, hafta numarası, ay ve yıldır.

Aşağıdaki tablolar, titreşim (Çizelge 3.2.), basınç (Çizelge 3.3.) ve sıcaklık (Çizelge 3.4.) dahil olmak üzere her biri on kaydı temsil eden bir veri kümesinin örneğini sunmaktadır. Üretici tarafından normal, kararlı ve kritik olarak kabul edilen değerler ve tehlikeli bir durumu temsil eden değerler için belirlenen sınırlar, tüm veriler için benimsenmiş ve tahmin sistemindeki nihai kararlılık durumunu belirlemek için kullanılmıştır. (Çizelge 3.4.), basınç (Çizelge 3.5.), sıcaklık (Çizelge 3.6.) ve titreşim (Çizelge 3.7.) dahil olmak üzere kararlı durum üzerinde doğrudan etkisi olan bir veri grubu için tanımlayıcı ölçümler sunmaktadır.

Çizelge 3. 2. Tahminde on kaydı temsil eden bir titreşim verisi seti kullanılmıştır.

Zaman	Vib.U3 Alt Kılavuz	Vib.U3 (Türbin Kılavuz Yatağı)	Vib.U3 (Üst Kılavuz B.)	Birleş Vib. Güç	Vib.U3 Alt Kılavuz	Vib.U3 (Türbin Kılavuz Yatağı)	Vib.U3 (Üst Kılavuz B.)	Birleş Vib. Güç
8/9/2021 10:35	74.7	82.6	135	34.9	74.8	82.7	135	34.9
8/9/2021 10:40	76.0	79.4	129	34.8	76.1	79.5	129	34.8
8/9/2021 10:45	77.4	78.8	127	34.8	77.5	78.9	127	34.8
8/9/2021 10:50	75.3	82.4	124	35.5	75.4	82.4	124	35.5
8/9/2021 10:55	74.5	82.3	124	35.7	74.5	82.3	124	35.7
8/9/2021 11:00	74.5	81.8	123	35.8	74.5	81.9	123	35.8
8/9/2021 11:05	74.6	85.8	123	35.7	74.6	85.9	123	35.7
8/9/2021 11:10	74.3	82.2	123	35.7	74.3	82.3	123	35.7
8/9/2021 11:15	73.6	85.1	125	35.7	73.6	85.2	125	35.7
8/9/2021 11:20	73.5	86.9	126	35.7	73.5	86.10	126	35.7

Çizelge 3. 3. Tahminde on kaydı temsil eden bir basınç verisi seti kullanılmıştır.

Zaman	Başlık Kapağı Vakum Basıncı (MPa)	Ana Şaft Sızdırmazlık Basıncı (MPa)	Taslak Boru Giriş Basıncı (MPa)	Taslak Boru Çıkış Basıncı (MPa)	Su Başlığı Fark Basıncı (MPa)	Kelebek Vana Yağ Basıncı (MPa)	Vali Yağ Basıncı (MPa)
8/9/2021 10:35	0.161413	0.187875	-0.0144	0.050831	0.6016	16.27969	6.19
8/9/2021 10:40	0.174763	0.188625	-0.01363	0.051038	0.5957	16.14531	6.11
8/9/2021 10:45	0.176075	0.18835	-0.01758	0.050925	0.6022	16.11094	6.06
8/9/2021 10:50	0.176525	0.189475	-0.01465	0.051206	0.5983	16.07813	6.02
8/9/2021 10:55	0.1781	0.186775	-0.01365	0.051338	0.593	16.07813	5.96
8/9/2021 11:00	0.178513	0.1885	-0.01297	0.051431	0.5886	16.04375	5.93
8/9/2021 11:05	0.177613	0.188275	-0.01522	0.051019	0.5995	16.04375	5.92
8/9/2021 11:10	0.180913	0.18665	-0.01477	0.051094	0.5955	16.00781	5.89
8/9/2021 11:15	0.179638	0.187175	-0.01463	0.051113	0.5832	16.00781	5.87

Çizelge 3. 4. Tahminde on kaydı temsil eden bir sıcaklık verisi seti kullanılmıştır.

Zaman	İtme Yatağı Pabucu Sıcaklık1 (C°)	Üst Kılavuz Yatak Pabucu Sıcaklığı2 (C°)	Alt Kılavuz Yatak Pabucu Sıcaklığı 1 (C°)	Alt Kılavuz Yatak Pabucu Sıcaklığı2 (C°)	Ana Trafo Yağ Sıcaklığı (C°)	Ana Trafo Sargı Sıcaklığı (C°)	G. Stator Sıcaklığı Z1 (C°)	G. Stator Sıcaklığı Z11 (C°)
8/9/2021 10:35	32.12813	38.52188	28.91251	27.69376	18.58125	22.71563	34.17	36.49
8/9/2021 10:40	31.93125	41.50313	29.50313	28.28438	18.77813	22.9125	36.65	39.33
8/9/2021 10:45	31.93125	42.4875	29.89688	28.67813	18.975	23.30625	38.24	41.45
8/9/2021 10:50	31.93125	43.07813	30.29063	28.875	19.36875	23.50313	39.65	43.05
8/9/2021 10:55	31.93125	43.47188	30.4875	29.07188	19.7625	23.89688	40.71	44.47
8/9/2021 11:00	32.12813	43.86563	30.4875	29.26875	20.55	24.88125	41.6	45.53
8/9/2021 11:05	32.12813	44.0625	30.68438	29.26875	21.73125	25.86563	42.31	46.24
8/9/2021 11:10	32.12813	44.25938	30.68438	29.46563	22.71563	27.04688	43.01	46.95
8/9/2021 11:15	32.12813	44.45625	30.88126	29.46563	23.89688	28.03125	43.54	47.66
8/9/2021 11:20	32.12813	44.65313	30.88126	29.46563	24.88125	28.81876	44.08	48.19

Çizelge 3. 5. Basınç verisi limitleri.

Değer	Başlık Vakum Basıncı (MPa)	Ana Şaft Sızdırma zlık Basıncı (MPa)	Taslak Boru Giriş Basıncı (MPa)	Taslak Boru Çıkış Basıncı (MPa)	Su Başlığı Fark Basıncı (MPa)	Kelebek Vana Yağ Basıncı (MPa)	Spiral Kasa Giriş Basıncı (MPa)	Spiral Kasa Çıkış Basıncı (MPa)	Vali Yağ Basıncı (MPa)
Min Acil Durdurma									5
Min Nominal Değer	-0.1	0	-0.1	0	0	13.5	0	0	5.8
Maksimum Nominal Değer	0.5	0.4	0.3	0.3	1.6	17.5	1.6	1.6	6.3
Maksimum Acil Durdurma	0.51	0.41	0.31	0.31	1.61	17.51	1.61	1.61	6.31

Çizelge 3. 6. Güç, voltaj, hız, seviye ve cos α veri sınırları.

Değer	154 kV Bara Gerilimi (kV)	Birim Hız (%)	Jeneratör Aktif Güç (MW)	Jeneratör Reaktif Güç (MVar)	JeneratörC os α	Vali Petrol Seviyesi (cm)	BARAJ Kuyruk Suyu (m)	BARAJ Su Seviyesi (m)
Min Nominal Değer	140	0%	0	-17	0.9	50	443.3	506
Maksimum Nominal Değer	170	100%	52.7	30	0.9	90	446	510
Maksimum Acil Durdurma		140%						

Çizelge 3. 7. Sıcaklık verisi limitleri.

Değer	YUKAR		Alt		Alt		Türbin			
	İtme Yatağı Pabucu Sıcaklığı (C°)	I. Kılavuz Yatağı Pabucu Sıcaklığı (C°)	Alt Kılavu z Yatak Pabucu Sıcaklı ğı (C°)	Kılavuz Yatak Yağ Yuvası Sıcaklı ğı (C°)	Ana Trafo Yağ Sıcaklı ğı (C°)	Ana Trafo Sarma Sıcaklı ğı (C°)	Kılavuz Yatak Pabucu Sıcaklı ğı (C°)	Jeneratör Stator Sıcaklığı Z1 (C°)	Jeneratör Stator Sıcaklığı Z11 (C°)	Jeneratör Stator Sıcaklığı Z29 (C°)
Min Nominal Değer								40	40	40
Maksimum Nominal Değer								105	105	105
Maksimum Acil Durdurma	65	65	65	65	95	110	65			

Barajdan alınan türbinler ve elektrik jeneratörleri için veriler, iletim şaftı dahil, dengesiz ve dalgalıdır ve ayrıca X Çizelge 3.2.- 3.4.'te gösterildiği gibi bir sensörden diğerine değerler açısından farklılık gösterir ve sınırlamaları Çizelge 3.5.-3.7.'de açıkça gösterilmiştir. Buna göre, veriler tahmin sürecinde kullanılmak üzere nitelendirilmek üzere çeşitli analiz, filtreleme ve hazırlama aşamalarından geçecektir.

3.2.3.3. Keşifsel Veri Analizi (EDA)

Bu bölümde, sistem kararlılığını etkileyen değişkenlerle ilgili tüm keşifsel veriler çıkarılır ve incelenir. Keşifsel verileri analiz etmek, verilerdeki çeşitli gizli kalıpları, bağlantıları ve özellikleri aramayı içerir. Veriler, kutu çizimi, otomatik korelasyon ve çizgi çizimi dahil olmak üzere bir dizi teknik kullanılarak analiz edildi ve incelendi. Zaman serisi tahmin modelleri geliştirmek için gerekli olan EDA'nın temel özelliklerinden biri, çeşitli değişkenler arasındaki ilişkilerde daha önce keşfedilmemiş kalıpları görselleştirme, inceleme ve ortaya çıkarma kapasitesidir [301].

Korelasyon

İki veya daha fazla değişken arasındaki doğrusal ilişkiyi ölçmek için korelasyon olarak bilinen istatistiksel bir yöntem kullanılır. Korelasyon, bir değişkeni diğerine göre tahmin etmek için kullanılabilir.

Özellikleri seçmek için korelasyon analizini kullanmanın ardındaki teori, yardımcı faktörler ile sonuç arasında önemli korelasyonların bulunacağıdır. Kısa vadeli yük tahminlerini öngörebilen ve veri setinin bileşenleri arasındaki ilişkiyi araştırabilen derin öğrenme modeli oluşturmak için yeterli bağlantı olup olmadığını belirlemek amacıyla, ısı haritası özellikler arasındaki korelasyon oranını anlamaya yardımcı olur. Isı haritasını oluşturmak için seaborn paketi ve Python matplotlib kullanıldı. Denklem 3.15., bileşenler arasındaki korelasyon katsayısını (r) elde etmek için kullanılır [302].

$$r = \frac{\sum(x_i - x^-)(y_i - y^-)}{\sqrt{\sum(x_i - x^-)^2 \sum(y_i - y^-)^2}} \quad (3.17)$$

Burada r = korelasyon katsayısı, x_i = bir örneklemden x -değişkeninin değerleri, x^- = x -değişkeninin değerlerinin ortalaması, y_i = bir örneklemden y -değişkeninin değerleri ve y^- = y -değişkeninin değerlerinin ortalamasıdır.

Şekil 3.16., veri kümeleri içindeki özellikler arasındaki korelasyon kümesini gösterir ve basınç değişkenlerinin kendileri, titreşim ve sıcaklığın kendileri gibi kararlılık üzerinde doğrudan etkisi olan bir dizi değişken arasında ve değişkenlerin yıl boyunca günlere göre zamana göre toplamaları arasında korelasyonlar olduğu görülebilir. Verilerdeki değişkenler arasındaki karşılıklı ilişki, pozitif veya negatif ilişki arasında değişirken, verilerin çoğu pozitif veya negatif ilişkiye yaklaşmaktadır.

Vibration	Vib.U3_ L. g. B_i_Smax	Vib.U3_ T.g. B_i_Smax	Vib.u3_ U. g. B_i_Smax	Unite_ Vib. POWER	Unite_vib.T. ab_X	U. Vib. T. ab_Y	U. Vib. gen. L. B. ab_X	U. Vib. gen. L. B. ab_Y	U. Vib. gen. up.gen. ab_X	U. Vib. gen. up.g. ab_Y
Vib.U3_ L. g. B_i_Smax										
Vib.U3_ T.g. B_i_Smax	-0.001366431									
Vib.u3_ U. g. B_i_Smax	0.235661689	0.49119253								
U_ Vib. Power	-0.31957437	0.17826055	-0.2321689							
U_vib.T. absolute_X	0.36350966	-0.2451681	0.04989059	-0.057775493						
U_Vib. T. absolute_Y	0.524737573	0.07860446	0.56763819	-0.375944048	0.396592462					
U_Vib.gen. L. B. ab_X	0.656965843	0.16353064	0.32062411	0.038675653	0.281364925	0.5945465				
U_Vib.gen. L. B. ab_Y	0.593115565	0.05615404	0.09199422	0.123999354	0.183819375	0.3537497	0.935726884			
U_Vib.gen. up.g. ab_X	0.360629781	0.2713139	0.47568476	-0.402151058	0.139077122	0.5051431	0.246115793	0.0361346		
U_Vib.gen. up.g. ab_Y	0.348644825	-0.3414176	-0.2046949	-0.608332167	0.168276909	0.1809307	-0.03032276	-0.0236363	0.318642334	

Şekil 3. 16. Veri setindeki titreşim özellikleri için korelasyon katsayısı.

Şekilde, Unite titreşim jeneratörü alt yatak mutlak-X (U. Vib. gen. L. B. ab._ X) ile Unite titreşim jeneratörü alt yatak mutlak-Y (U._vib.gen. L. B. ab._Y) arasında pozitif bir ilişki olduğu ve buna yakın olarak Unite titreşim jeneratörü alt yatak mutlak-X (U._Vib.gen. L. B._ab._X) ve Unite3 titreşim alt kılavuz yatak_i_Smax (Vib.U3. L. g. B._i_Smax) arasında pozitif bir ilişki olduğu, unite titreşim gücü ile Unite titreşim jeneratörü üst kılavuz mutlak-Y arasında negatif ilişkiler olduğu, geri kalan değerlerin renk tonlamasına göre pozitif ve negatif ilişkiler arasında değiştiği görülebilir, Şekil 68'te gösterildiği gibi.

Şekilde görülebileceği gibi, Ana trans. Su sıcaklığı ile Ana trafo yağ sıcaklığı ve ayrıca Jeneratör stator sıcaklığı arasında pozitif bir ilişki vardır. Z1 ve Jeneratör stator sıcaklığı Z11 ve diğer değerler ve İtme yatağı pabucu sıcaklığı 2 ile İtme B pabucu sıcaklığı 1 arasında negatif bir ilişki vardır. Diğer değerler, Şekil 3.17'te gösterildiği gibi renk derecelendirmesine göre pozitif ve negatif ilişkiler arasında değişmektedir

Temperature. (C°)	Thrust B. Shoe -1	Thrust B. Shoe-2	U. g. B. shoe-2	U. g. B. shoe-2	L. g. B. Shoe-1	L. g. B. Shoe-2	Main trans. oil	Main trans. Winding	G. Stator Z1	G. stator Z11	G. stator Z29
Thrust bearing shoe-1											
Thrust bearing shoe-2	0.62944083										
U. g. bearing shoe-1	0.94934888	0.6910291									
U. g. bearing shoe-2	0.92168332	0.6784506	0.980462								
L. g. bearing shoe-1	0.80121231	0.7374204	0.892337	0.923387							
L. g. bearing shoe-2	0.86284948	0.6185789	0.912068	0.95672	0.898424						
Main transformer oil	0.87047119	0.6603238	0.893778	0.8590971	0.746914	0.7681553					
Main tran. W.	0.8902844	0.6444584	0.9045	0.8681001	0.740662	0.7780163	0.9927986				
Generator stator-Z1	0.8359681	0.7077984	0.930788	0.9143323	0.895532	0.8175581	0.8839284	0.870021853			
Generator stator-Z11	0.83353689	0.697739	0.929753	0.9161788	0.898332	0.8240871	0.879535	0.866147317	0.9991277		
Generator stator-Z29	0.84977305	0.6972815	0.942174	0.9274193	0.902193	0.8359127	0.8814689	0.870734107	0.9982969	0.9986598	

Şekil 3. 17. Veri setindeki sıcaklık özellikleri için korelasyon katsayısı.

Basınç açısından, değişkenler arasındaki karşılıklı ilişki yoluyla, basınç, titreşim ve sıcaklık etkisine kıyasla daha az etkiye sahip olduğu, değerler pozitif bir ilişkiye (örneğin Su başı diff. basıncı ile Spiral kasa çıkış basıncı arasındaki ilişki) ve negatif bir ilişkiye (örneğin ana şaft sızdırmazlık basıncı ile kelebek vana yağ basıncı arasındaki ilişki) yaklaştıkça, Şekil 3.18'da gösterildiği gibi not edilir.

Pressure (MPa)	Head cover vacuum	Main shaft sealing	Draft tube inlet	Draft tube exit	Water head diff.	Butterfly valve oil	Spiral case inlet	Spiral case exit	Governor oil
Head cover vacuum									
Main shaft sealing	-0.0288459								
Draft tube inlet	0.1366941	-0.067538							
Draft tube exit	-0.0112541	-0.123464	-0.018941						
Water head diff.	-0.0874159	-0.10312	-0.094316	0.0388512					
Butterfly valve oil	-0.0329494	-0.576585	0.080326	0.2024537	0.2497647				
Spiral case inlet	-5.107E-15	-5.49E-14	3.17E-15	-5.7E-13	-5.26E-13	6.09E-13			
Spiral case exit	-0.1263832	-0.028508	-0.157533	0.0927853	0.3784189	0.190251	-2.01E-13		
Governor oil	0.0069225	0.033291	-0.013246	-0.001015	0.0287657	0.002642	-9.08E-16	0.0252755	

Şekil 3. 18. Veri setindeki basınç özellikleri için korelasyon katsayısı.

Birleştirilmiş farklı değişkenlerin veritabanına gelince, barajdaki su seviyesindeki artışın titreşim ve sıcaklıktan daha az önemli olmayan doğrudan bir etkisi olduğunu fark ediyoruz. Burada, barajdaki su seviyesinin ve diğer değişkenlerin etkisine bağlı pozitif ve negatif bir ilişki olduğu not edilir. Şekil 3.19'deki renk derecelendirmesiyle


gösterildiği gibi, Baraj Su Başı seviyesi ile titreşim ünitesi 3 T. kılavuz B arasında pozitif bir ilişkinin yanı sıra, Baraj Su Başı seviyesi ile Kelebek vana basıncı arasında negatif bir ilişkinin olduğu belirtilmektedir.

	Vib.U3 L. g. B i Smax	Vib.U3_ T. guide B	Unite Vib. P.	Thrust B. S. T.1 (C°)	Thrust B. S. T.2 (C°)	U. g. B. S. T.1 (C°)	H. C. V. P. (MPa)	Draft tube inlet P. (MPa)	Spiral case inlet P. (MPa)	DAM WaterH level (m)
Vib.U3_ L. g. B_i Smax										
Vib.U3_ T. guide B	-0.23457									
Unite Vib. POWER	-0.21312	0.14403								
Th. B. Shoe T.1 (C°)	0.561642	-0.1659	0.0637							
Th. B. shoe T.2 (C°)	0.553877	-0.2101	0.165	0.77277						
U. g. B. shoe T.1 (C°)	0.380975	0.21117	0.0589	0.48647	0.37443					
H. cover V. P. (MPa)	-0.04516	0.06283	0.1596	0.00546	0.05184	0.096				
D. tube inlet P. (MPa)	-0.00164	0.02319	0.0484	0.04848	0.04974	-0.0134	0.13669			
S. case inlet P. (MPa)	-9.9E-15	1.1E-14	-3E-12	3.1E-12	1.8E-12	6.7E-13	-5E-15	3.2E-15		
DAM W. H. level (m)	0.493673	-0.3878	0.1124	0.75144	0.7674	-0.0606	-0.0311	0.06829	4.5E-12	


Şekil 3. 19. Veri setindeki farklı değişkenlerin birleşik özelliklerinin veritabanı için korelasyon katsayısı.

Sistem Kararlılık Davranışı Analizi

Sistem kararlılığının zaman serisini analiz etme süreciyle, günlük, haftalık, aylık ve gün boyunca kararlılık ve kararsızlık zamanları belirlenebilir. Şekil 3.20. ve 3.21., zaman içindeki kararlılık davranışının doğasını gösterir. Bu, verilerin tekrarlı mı yoksa rastgele mi olduğunu belirlemeyi kolaylaştırır. Ek olarak, veri setindeki belirli sayıların dağılımını gösteren birkaç istatistiksel ölçüm sağlanır.



Şekil 3. 20. Zaman içinde haftanın günlerindeki sistem kararlılığı (8 Ağustos 2021 - 15 Ağustos 2021).



Şekil 3. 21. Sistemin kararlılığının doğası.


Verileri Temizleme

NaN'leri kaldırmak, veri setinin NaN değerlerini doğruladıktan sonra veri filtrelemedeki ilk adımdır. Tahmini daha etkili ve doğru hale getirmek için, sensörün hiçbir veri göndermediği bölümler sıfır değerleriyle karıştırılmamalıdır; bu, değer in aslında sıfır olduğu anlamına gelebilir (bir veri setinde çok fazla sıfır olması, onu seyrek bir veri seti yapar).

Sınıflandırma aradığımız için, softmax aktivasyonunun kategorileri doğru şekilde yorumlaması ve kategori sırasını (0,1,2) derecelendirme veya önem olarak yanlış yorumlamaması için hedefimizi eğitimden önce bir kez kodlamamız gerekir. Bu, sklearn.preprocessing.OneHotEncode () işlevi kullanılarak gerçekleştirilir.

3.2.3.4. Tahmin Metodolojisi

Bu bölüm, Şekil 3.23.'de gösterildiği gibi, sistemin gerçek veri kümesinde LSTM algoritmalarına dayalı bir RNN algoritması kullanarak bir baraj türbini sisteminin sabit durumunu tahmin etmek için bir yöntem sunar. İlk olarak, veri kümesi oluşturulur ve özellik seçimi ve normalizasyon gibi ön işleme adımları açıklanır. Daha sonra, geçmiş verilere dayalı olarak kısa vadeli yükleri tahmin etmek için derin öğrenme kullanılarak modeller oluşturulur ve eğitilir. Bu modeller LSTM ve RNN'dir. Daha sonra her makine öğrenimi modelinin doğruluğu, optimize edici, aktivasyon işlevi, öğrenme oranı, dönem sayısı, parti boyutu ve gizli katman sayısını içeren performans ölçümleri ve hiperparametre ayarlamaları kullanılarak değerlendirildi. En doğru tahmin modelini seçin. Python ve Pandas, Seaborn, Sklearn, Matplotlib, TensorFlow ve NumPy kütüphaneleri kullanılarak bu makaledeki tüm modeller oluşturuldu.



Şekil 3. 23. HES durum tahmin algoritmalarının metodolojisi.

LSTM'lerde, zaman serisi analizi açısından katman sayısı bellek hücresi sayısından daha önemlidir. Buradaki kural, gizli birim (bellek hücresi) sayısının giriş özelliklerinden daha az olmasıdır.

Her biri 42 gizli birim ve iki çıktı katmanını içeren iki LSTM katmanını kullanıldı. Burada basit bir tek çıktı seri modeli kullanabilirsiniz. İki durumumuz var ve farklı kullanım durumlarını göstermek istiyoruz. Signal_out, bize beklenen bir sinyal veren 1 birimlik yoğun bir katmandır, class_out ise 3 birimlik yoğun bir katmandır ve softmax'i etkinleştirmek bize beklenen "Normal", "Kurtarıyor" ve "Bozuk" sınıflarını verir.

3.2.3.5. Veri Ön İşleme

Verileri hazırlamak ve işlemek, makine öğrenimi modelinin eğitilmesinde ilk adımdır ve veri yapısını en iyi şekilde kullanmasını sağlar. Veriler uygun şekilde hazırlanmazsa makine öğrenimi modeli genellikle tahminde yüksek verimlilik sağlamaz ve bu, kötü ve başarısız oldukları için sonuçlara yansır. Başlatma ve ön işlemede yardımcı olmak için farklı alt optimizasyon adımları kullanılabilir [305]. Veri normalizasyonu ve yüksek oranda ilişkili özelliklerin kaldırılması, hedef özellikle çok az korelasyonu olan özelliklerin kaldırılması, aykırı değerlerin ortadan kaldırılması ve orijinal verilerdeki boş değerlerin değerlendirilmesiyle birlikte veritabanında kullanılmıştır. Teknikler bir sonraki bölümde tam olarak açıklanacaktır.

Şekil 3.23., verilerin kaynaktan toplanması ve alınması gereken üç temel aşamadan geçen hidroelektrik santrali durum tahmin algoritmaları oluşturma metodolojisini göstermektedir. İlk adım, başlatma, normalleştirme ve özellik seçimi gibi birkaç alt optimizasyon adımını içeren veri işlemeyle ilgilidir. Daha sonra, Huber parametresinin ayarlanması, modelin eğitilmesi, modelin test edilmesi ve son olarak modelin doğrulanması gibi işlemleri içeren ikinci adımda model oluşturulur ve eğitilir. Üçüncü ve son adım, dağıtım, tahmin ve toplu kayıt işlemlerini içerir.

BÖLÜM 4

SONUÇLAR VE TARTIŞMA


Bu araştırmada, Türkiye'de elektrik enerjisi üretmek için Obruk Barajı'nın türbinlerinin kararlılık durumu, dünyadaki diğer hidroelektrik santrallerini simüle etmek için bir model olarak, aynı barajdan kararlılıklarını etkileyen değişkenler için elde edilen devasa veri tabanı aracılığıyla çeşitli derin öğrenme algoritmaları kullanılarak simüle edildi. Seçilen modellerin (RNN ve LSTM) verimliliği, yüksek etkinliklerini ve gelişmiş performanslarını sağlamak için verimli performans ölçümleri kullanılarak değerlendirildi.

4.1. KONTROL SİSTEMİ

GUI iki amaç için tasarlanmıştır: Birincisi titreşim, basınç, sıcaklık ve diğer faktörlerin grafiğini çıkarmaktır, ikincisi ise Şekil .4.1'de gösterildiği gibi türbine su akış kapısının açılıp kapanmasını kontrol etmektir. GUI iki grafiksel pencere içerir. Grafiksel pencereler türbinlerin titreşim, basınç ve sıcaklık sonuçlarını görüntüler. İkinci bölüm kontroldür; GUI, kullanıcının işini kolaylaştırmak için ekrandaki düğmeler aracılığıyla baraj kapılarını açma ve kapatma erişimini içerir.

Kullanıcı açılır pencereden başlar: i) Erişim sürecini kolaylaştırmak için kullanılan kapının seçildiği Adım 1. Bu arayüz ayrıca kullanıcının, Adım (2)'de alınabilecek önlem tedbirleri için kullanıcı tarafından titreşimler, basınç ve sıcaklıklar için minimum değerler olarak kabul edilen sınırları tanımlamasını sağlar; kritik aşama durumlarının başladığı ve buna göre gözlemciyi uyarmak için bir uyarı sinyali göndermek gibi uygun kararların alındığı; (3) Adım 3, grafiğin başladığı grafik düğmesine (çizim) tıklamaktır ve aynı düğmeye basılarak grafik durdurulacaktır; 4) Adım 4, GUI, üç durum için sensörlerin durumunu gösteren bir dizi renkli kutu içerir (normal, kritik ve tehlikeli), her sensör bir renkli kutuyla ilişkilendirilir, normal

durumda yeşil, kritik durumda sarı ve tehlike durumunda kırmızı olur ve dördüncü panelde gösterildiği gibi kapıları açmak ve kapatmak için düğmeler [26].



Şekil 4. 1. İzleme sistemi için GUI


Kontrolör iki görev için programlanmıştır: 1) Birincisi, sensörler aracılığıyla titreşim sinyalini, basıncı, sıcaklığı ve diğer faktörleri izlemek ve bunları grafiksel kullanıcı arayüzünde görüntülenmek üzere iletmek ve 2) İkincisi, kapılar açılıp kapanmasını kontrol etmektir; karar iki şekilde verilir, birincisi kontrolör aracılığıyla, ikincisi gözlemci aracılığıyla. Karar, aşırı tehlike durumunda kontrolör tarafından verilir ve tahmin süreci, titreşim, basınç ve sıcaklıktaki ani artış ve tahmin algoritması aracılığıyla belirlenen maksimum tehlike seviyesinin aşılması nedeniyle herhangi bir felaketi önlemek için proaktif bir tedavi olmak üzere yapılır ve alarmı çalıştırma ve türbinlere su akışını kesmek için kapıyı kapatma kararı verilir ve böylece koşucu kanatlarının kırılmasına yol açabilecek herhangi bir hasar önlenir.

Tehlike aşaması hariç, kontrol, eşik aşamasında veya başka bir şekilde kapıları açma ve kapatma kararını verme özgürlüğüne sahip olan gözlemci tarafından yapılır. Titreşim, basınç veya sıcaklık kullanıcı tarafından belirlenen sınıra ulaşırsa, grafiksel kullanıcı arayüzüne yerleştirilen düğmeler aracılığıyla sinyal daha da arttığında gözlemciyi uygun eylemi yapması için uyarmak üzere alarm cihazını etkinleştirmek üzere bir sinyal tetiklenir.

Bu projenin sonuçları Şekil 4.1 ve 4.2.'de gösterildiği gibi iki modelde temsil edilmektedir. Şekil 4.1.'de gösterilen ilk modelde, ilk türbinin titreşimi tehlike eşiğini aşmaktadır; bu nedenle, kırmızı ışık bu durumu gösterir ve ardından alarm çalışmaya başlar ve karar bölüm 2.3'te belirtilenlere göre verilir. İkinci model Şekil 4.2.'de temsil edilmektedir. Titreşim ve sıcaklığın ikinci türbin için tehlike eşiğini aştığını gösterir ve bu, sinyal göstergelerinin görünümü ve ikinci türbinin iki renkli kutularının kırmızı olarak görünmesiyle belirtilir.

Çizelge 4.1, ilk modelin sonuçlarının analizini göstermektedir, titreşim ve sıcaklığın mevcut değerini her biri için eşik değeriyle karşılaştırarak, ilk türbinin titreşim değerinin eşiği yükselttiğini ve bu nedenle tehlike durumunda olduğunu buluyoruz ve bu durum kırmızı renkli kutunun görünmesiyle açıkça gösterilmektedir. Kalan değerler için, eşiğin altındadırlar, bu nedenle normal durumdadırlar, çünkü renkli kutular yeşil renkte gösterilmiştir.

Çizelge 4.2, ikinci modelin sonuçlarının analizini göstermektedir. Bu türbinler için iki farklı durum göstermektedir. İlk türbinin titreşim değeri ve sıcaklığı eşiğin altındadır, bu nedenle normal durumdadırlar. İki renkli kutuların yeşil renkte görünmesi bu durumu açıkça göstermektedir. Dahası, ikinci türbinin titreşim değeri ve sıcaklığı eşiği aşmıştır, bu nedenle tehlikeli durumdadır. Bu durum oluştuğunda, renkli kutular kırmızı olacaktır.



Şekil 4. 2. İzleme sistemi için GUI

Çizelge 4. 1. İlk model için kurallar

Türbin	Sensör	Eşik	Akım	Renk	Durum
1	Titreşim_1	5	5.9	Kırmızı	Risk
2	Titreşim_2	5	4.75	Yeşil	Doğal
1	Sıcaklık_1	80	29.2	Yeşil	Doğal
2	Sıcaklık_2	80	26.5	Yeşil	Doğal

Çizelge 4. 2. İkinci model için kurallar

Türbin	Sensör	Eşik	Akım	Renk	Durum
1	Titreşim_1	5	4.9	Yeşil	Doğal
2	Titreşim_2	5	6.22	Kırmızı	Risk
1	Sıcaklık_1	30	28.2	Yeşil	Doğal
2	Sıcaklık_2	30	31	Kırmızı	Risk

4.2. TAHMİN SONUÇLARI

Tahmin algoritmaları, ideal olana yakın en yüksek ve en iyi tahmin sonucunu elde etmek için oluşturulur. Her modelden elde edilen sonuçlar arasında ideal sonucu elde etmek için en iyi yöntemler kullanıldı ve test edildi, bu sonucu testten sonra elde etmek için en iyi optimizasyon tipinin seçilmesi dikkate alındı. Test ayrıca, gizli katman sayısı, öğrenme oranı, aktivasyon fonksiyonu tipi ve parti boyutu gibi tahmin doğruluğunu etkileyen çeşitli faktörlere göre de dahil edildi.

Sonucu elde etmek için farklı eğitim ve test oranlarıyla iki tahmin modeli (LSTM, RNN) uygulandı. En iyi sonucu verebilecek en iyi değerin %67 eğitim ve %33 test olduğu bulundu. En iyi sonuçlar, seçilen optimizasyon tiplerini test ettikten ve her modelde farklı bir öğrenme oranıyla en iyi sonuçları elde ettikten sonra elde edildi. Aşağıdaki bölümlerde sonuçlar, en iyi optimizasyon tipinin seçilmesi ve farklı sayıda gizli katman ve etki eden faktörlerle en iyi kayıp hesaplama fonksiyonu tipleri tartışılmaktadır.

4.1.1. Adam Optimizer ile RNN ve LSTM Modellerini Kullanarak Tahmin

Bu bölüm, kullanılan tahmin algoritmalarından elde edilen sonuçları paylaşır, bu algoritmaların performansını iyileştirmek için kullanılan yöntemleri ve mekanizmaları karşılaştırır ve farklı sayıda katman, çeşitli optimizasyon mekanizmaları, farklı kayıp hesaplama yöntemleri ve farklı öğrenme oranları kullanarak hem LSTM hem de RNN algoritmaları için en iyi sonuçları elde etmek için en iyisini seçer.

Her seferinde bir algoritma en iyisini seçmek üzere eğitildiğinde farklı algoritma modelleri, optimize ediciler ve diğer yardımcı faktörler kullanılır. Her modeldeki giriş ve çıkış katmanlarına ek olarak, Adam optimizasyonu ile başlayarak tek, çift ve üçlü katmanlar kullanılır.

Eğitim, ikinci optimize edici türü olan RMSprop ile aynı mekanizma kullanılarak gerçekleştirilir ve ardından üçüncü ve dördüncü optimize edici türleri olan Adagrad ve Adadelat ile tekrarlanır. Algoritmaları değerlendirmede kullanılan en önemli

faktörlerden biri, üç farklı yöntem kullanılarak kayıpların hesaplanmasıdır: MSE, MAE ve RMSE.


Algoritma sonuçları, iki grafik gösteren bir grafikte gösterilir: mavi renkteki ilk grafik gerçek sonuçları, turuncu renkteki ikinci grafik ise tahmin edilen sonuçları temsil eder.

Figure 4.3 shows the prediction results obtained using LSTM and RNN algorithms with a single hidden layer, three loss calculation methods, and two learning rates (0.01 and 0.001). The training process also shows the test results obtained for each learning rate.


When different test results were obtained for both LSTM and RNN models and compared, the LSTM model with two learning rates and different loss calculation methods achieved the best prediction accuracy among the results for different layers and learning rates used compared to the RNN model, reaching 99.55%, which is roughly equivalent to the training expected value of 99.23%. This can be clearly seen by comparing the error rates of the different methods and functions used to predict the system's steady state.

Zirve en düşük seviyedeydi. En düşük kayıp değeri $MSE = 0,0072$ idi. MAE 0,0053 idi ve hata oranı 0,001 idi. $RMSE$, 0,001 öğrenme oranında 0,0551 idi. Bu faktörler, benimsenecek en iyi modeli seçmeye etkili bir şekilde katkıda bulunacaktır. RNN modeli tek katman ve 0.001 öğrenme oranı ile en iyi tahmin doğruluğunu elde ederken, bu değer beklenen değer olan %97.91'e biraz daha yakın olan %98.31'dir, kayıp değeri ise en düşük değer olan $MSE = 0.0513$ 'e ulaşmıştır. MAE ise 0.0175 ve $RMSE$ ise 0.0846'dır, öğrenme oranı ise 0.001'dir.

LSTM Tahmin sonuçları HPP istasyonu sabit durumu için



RNN Tahmin sonuçları HPP istasyonu sabit durumu için




Şekil 4. 3. Adam optimizatörü ve bir katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.

Şekil 4.4, iki gizli katman, üç kayıp hesaplama yöntemi ve önceki sonuçlarda kullanılan aynı öğrenme oranları kullanılarak iki algoritma modelinden elde edilen sonuçları ve LSTM ve RNN algoritmaları kullanılarak elde edilen eğitim sonuçlarını göstermektedir. Eğitim süreci, çeşitli optimize ediciler ve farklı öğrenme oranları için elde edilen test sonuçlarını göstermektedir.


Hem LSTM hem de RNN modelleri için farklı test sonuçları elde edilmiş ve farklı öğrenme oranları ve kayıp hesaplama yöntemleri ile karşılaştırılmıştır. LSTM modeli, kullanılan çeşitli katmanlar ve öğrenme oranları için en iyi tahminin %99,40'ını elde etmiştir; bu, eğitim için beklenen %98,24'e kabaca eşdeğerdir. Bu, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan farklı yöntem ve fonksiyonların hata oranlarını karşılaştırarak açıkça görülebilir.

The peak was at its lowest. The lowest loss value was $MSE = 0.0117$. The MAE was 0.0058, and the error rate was 0.001. The RMSE was 0.0553 at a learning rate of 0.001. These factors will effectively contribute to selecting the optimal model. While the RNN model achieved the best prediction accuracy using a single layer and a learning rate of 0.001, which is 98.12%, slightly closer to the expected value of 98.24%, the loss value was the lowest, with an MSE of 0.0603. The MAE was 0.0251 and the RMSE was 0.1007, at a learning rate of 0.001.

LSTM Tahmin sonuçları HPP istasyonunun sabit durumu için



RNN Tahmin sonuçları HPP istasyonunun sabit durumu için




Şekil 4. 4. Adam optimizatörü ve iki katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.

Şekil 4.5, üç gizli katman, üç kayıp hesaplama yöntemi ve iki öğrenme oranı ile LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca her öğrenme oranı için elde edilen test sonuçlarını göstermektedir.


Hem LSTM hem de RNN modelleri için çeşitli test sonuçları elde edildiğinde ve farklı öğrenme oranları ve kayıp hesaplama yöntemleri ile karşılaştırıldığında, LSTM modeli kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %99,34'e ulaşmıştır; bu da eğitim için beklenen %99,01 değerine kabaca eşdeğerdir. Bu ayrıca, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan çeşitli yöntemlerin ve işlevlerin hata oranlarını karşılaştırarak da açıkça görülebilir.

Zirve en düşük seviyesindeydi. En düşük kayıp değeri $MSE = 0,0136$ idi. MAE 0,0057 idi ve hata oranı 0,001 idi. $RMSE$, 0,001 öğrenme oranında 0,0563 idi. Bu faktörler, en uygun modeli seçmeye etkili bir şekilde katkıda bulunacaktır. RNN modeli, %91,58 olan ve beklenen %95,16 değerine biraz daha yakın olan 0,001'lik bir öğrenme oranı ve tek bir katman kullanarak en iyi tahmin doğruluğunu elde ederken, kayıp değeri 0,1099'luk bir MSE ile en düşüktü. MAE 0,0674 ve $RMSE$ 0,1689'du ve öğrenme oranı 0,001'di.

HPP istasyonunun sabit durumu için LSTM Tahmin sonuçları



HPP istasyonunun sabit durumu için RNN Tahmin sonuçları



Şekil 4. 5. Adam optimizatörü ve üç katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.

Çizelge 4.3, seçilen iki model (RNN ve LSTM) için deneysel prosedürlerle elde edilen sonuçları göstermektedir. Gösterildiği gibi eğitim prosedürleri, iki modelin eğitim sonuçlarını etkileyen çeşitli faktörlerin kullanımını içeriyordu. Bunlar, modellerin bir, iki ve üç gizli katmanla test edilmesini, ardından 0,01 ve 0,001 eğitim oranlarıyla test edilmesini ve kayıpları hesaplamak için üç yöntemi içeriyordu: MSE, MAE ve RMSE.

Çeşitli sonuçlar gözden geçirildiğinde en yüksek doğruluk ve en düşük hata ile en iyi sonuçların %99,55 doğruluk oranıyla LSTM modeliyle elde edildiği görülmüştür. En düşük kayıplar MSE ile 0,0072, MAE ile 0,0053 ve RMSE ile 0,0551 oldu. Bu sonuçların tümüne 0,001 öğrenme oranıyla ulaşıldı.

Bu sonuçlardan, Çizelge 4.3'te gösterildiği gibi LSTM modelinin Adam Optimizer kullanıldığında en iyi performansı gösterdiği sonucuna varıyoruz.

Çizelge 4. 3. Adam optimizasyon aracını kullanarak her iki model için tahmin sonuçları.

Modeli	Katman Sayısı	Öğrenme Oranı	Accuracy		MSE		MAE		RMSE	
			Acc	Val-Acc	Loss	Val-Loss	Loss	Var	Loss	Val
RNN	Bir gizli katman	0.01	0.7846	0.8185	0.2086	0.2197	0.2446	0.2270	0.3331	0.2988
		0.001	0.9831	0.9791	0.0513	0.0633	0.0175	0.0376	0.0846	0.1263
LSTM	Bir gizli katman	0.01	0.8120	0.8603	0.1835	0.1682	0.1662	0.1715	0.3035	0.2640
		0.001	0.9955	0.9923	0.0072	0.0093	0.0053	0.0172	0.0551	0.0827
RNN	İki gizli katman	0.01	0.6934	0.6825	0.2740	0.2815	0.2584	0.2449	0.4159	0.4198
		0.001	0.9812	0.9824	0.0603	0.0537	0.0251	0.0273	0.1007	0.1378
LSTM	İki gizli katman	0.01	0.7234	0.5952	0.2744	0.2610	0.2136	0.2124	0.3102	0.3121
		0.001	0.9940	0.9824	0.0117	0.0335	0.0058	0.0165	0.0553	0.0842
RNN	Üç gizli katman	0.01	0.5639	0.5325	0.3074	0.3105	0.2609	0.2469	0.3321	0.4412
		0.001	0.9158	0.9516	0.1099	0.0981	0.0674	0.0452	0.1689	0.1931
LSTM	Üç gizli katman	0.01	0.6324	0.5325	0.3074	0.3105	0.3436	0.3453	0.3282	0.3241
		0.001	0.9934	0.9901	0.0136	0.0397	0.0057	0.0178	0.0563	0.1488

4.1.2. RMSprop Optimizer ile LSTM ve RNN Algoritmalarını Kullanarak Tahmin


Bu bölüm, kullanılan tahmin algoritmalarından elde edilen sonuçları paylaşır ve bu algoritmaların performansını iyileştirmek için kullanılan yöntem ve mekanizmaları karşılaştırır, farklı katman sayıları, çoklu optimizasyon mekanizmaları ve kayıpları hesaplamak için farklı yöntemler kullanarak hem LSTM hem de RNN algoritmaları için en iyi sonuçları elde etmek için en uygun olanı seçer. Tüm test işlemlerindeki tüm algoritmalar 0,001 öğrenme oranıyla en yüksek sonuçları elde ettiğinden, kalan tüm testler 0,001 öğrenme oranıyla gerçekleştirilir.

Her modeldeki giriş ve çıkış katmanlarına ek olarak, RMSprop optimizatörüyle hem tek hem de çoklu gizli katmanlar kullanılır. Kayıpları hesaplamak için üç farklı yöntem kullanılır: MSE, MAE ve RMSE.


Sonuçlar iki grafikte sunulur: mavi renkteki ilki gerçek sonuçları, turuncu renkteki ikincisi ise tahmin edilen sonuçları temsil eder.

Şekil 4.6, tek gizli katman ve üç kayıp hesaplama yöntemi kullanılarak LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca her öğrenme oranı için elde edilen test sonuçlarını da göstermektedir. LSTM modeli, kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %97,93'e ulaşmıştır; bu da eğitim için beklenen %95,05 değerine kabaca eşdeğerdir. Bu, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan çeşitli yöntem ve fonksiyonların hata oranlarını karşılaştırarak da açıkça görülebilir. Tepe en düşük seviyedeydi. En düşük kayıp değeri MSE = 0,0494 idi. MAE 0,0279 idi ve hata oranı 0,001 idi. RMSE, 0,001'lik bir öğrenme oranında 0,1207 idi. Bu faktörler, benimsenecek en iyi modeli seçmeye etkili bir şekilde katkıda bulunur. RNN modeli, %96.82'lik bir öğrenme oranı ile tek katman ve %95.82'lik beklenen değere biraz daha yakın olan 0.001'lik bir öğrenme oranı kullanarak en iyi tahmin doğruluğunu elde ederken, kayıp değeri 0.0734'lük bir MSE ile en düşük olmuştur. MAE 0.0302 ve RMSE 0.1504 olup, öğrenme oranı 0.001'dir.

LSTM Tahmin sonuçları HPP istasyonunun sabit durumu için



RNN Tahmin sonuçları HPP istasyonunun sabit durumu için



Şekil 4. 6. RMSprop optimizatörü ve bir katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.


Şekil 4.7, iki gizli katman, üç kayıp hesaplama yöntemi ve iki öğrenme oranı ile LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca 0,001 öğrenme oranı ile elde edilen test sonuçlarını da göstermektedir.

Hem LSTM hem de RNN modelleri için çeşitli test sonuçları elde edildiğinde ve farklı öğrenme oranları ve kayıp hesaplama yöntemleri ile karşılaştırıldığında, LSTM modeli kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %96,94'e ulaşmıştır; bu da eğitim için beklenen %98,79 değerine kabaca eşdeğerdir.


Bu durum, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan çeşitli yöntem ve fonksiyonların hata oranlarını karşılaştırarak da açıkça görülebilir. Tepe en düşük seviyesindeydi. En düşük kayıp değeri $MSE = 0,0591$ idi. MAE 0,0429 ve hata oranı 0,001 idi.

$RMSE$, 0,001 öğrenme oranında 0,1219'du. Bu faktörler, en uygun modeli seçmeye etkili bir şekilde katkıda bulunacaktır. RNN modeli, %93,28'lik beklenen değere biraz daha yakın olan %94,27'lik bir öğrenme oranı olan tek bir katman ve 0,001'lik bir öğrenme oranı kullanarak en iyi tahmin doğruluğunu elde ederken, kayıp değeri en düşüktü, $MSE = 0,0876$. MAE 0,0537 ve $RMSE$ 0,1391'di, 0,001 öğrenme oranında.

LSTM Tahmin sonuçları HPP istasyonunun sabit durumu için



RNN Tahmin sonuçları HPP istasyonunun sabit durumu için




Şekil 4. 7. RMSprop optimizatörü ve iki katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.

Şekil 4.8, üç gizli katman ve üç kayıp hesaplama yöntemi ile LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca 0,001'lik bir öğrenme oranı ile elde edilen test sonuçlarını da göstermektedir.


Hem LSTM hem de RNN modelleri için çeşitli test sonuçları elde edildiğinde ve farklı kayıp hesaplama yöntemleri ile karşılaştırıldığında, LSTM modeli kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %93,11'e ulaşmıştır; bu da eğitim için beklenen %95,49 değerine kabaca eşdeğerdir. Bu durum, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan çeşitli yöntem ve fonksiyonların hata oranlarını karşılaştırarak da açıkça görülebilir. Tepe noktası en düşük seviyedeydi.

En düşük kayıp değeri $MSE = 0.0614$ 'tür. MAE 0.0838'dir ve hata oranı 0.001'dir. $RMSE$, 0.001 öğrenme oranında 0.1352'dir. Bu faktörler, en uygun modeli seçmeye etkili bir şekilde katkıda bulunacaktır. RNN modeli, tek katman ve 0.001 öğrenme oranı kullanarak en iyi tahmin doğruluğunu elde ederken, bu %93.39'dur, beklenen %93.84 değerine biraz daha yakındır, kayıp değeri en düşüktü, $MSE = 0.0992$ 'dir. MAE 0.0739'dur ve $RMSE$ 0.1889'dur, 0.001 öğrenme oranında.

LSTM Tahmin sonuçları HPP istasyonunun sabit durumu için



RNN Tahmin sonuçları HPP istasyonunun sabit durumu için



Şekil 4. 8. RMSprop optimizatörü ve 3 katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.

Farklı optimize ediciler, tek ve çoklu katmanlar ve öğrenme oranları kullanılarak sonuçlar incelendiğinde, 0,001 öğrenme oranına ve tek katmana sahip LSTM modeli en yüksek doğruluk ve en düşük hata ile en iyi sonuçları elde etti. Bu tek katmanlı modelin çizelge 4.4.'de gösterildiği gibi RMSprop optimize edicisini kullanarak en iyi sonuçları ürettiği sonucuna vardık.

Çizelge 4. 4. RMSprop optimizatörü kullanılarak her iki model için tahmin sonuçları.

Modeli	Katman Sayısı	Öğrenme Oranı	Accuracy		MSE		MAE		RMSE	
			Acc	Val-Acc	Loss	Val-Loss	Loss	Val-Loss	Loss	Val-Loss
RNN	Bir gizli katman	0.001	0.9682	0.9582	0.0734	0.0966	0.0302	0.0504	0.1504	0.1054
LSTM		0.001	0.9793	0.9505	0.0494	0.0594	0.0279	0.0297	0.1207	0.1053
RNN	İki gizli katman	0.001	0.9427	0.9328	0.0876	0.0684	0.0537	0.0226	0.1391	0.1278
LSTM		0.001	0.9694	0.9879	0.0591	0.0564	0.0429	0.0382	0.1219	0.1356
RNN	Üç gizli katman	0.001	0.9339	0.9384	0.0992	0.1178	0.0739	0.0537	0.1889	0.1310
LSTM		0.001	0.9311	0.9549	0.0614	0.0728	0.0838	0.0567	0.1352	0.1128

En yüksek tahmin doğruluğu, tek katman kullanılarak %97,93'e ulaşan LSTM modeli ile elde edildi ve en düşük kayıp değerleri ise MSE = 0,0494, MAE = 0,0279 ve RMSE = 0,1207 olarak elde edildi.

RNN modeli, tek katmanla %96,82'lik en iyi doğruluğa, MSE = 0,0734, MAE = 0,0302 ve RMSE = 0,1504 kayıp değerleriyle ulaştı.

En yüksek doğruluk ve en az hata miktarıyla elde edilen en iyi sonuç, 0,001 öğrenme oranına ve tek katmana sahip LSTM modeli içindi.

4.1.3. Adagrad Optimizer ile LSTM ve RNN Algoritmalarını Kullanarak Tahmin


Bu bölüm, kullanılan tahmin algoritmalarından elde edilen sonuçları paylaşır ve bu algoritmaların performansını iyileştirmek için kullanılan yöntemleri ve mekanizmaları karşılaştırır, farklı katman sayıları, çoklu optimizasyon mekanizmaları ve farklı kayıp hesaplama yöntemleri kullanarak hem LSTM hem de RNN algoritmaları için en iyi sonuçları elde etmek için en uygun olanları seçer. Tüm test çalışmalarındaki tüm algoritmalar 0,001 öğrenme oranıyla en yüksek sonuçları elde ettiğinden, kalan tüm testler 0,001 öğrenme oranıyla çalıştırılır.

Her modeldeki giriş ve çıkış katmanlarına ek olarak Adagrad optimizatörüyle hem tek hem de çoklu gizli katmanlar kullanılır. Kayıpları hesaplamak için üç farklı yöntem kullanılır: MSE, MAE ve RMSE. Sonuçlar iki grafikte sunulur: mavi renkteki ilki gerçek sonuçları, turuncu renkteki ikincisi ise tahmin edilen sonuçları temsil eder.


Şekil 4.9, tek gizli katman ve üç kayıp hesaplama yöntemi kullanılarak LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca her öğrenme oranı için elde edilen test sonuçlarını da göstermektedir. LSTM modeli, kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %73,47'ye ulaşmıştır; bu da eğitim için beklenen %75,47 değerine kabaca eşdeğerdir. Bu, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan farklı yöntem ve fonksiyonların hata oranlarını karşılaştırarak da açıkça görülebilir.

Tepe en düşük seviyedeydi. En düşük kayıp değeri $MSE = 0,2291$ idi. MAE 0,2844 idi ve hata oranı 0,001 idi. $RMSE$, 0,001'lik bir öğrenme oranında 0,3668 idi. Bu faktörler, benimsenecek en iyi modeli seçmeye etkili bir şekilde katkıda bulunur. RNN modeli, tek katman ve 0.001 öğrenme oranı ile en iyi tahmin doğruluğunu %73.18 ile elde ederken, beklenen %75.21 değerine biraz daha yakinken, kayıp değeri en düşük olan MSE değeri 0.2081 olmuştur. MAE değeri 0.2585, $RMSE$ değeri ise 0.3521 olup, öğrenme oranı 0.001 olmuştur.

LSTM Tahmin sonuçları HPP istasyonunun sabit durumu için



RNN Tahmin sonuçları HPP istasyonunun sabit durumu için




Şekil 4. 9. Adagrad optimizatörü ve bir katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.

Şekil 4.10, iki gizli katman, üç kayıp hesaplama yöntemi ve iki öğrenme oranı ile LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca 0,001 öğrenme oranında elde edilen test sonuçlarını da göstermektedir.


Hem LSTM hem de RNN modelleri için çeşitli test sonuçları elde edildiğinde ve farklı öğrenme oranları ve kayıp hesaplama yöntemleri ile karşılaştırıldığında, LSTM modeli kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %73,47'ye ulaşmıştır; bu da eğitim için beklenen %75,47 değerine kabaca eşdeğerdir. Bu durum, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan çeşitli yöntem ve fonksiyonların hata oranlarını karşılaştırarak da açıkça görülebilir. Tepe noktası en düşük seviyedeydi.

En düşük kayıp değeri $MSE = 0,2291$ 'dir. MAE 0,2844'tür ve hata oranı 0,001'dir. $RMSE$ ise 0,3668'dir. Bu faktörler, optimum modelin seçilmesine etkili bir şekilde katkıda bulunacaktır. RNN modeli, tek katman ve 0,001 veya %73,18'lik bir öğrenme oranıyla en iyi tahmin doğruluğunu elde ederken, bu beklenen %75,21 değerine biraz daha yakındır, ancak 0,2081'lik bir ortalama karesel hata (MSE) ile en düşük kayba sahipti. Ortalama karesel hata (MAE) 0,2585'tir ve ortalama karesel hata ($RMSE$) 0,3521'dir ve 0,001'lik bir öğrenme oranına sahiptir.

LSTM Tahmin sonuçları HPP istasyonunun sabit durumu için



RNN Tahmin sonuçları HPP istasyonunun sabit durumu için



Şekil 4. 10. Adagrad optimizatörü ve iki katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.


Şekil 4.11, üç gizli katman ve üç kayıp hesaplama yöntemi ile LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca 0,001 öğrenme oranında elde edilen test sonuçlarını da göstermektedir.

Hem LSTM hem de RNN modelleri için çeşitli test sonuçları elde edildiğinde ve farklı öğrenme oranları ve kayıp hesaplama yöntemleri ile karşılaştırıldığında, LSTM modeli kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %72,70'e ulaşmıştır; bu da eğitim için beklenen %74,15 değerine kabaca eşdeğerdir.


Bu durum, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan çeşitli yöntem ve fonksiyonların hata oranlarını karşılaştırarak da açıkça görülebilir. Tepe en düşük seviyedeydi. En düşük kayıp değeri $MSE = 0,2324$ 'tü. MAE 0,3289'du ve hata oranı 0,001'di. $RMSE$ 0,3836'ydı.

Bu faktörler, optimum modeli seçmeye etkili bir şekilde katkıda bulunur. RNN modeli, tek bir katman ve 0,001 veya %69,33'lük bir öğrenme oranı kullanarak en iyi tahmin doğruluğunu elde ederken, bu beklenen %69,53 değerine biraz daha yakındır, 0,2435'lik bir ortalama karesel hata (MSE) ile en düşük kayba sahiptir. Ortalama karesel hata (MAE) 0,2706 ve ortalama karesel hata ($RMSE$) 0,3615 idi, 0,001'lik bir öğrenme oranı vardı.

LSTM Tahmin sonuçları HPP istasyonunun sabit durumu için



RNN Tahmin sonuçları HPP istasyonunun sabit durumu için



Şekil 4. 11. Adagrad optimizatörü ve üç katmanı kullanan bir S-S HPP istasyonu için tahmin sonuçları.

Çizelge 4.5, Adagrad optimizatörü ve tek, ikili ve üçlü katmanlar ile kullanılan iki modelin (RNN, LSTM) her biri için farklı test sonuçlarını sunar, farklı kayıp hesaplama fonksiyonları ve 0,001'lik bir eğitim oranı kullanır.

Çizelge 4. 5. Adagrad optimizatörü kullanılarak her iki model için tahmin sonuçları.

Modeli	Katman Sayısı	Öğrenme Oranı	Accuracy		MSE		MAE		RMSE	
			Acc	Val-Acc	Loss	Val-Loss	Loss	Val-Loss	Loss	Val-Loss
RNN	Bir gizli katman	0.001	0.7318	0.7521	0.2081	0.1860	0.2585	0.2458	0.3521	0.3394
LSTM		0.001	0.7347	0.7547	0.2291	0.2129	0.2844	0.2764	0.3668	0.3598
RNN	İki gizli katman	0.001	0.7201	0.7349	0.2237	0.2043	0.2630	0.2523	0.3498	0.3348
LSTM		0.001	0.7270	0.7613	0.2463	0.2402	0.2975	0.2943	0.3679	0.3615
RNN	Üç gizli katman	0.001	0.6933	0.6953	0.2435	0.2284	0.2706	0.2626	0.3615	0.3516
LSTM		0.001	0.7270	0.7415	0.2324	0.2165	0.3289	0.3295	0.3836	0.3806

En yüksek tahmin doğruluğu, tek katman kullanılarak %73,47'ye ulaşan LSTM modeli ile elde edildi. RNN modeline gelince, tek katmanla %73,18'lik en iyi doğruluğa ulaştı. Sonuç olarak, 0,001 öğrenme oranına ve tek katmana sahip LSTM modeli, maksimum doğruluğu ve en düşük hata oranını üreten en iyi modeldir.

4.1.4. Adadelat Optimizer ile LSTM ve RNN Algoritmalarını Kullanarak Tahmin

Bölüm 4, kullanılan tahmin algoritmalarının sonuçlarını paylaşıyor, bu algoritmaların performansını optimize etmek için kullanılan yöntemleri ve mekanizmaları karşılaştırıyor, farklı katman sayıları, çoklu optimizasyon mekanizmaları ve farklı


kayıp hesaplama yöntemleri kullanarak hem LSTM hem de RNN algoritmaları için en iyi sonuçları elde etmek için en uygun olanları seçiyor. Tüm test çalışmalarındaki tüm algoritmalar 0,001 öğrenme oranıyla en yüksek sonuçları elde ettiğinden, kalan tüm testler 0,001 öğrenme oranıyla çalıştırılıyor.

Adadelata optimize edicisi, her modeldeki giriş ve çıkış katmanlarına ek olarak hem tek hem de çoklu gizli katmanlar kullanır. Kayıpları hesaplamak için üç farklı yöntem kullanılır: MSE, MAE ve RMSE. Sonuçlar iki grafikte sunulur: mavi renkteki ilki gerçek sonuçları, turuncu renkteki ikincisi ise tahmin edilen sonuçları temsil eder.


Şekil 4.12, tek gizli katman ve üç kayıp hesaplama yöntemi kullanılarak LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca her öğrenme oranı için elde edilen test sonuçlarını da göstermektedir. LSTM modeli, kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %56,39'a ulaşmıştır; bu da eğitim için beklenen %53,25 değerine kabaca eşdeğerdir.

Bu, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan çeşitli yöntem ve fonksiyonların hata oranlarını karşılaştırarak da açıkça görülebilir. Tepe en düşük seviyedeydi. En düşük kayıp değeri $MSE = 0,3027$ idi. MAE 0,3336 idi ve hata oranı 0,001 idi. $RMSE$, 0,001'lik bir öğrenme oranında 0,4134 idi. Bu faktörler, benimsenmesi gereken en iyi modeli seçmeye etkili bir şekilde katkıda bulunur. RNN modeli, %54,02'lik beklenen değere biraz daha yakın olan %56,85'lik tek katman ve 0,001'lik bir öğrenme oranıyla en iyi tahmin doğruluğunu elde ederken, kayıp değeri 0,2640'lık bir MSE ile en düşüktü. Ortalama kasıtlı hata 0,3353 ve ortalama karesel hata 0,3980'di ve 0,001'lik bir öğrenme oranı vardı.

LSTM Tahmin sonuçları HPP istasyonunun sabit durumu için



RNN Tahmin sonuçları HPP istasyonunun sabit durumu için





Şekil 4. 12. Adadelata optimizatörü ve bir katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.

Şekil 4.13, iki gizli katman ve üç kayıp hesaplama yöntemi ile LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca 0,001 öğrenme oranında elde edilen test sonuçlarını göstermektedir.

Hem LSTM hem de RNN modelleri için çeşitli test sonuçları elde edildiğinde ve farklı öğrenme oranları ve kayıp hesaplama yöntemleri ile karşılaştırıldığında, LSTM modeli kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %56,39'a ulaşmıştır; bu da eğitim için beklenen %53,25 değerine kabaca eşdeğerdir.

Bu durum, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan çeşitli yöntem ve fonksiyonların hata oranlarını karşılaştırarak da açıkça görülebilir. Tepe en düşük seviyesindeydi. En düşük kayıp değeri $MSE = 0,3039$ 'du. MAE 0,3403 ve hata oranı 0,001'di. $RMSE$ ise 0,4146'ydı. Bu faktörler, optimum modeli seçmeye etkili bir şekilde katkıda bulunur.

RNN modeli, iki gizli katman ve 0,001'lik bir öğrenme oranı kullanarak %56,85'lik bir tahmin doğruluğu elde ederken, beklenen %54,02 değerine biraz daha yakındı, kayıp daha düşüktü ve ortalama karesel hata (MSE) 0,2640'tı. Ortalama karesel hata (MAE) 0,3353 ve ortalama karesel hata ($RMSE$) 0,3980'di ve öğrenme oranı 0,001'di.



Şekil 4. 13. Adadelat optimizatörü ve iki katman kullanılarak bir S-S HPP istasyonu için tahmin sonuçları.


Şekil 4.14, üç gizli katman ve üç kayıp hesaplama yöntemi ile LSTM ve RNN algoritmaları kullanılarak elde edilen tahmin sonuçlarını göstermektedir. Eğitim süreci ayrıca 0,001 öğrenme oranında elde edilen test sonuçlarını göstermektedir.

Hem LSTM hem de RNN modelleri için çeşitli test sonuçları elde edildiğinde ve farklı öğrenme oranları ve kayıp hesaplama yöntemleri ile karşılaştırıldığında, LSTM modeli kullanılan çeşitli katmanlar ve öğrenme oranları için sonuçlar arasında en iyi tahmin doğruluğunu elde ederek %56,39'a ulaşmıştır; bu da eğitim için beklenen %53,25 değerine kabaca eşdeğerdir.


Bu durum, sistemin sabit durum tahminindeki hatayı hesaplamak için kullanılan çeşitli yöntem ve fonksiyonların hata oranlarını karşılaştırarak da açıkça görülebilir. Tepe en düşük seviyesindeydi. En düşük kayıp değeri $MSE = 0,3091$ idi. MAE 0,3513 idi ve hata oranı 0,001 idi. $RMSE$ ise 0,4139 idi. Bu faktörler, optimum modeli seçmeye etkili bir şekilde katkıda bulunur.

RNN modeli, iki gizli katman ve 0,001'lik bir öğrenme oranı kullanarak %56,15'lik bir tahmin doğruluğu elde ederken, beklenen %53,03 değerine biraz daha yakındı, kayıp daha düşüktü ve ortalama karesel hata (MSE) 0,2841 idi. Ortalama karesel hata (MAE) 0,3355 idi ve ortalama karesel hata ($RMSE$) 0,4094 idi ve öğrenme oranı 0,001 idi.

LSTM Tahmin sonuçları HPP istasyonunun sabit durumu için



RNN Tahmin sonuçları HPP istasyonunun sabit durumu için



Şekil 4. 14. Adadelat optimizatörü ve üç katman kullanan bir S-S HPP istasyonu için tahmin sonuçları.

Çizelge 4.6, Adadelata optimizatörü ve tek, ikili ve üçlü katmanları kullanan, çeşitli kayıp hesaplama fonksiyonları ve 0,001 eğitim oranına sahip iki modelin (RNN, LSTM) her biri için test sonuçlarını sunar.

Çizelge 4. 6. Adadelata optimizatörü kullanan her iki model için tahmin sonuçları.

Modeli	Katman Sayısı	Öğrenme Oranı	Accuracy		MSE		MAE		RMSE	
			Acc	Val-Acc	Loss	Val-Loss	Loss	Val-Loss	Loss	Val-Loss
RNN	Bir gizli katman	0.001	0.5685	0.5402	0.2640	0.2581	0.3353	0.3377	0.3980	0.4013
LSTM			0.5639	0.5325	0.3027	0.2886	0.3336	0.3468	0.4134	0.4171
RNN	İki gizli katman	0.001	0.5639	0.5325	0.2776	0.2778	0.3431	0.3325	0.4043	0.4057
LSTM			0.5639	0.5325	0.3039	0.3187	0.3403	0.3438	0.4146	0.4188
RNN	Üç gizli katman	0.001	0.5615	0.5303	0.2841	0.2853	0.3355	0.3389	0.4094	0.4127
LSTM			0.5639	0.5325	0.3091	0.3245	0.3513	0.3554	0.4139	0.4181

En yüksek tahmin doğruluğu, tek katman kullanılarak %56,85'e ulaşan RNN modeli ile elde edilirken, en düşük kayıp değerleri ise MSE = 0,2640, MAE = 0,3353 ve RMSE = 0,3980 olarak elde edildi.

RNN modeli, tek katmanla %96,82'lik en iyi doğruluğa ulaşırken, kayıp değerleri MSE=0,0513, MAE = 0,0175 ve RMSE = 0,0846 oldu.

Bu nedenle, tek katmana ve 0,001 öğrenme oranına sahip olan RNN modeli, en yüksek doğruluğu ve en düşük hata oranını üreten en iyi modeldir.

BÖLÜM 5

SONUÇLAR

Bu araştırmada hidroelektrik santraller, bileşenleri, işletme özellikleri, kuruluş başlangıçları, elektrik enerjisi üretim kaynakları arasındaki katkıları ve önemleri, işletme özelliklerini etkileyen faktörler ve en etkili faktörlerin belirlenmesi üzerine bir çalışma yapılmıştır.

Dünyadaki diğer hidroelektrik santralleri için model olarak iki istasyon (Haditha ve Obruk) çalışma için seçildi. Bu istasyonların çalışmalarının doğasını etkileyen tüm faktörler için büyük miktarda veri toplandı, bunların en önemlileri hidroelektrik santralinin çeşitli bileşenlerinin titreşimleri, elektrik jeneratörü, güç iletim şaftı ve özellikle bu istasyonların çekirdeği olan ve su içlerinden geçtiğinde rahatsızlıkların merkezi olan su türbinleri ve basınç, sıcaklık, üretim miktarı, frekans, rezervuardaki su yüksekliği ve güç faktörü gibi diğer etkili faktörlerdir. Bunlar incelendi, analiz edildi ve bu istasyonlardaki mevcut sorunları çözen ideal bir sistem bulmak için bir temel ve veri bankası olarak kullanıldı.

Hidroelektrik santrallerinin karşı karşıya olduğu başlıca sorunlar vurgulandı; bunlar, verimliliklerini azaltıyor, hasara maruz bırakıyor, çalışanların hayatlarını tehlikeye atıyor, iş durmalarına neden oluyor ve maddi kayıplara ve nüfus artışına etki ediyor. Bu hataları önleyen ve önleyen radikal çözümler bulmadaki önemleri göz önüne alındığında otomasyon ve kontrole odaklanıldı. Bu santrallerin kapasitesini sınırlı ölçüde artırmaya katkıda bulunmak için geliştirme aşamalarından geçen bu sistemlerin geliştirme aşamaları da vurgulandı.

Önceki çalışmalar, kontrol programlarının mekanik kontrolden elektronik programlama yoluyla kontrole evrildiğini göstermiştir. Sınırlı bir ölçüde elektronik sensör okumalarına dayanan bu sistemler, hidroelektrik santrallerinin performansını

iyileştirmiş, operasyondaki zayıf noktaları belirlemiş ve gerekli bakım için zaman ve yerlerin belirlenmesini sağlamıştır. Bu diğer izleme ve kontrol sistemleri, tehlikeleri yalnızca meydana geldiklerinde ortaya çıkardıkları ve bu da santrallerin hata yapmasını engellemediği için etkinlikleri bakımından sınırlıdır.

Yapay zeka ve makine öğrenmesindeki son gelişmeler ve bunların kontrol sistemlerinin performansını iyileştirmek için kullanılma potansiyeli ile izleme ve kontrol sistemleri yeni bir geliştirme aşamasına girmiştir. Kontrol sistemleri, hataları oluşmadan önce tespit ederek ve oluşmalarını önleyerek optimum şekilde çalışmalarını sağlayan öngörücü bir yaklaşım kullanılarak geliştirilmiştir.

Hidroelektrik santrali izleme ve kontrol sistemleri, hidroelektrik santrallerinin istikrarını etkileyen tüm faktörler hakkında veri içeren büyük ve gerçek bir veri tabanına dayalı olarak hidroelektrik santrallerinin durumunu tahmin etmek için iki model (LSTM ve RNN) kullanılarak geliştirilmiştir. Tahmin değerleri, bu kontrol sistemlerinin performansını iyileştirmek için kullanılmış ve bu sistemler esnek hale getirilerek dünyanın dört bir yanındaki çeşitli hidroelektrik santrallerine uygulanabilir hale getirilmiştir. Geliştirilen sistem, bu tesislerde kullanılan sistemlerle bağımsız veya entegre olarak çalışır.

MATLAB yazılımı ve farklı sensörlerin çeşitli sinyallerini ve türbinleri kontrol etme ve kapıları açma ve kapama yeteneğini gelişmiş bir işlem ünitesi aracılığıyla görüntüleyen bir grafiksel kullanıcı arayüzü kullanılarak ayrı bir kontrol ve izleme sistemi tasarlanmıştır. Aynı zamanda, tahmin algoritması istasyonun gelecekteki durumunu bulmak için çalışır ve kontrol programını uygun eylemi gerçekleştirmesi için bilgilendirir.

Bu algoritma ve tahmin, tahmin sonuçlarını alarak ve bu sonuçlara göre belirli önlemler almak ve istasyonun potansiyel risklerini korumak için bunları kontrol ünitesine göndererek SCADA sistemleri gibi bazı istasyonlarda şu anda kullanılan izleme ve kontrol sistemleriyle entegre edilebilirken.

Algoritma dosyasının yüklendiği ve kontrol programlarının çalışmasıyla birlikte veri olarak ve geleceği tahmin ederek mükemmel bir şekilde çalıştığı sofistike bir kontrol cihazı (Raspberry Pi 5) kullanılır.

Tahminle temsil edilen derin öğrenme ve makine öğrenmesi, dünyadaki herhangi bir ülke için gelecek planlamasını iyileştirmek için gereklidir. Demografik, endüstriyel ve ekonomik istikrara temel olarak katkıda bulunan bir bilimdir ve herhangi bir ülke için temel bir hedef, bu modellerin mümkün olduğunca doğru, güvenilir ve anlamlı olmasıdır. En yüksek tahmin doğruluğuna ve en düşük kayıp oranına sahip en iyi model tartışıldı ve çeşitli sonuçlardan belirlendi.

Model, en iyi optimize edici türlerinin, öğrenme oranlarının ve katman sayısının seçimi ve farklı yöntemler kullanılarak kayıp sonuçlarının hesaplanması dikkate alınarak hidroelektrik santrali kararlılığı için hem LSTM hem de RNN modelleri için test edildi. En iyi performans gösteren ve en verimli modeli belirlemek için yardımcı yöntemler olarak dört farklı optimize edici (Adam, RMSprop, Adadelta ve Adagrad), üç gizli katman (tek, çift ve üçlü) ve üç kayıp hesaplama yöntemi (MAE, RMSE ve MSE) kullanıldı. Seçilen model, benzer hidroelektrik santrallerine sahip tüm barajlarda kullanıma uygun olacaktır.

LSTM modeli en iyi sonuçları elde etti, en verimli ve en iyi performans gösteren model oldu, %99,55 doğruluk ve en düşük kayıp değeri ($MSE = 0,0072$) elde etti. Bu değer varsayılan 0,0093 değeriyle tutarlıdır. Diğer kayıp hesaplama yöntemleri ($MAE = 0,0053$ ve $RMSE = 0,0551$) Adam optimize edici ve tek gizli katman kullanılarak 0,001 öğrenme oranına sahiptir. Kullanılan veri kümesi şu şekilde bölünmüştür: %67 eğitim ve %33 test.

RNN modeli %98,31'lik en iyi doğruluğu ve en düşük kayıp değerini ($MSE = 0,0513$) elde ederken, bu değer varsayılan 0,0633 değeriyle tutarlıdır. Diğer kayıp hesaplama yöntemleri ($MAE = 0,0175$ ve $RMSE = 0,0846$) Adam optimize edici ve tek gizli katman kullanılarak 0,001 öğrenme oranına sahiptir. Veri kümesi şu şekilde bölündüğünde: %67 eğitim ve %33 test, bu değer hala LSTM modeliyle elde edilen doğruluktan düşüktür, bu nedenle LSTM modeli en iyi model olarak seçilmiştir.

Önerilen model, tahmin süreçleri aracılığıyla, özellikle bu santrallerdeki elektrik üretim türbinlerinde arızaları tespit ederek ve önleyerek hidroelektrik santrallerinin kararlılığını artırmaya katkıda bulunur. Bu model ayrıca, sakinler ve endüstriyel şirketler için arıza ve elektrik kesintisi olasılığını azaltır ve acil bakım maliyetlerini ve gelecekteki bakım için planlamayı azaltır. Bu, yüksek ekonomik uygulanabilirliğe dönüşür.



KAYNAKLAR

- 1 Zolfaghari, M.; Golabi, M.R. Modeling and predicting the electricity production in hydropower using conjunction of the wavelet transform, long short-term memory, and random forest models. *Renew. Energy* 2021, 170, 1367–1381.
- 2 Kartal, Mustafa Tefvik, Serpil Kılıç Depren, Fatih Ayhan, and Özer Depren. "Impact of renewable and fossil fuel energy consumption on environmental degradation: evidence from USA by nonlinear approaches." *International Journal of Sustainable Development & World Ecology* 29, no. 8 (2022): 738-755.
- 3 Bobat, Alaeddin. "Thermal pollution caused by hydropower plants." In *Energy systems and management*, pp. 19-32. Springer International Publishing, 2015.
- 4 Liu, Qidong, Ruisheng Zhang, Rongjing Hu, Guangjing Wang, Zhenghai Wang, and Zhili Zhao. "An improved path-based clustering algorithm." *Knowledge-Based Systems* 163 (2019): 69-81.
- 5 Eichler, Otto. "Vibration phenomena on hydraulic axial turbines." In *Practical experiences with flow-induced vibrations: symposium, Karlsruhe/Germany*. 1979.
- 6 Jacquemoud R., Research on a Kaplan Turbine Operating Range Below The Guarantee Performance Range Based on an Approach Initially Developed for Investigation of the Process of Damage by Metal Fatigue, *XVII IAHR Symposium*, Beijing, China 1994.
- 7 Yao X. Evolving artificial neural networks. *Proc IEEE*. 1999;87(9):1423–47.
- 8 Al-Hardanee, Omar Farhan, and Hüseyin Demirel. "Hydropower Station Status Prediction Using RNN and LSTM Algorithms for Fault Detection." *Energies* 17, no. 22 (2024): 5599.
- 9 Magee, Darrin. "Dams: Controlling water but creating problems." In *Routledge handbook of environment and society in Asia*, pp. 216-236. Routledge, 2014.
- 10 Muhsen, Abdulmuttalib A., Ali A. Resan Al-Malik, Bashar H. Attiya, Omar Farhan Al-Hardanee, and Karam Aied Abdalazize. "Modal analysis of Kaplan turbine in Haditha hydropower plant using ANSYS and SolidWorks." In *IOP Conference Series: Materials Science and Engineering*, vol. 1105, no. 1, p. 012056. IOP Publishing, 2021.

- 11 Graves, Alex, and Jürgen Schmidhuber. "Framewise phoneme classification with bidirectional LSTM and other neural network architectures." *Neural networks* 18, no. 5-6 (2005): 602-610.
- 12 Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." *Neural computation* 9, no. 8 (1997): 1735-1780.
- 13 Winton, R. S., Calamita, E., & Wehrli, B. (2019). Reviews and syntheses: Dams, water quality and tropical reservoir stratification. *Biogeosciences*, 16(8), 1657-1671.
- 14 Atkins. "FD2628 Impact of Climate Change on Dams & Reservoirs, *Final Guidance Report*." (2013).
- 15 A.-Hardanee and O. Farhan, "Design and Improvement of an Intelligent Control System to Solve the Dam Ground Water Problem," *Diss. Ankara Yıldırım Beyazıt Üniversitesi Fen Bilimleri Enstitüsü*, 2019
- 16 Al-Hardanee, O. F., Çankaya, İ., Muhsen, A. A., & Canbolat, H. (2021). Design a control system for observing vibration and temperature of turbines. *Indonesian Journal of Electrical Engineering and Computer Science*, 24(3), 1437-1444.
- 17 Attiya, B. H., Alashaab, A. A. N., & Muhsen, A. A. (2024, February). Analysis study of the influence of high vibration on Kaplan turbine generation capacity in Haditha plant. *In AIP Conference Proceedings* (Vol. 3009, No. 1). AIP Publishing.
- 18 A. A. Muhsen, G. Szymański, T. Mankhi, and B. Attiya, "Selecting the most efficient maintenance approach using AHP multiple criteria decision making at haditha hydropower plant," *Zesz. Nauk. Politech. Poznańskiej. Organ. i Zarządzanie*, vol. 78, no. 78, pp. 113-136, 2018, doi: 10.21008/j.0239-9415.2018.078.09.
- 19 Quaranta, E., Bonjean, M., Cuvato, D., Nicolet, C., Dreyer, M., Gaspoz, A., ... & Bragato, N. (2020). Hydropower case study collection: Innovative low head and ecologically improved turbines, hydropower in existing infrastructures, hydropeaking reduction, digitalization and governing systems. *Sustainability*, 12(21), 8873.
- 20 Cutting Edge, Hydroelectric Power & Hydro Turbine Maintenance. <https://ceomachining.com/hydro-turbine-maintenance/> 2025.1.11
- 21 Nerurkar, P., Shirke, A., Chandane, M. & Bhirud, S., "Empirical Analysis of Data Clustering Algorithms". *Procedia Computer Science*, 125, 770–779. 2018.
- 22 Fahad, A., Alshatri, N., Tari, Z., Alamri, A., Khalil, I., Zomaya, A. Y., Fofou, S. & Bouras, A., "A survey of clustering algorithms for big data: Taxonomy and empirical analysis". *IEEE Transactions on Emerging Topics in Computing*, 2(3), 267–279, 2014.

- 23 Liu, Q., Zhang, R., Hu, R., Wang, G., Wang, Z., & Zhao, Z., "An improved path-based clustering algorithm", *Knowledge-based Systems*, 163, 69–81, 2019.
- 24 Şaar, F., & Topcu, A. E. (2022). Minimum spanning tree-based cluster analysis: A new algorithm for determining inconsistent edges. *Concurrency and Computation: Practice and Experience*, 34(9), e6717.
- 25 "2000 HUB5 English Evaluation Speech - Linguistic Data Consortium". *catalog.ldc.upenn.edu*.
- 26 Hannun, Awni; Case, Carl; Casper, Jared; Catanzaro, Bryan; Diamos, Greg; Elsen, Erich; Prenger, Ryan; Satheesh, Sanjeev; Sengupta, Shubho (2014-12-17). "Deep Speech: Scaling up end-to-end speech recognition". *arXiv:1412.5567* [cs.CL].
- 27 F. Harrou, M. Madakyaru, Y. Sun, S. Khadraoui, Improved detection of incipient anomalies via multivariate memory monitoring charts: application to an air flow heating system, *Applied Thermal Engineering* 109 (2016) 65-74
- 28 I. Nimmo. Adequately address abnormal operations. *Chemical Engineering Progress* 91 (9) (1995) 36-45
- 29 Fan, Bo; Wang, Lijuan; Soong, Frank K.; Xie, Lei (2015) "Photo-Real Talking Head with Deep Bidirectional LSTM", in *Proceedings of ICASSP 2015*
- 30 Zen, H. and Sak, H., 2015, April. Unidirectional long short-term memory recurrent neural network with recurrent output layer for low-latency speech synthesis. *In 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 4470-4474). IEEE.
- 31 Sak, Haşim, Andrew Senior, Kanishka Rao, Françoise Beaufays, and Johan Schalkwyk. "Google voice search: faster and more accurate." *Google Research blog* (2015).
- 32 Sutskever, Ilya, Oriol Vinyals, and Quoc V. Le. "Sequence to sequence learning with neural networks." *Advances in neural information processing systems* 27 (2014).
- 33 Jozefowicz, Rafal, Oriol Vinyals, Mike Schuster, Noam Shazeer, and Yonghui Wu. "Exploring the limits of language modeling." *arXiv preprint arXiv:1602.02410* (2016).
- 34 Gillick, Dan, Cliff Brunk, Oriol Vinyals, and Amarnag Subramanya. "Multilingual language processing from bytes." *arXiv preprint arXiv:1512.00103* (2015).

- 35 Vinyals, Oriol, Alexander Toshev, Samy Bengio, and Dumitru Erhan. "Show and tell: A neural image caption generator." In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3156-3164. 2015.
- 36 Million, Elizabeth. "The hadamard product." *Course Notes* 3, no. 6 (2007): 1-7.
- 37 Fox, John. *Applied regression analysis and generalized linear models*. Sage publications, 2015.
- 38 N .R . Draper, H. Smith, *Applied Regression Ana lysis*, vol. 326, John Wi ley & Sons, 2014.
- 39 Hoerl, Arthur E., and Robert W. Kennard. "Ridge regression iterative estimation of the biasing parameter." *Communications in Statistics-Theory and Methods* 5, no. 1 (1976): 77-88.
- 40 Al-Hadeethi, Muthanna M., Mohd Wazir Bin Mustafa, and Abdulmuttalib A. Muhsen. "Exploiting Renewable Energy in Iraq to Conquer the Problem of Electricity Shortage and Mitigate Greenhouse Gas Emissions." In *Proceedings of the 9th Virtual International Conference on Science, Technology and Management in Energy. Complex System Research Centre, Mathematical Institute of the Serbian Academy of Sciences and Arts, Belgrad, Serbia*, pp. 23-24. 2023.
- 41 Muhsen, Abdulmuttalib A., Ali A. Resan Al-Malik, Bashar H. Attiya, Omar Farhan Al-Hardanee, and Karam Aied Abdalazize. "Modal analysis of Kaplan turbine in Haditha hydropower plant using ANSYS and SolidWorks." In *IOP Conference Series: Materials Science and Engineering*, vol. 1105, no. 1, p. 012056. IOP Publishing, 2021.
- 42 Proske, Dirk. "Comparison of dam failure frequencies and failure probabilities." *Beton-und Stahlbetonbau* 113 (2018): 2-6.
- 43 Cleary, Paul W., Mahesh Prakash, Stuart Mead, Xinming Tang, Huibin Wang, and Sida Ouyang. "Dynamic simulation of dam-break scenarios for risk analysis and disaster management." *International Journal of Image and Data Fusion* 3, no. 4 (2012): 333-363.
- 44 Reza, Ghanatian, and Mauricio Dziedzic. "An Improved Conceptual Bayesian Model for Dam Break Risk Assessment." In *World Environmental and Water Resources Congress 2024*, pp. 1002-1018. 2024.
- 45 Wang, Shuming, Bing Yang, Huimin Chen, Weihua Fang, and Tiantang Yu. "LSTM-based deformation prediction model of the embankment dam of the danjiangkou hydropower station." *Water* 14, no. 16 (2022): 2464.
- 46 Liu, Zhong, Shuyun Zou, and Lihua Zhou. "Condition monitoring system for hydro turbines based on LabVIEW." In *2012 Asia-Pacific Power and Energy Engineering Conference*, pp. 1-4. IEEE, 2012.

- 47 Mohanta, Rati Kanta, Thanga Raj Chelliah, Srikanth Allamsetty, Aparna Akula, and Ripul Ghosh. "Sources of vibration and their treatment in hydro power stations-A review." *Engineering science and Technology, an international journal* 20, no. 2 (2017): 637-648.
- 48 CAS Dataloggers, (Vibration Monitoring System for Hydro Turbines) https://www.dataloggerinc.com/wp-content/uploads/2016/03/18-Vibration_Monitoring_System_for_Hydro_Turbines.pdf. 20 June 2024.
- 49 Vijaya, K. K., and S. Surender. "Industry monitoring robot using Arduino Uno with Matlab interface." *Adv Robot Autom* 5, no. 150 (2016): 2.
- 50 Bansal, Puneet, IS Rajay Vedaraj, and P. G. Student. "Monitoring and analysis of vibration signal in machine tool structures." *International Journal of Engineering Development and Research* 2, no. 2 (2014): 2310-1317.
- 51 Al-Hardanee, Omar, İlyas Çankaya, Abdulmuttalib Muhsen, and HÜSEYİN CANBOLAT. "Design a control system for observing vibration and temperature of turbines." *Indonesian Journal of Electrical Engineering and Computer Science* 24, no. 3 (2021).
- 52 Coulibaly, Paulin, François Anctil, and Bernard Bobée. "Neural network-based long-term hydropower forecasting system." *Computer-Aided Civil and Infrastructure Engineering* 15, no. 5 (2000): 355-364.
- 53 Kaur, Sukhmeet, Namita Kathpal, and Nitika Munjal. "Role of SCADA in hydro power plant automation." *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering* 4, no. 10 (2015): 8085-8090.
- 54 Enescu, Florentina-Magda, Cosmin Ştirbu, and Valeriu Ionescu. "SCADA Network System for the Monitoring and Control of an Electrical Installation Supplied by a Hydro-Generator." In *International Joint Conference SOCO'16-CISIS'16-ICEUTE'16: San Sebastián, Spain, October 19th-21st, 2016 Proceedings 11*, pp. 156-166. Springer International Publishing, 2017.
- 55 Côrtes, Hyghor Miranda, Paulo Eduardo Santos, and João Inácio da Silva Filho. "Monitoring electrical systems data-network equipment by means of Fuzzy and Paraconsistent Annotated Logic." *Expert Systems with Applications* 187 (2022): 115865.
- 56 Network Manager SCADA System in Hydroelectric Power Plants https://control.com/technical-articles/network-manager-scada-system-in-hydroelectric-power-plants/?utm_source=chatgpt.com 2025.3.16
- 57 Northern California: Hydro-SCADA https://www.campbellsci.com/northern-california-hydro-scada?utm_source=chatgpt.com. 2025.3.17

- 58 Russell, Stuart J., and Peter Norvig. *Artificial intelligence: a modern approach*. pearson, 2016.
- 59 Conteh, Foday, Shota Tobaru, Mohamed E. Lotfy, Atsushi Yona, and Tomonobu Senjyu. "An effective Load shedding technique for micro-grids using artificial neural network and adaptive neuro-fuzzy inference system." *Aims Energy* 5, no. 5 (2017).
- 60 Zhang, Wengang, Runhong Zhang, Chongzhi Wu, Anthony Teck Chee Goh, Suzanne Lacasse, Zhongqiang Liu, and Hanlong Liu. "State-of-the-art review of soft computing applications in underground excavations." *Geoscience Frontiers* 11, no. 4 (2020): 1095-1106.
- 61 Aslan, H. Kurt Y. "Optimization of Power Output of Micro Hydro Power Station Using Fuzzy Logic Algorithm." *IJTPE International Journal* 5, no. 1 (2013): 138-143.
- 62 Herath, Pramod, and Ganesh K. Venayagamoorthy. "A service provider model for demand response management." In *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*, pp. 1-8. IEEE, 2016.
- 63 Senthil Kumar, A. R., Manish Kumar Goyal, C. S. P. Ojha, R. D. Singh, and P. K. Swamee. "Application of artificial neural network, fuzzy logic and decision tree algorithms for modelling of streamflow at Kasol in India." *Water science and technology* 68, no. 12 (2013): 2521-2526.
- 64 Kumar, Krishna, Ravindra Pratap Singh, Prashant Ranjan, and Narendra Kumar. "Daily plant load analysis of a hydropower plant using machine learning." In *Applications of Artificial Intelligence in Engineering: Proceedings of First Global Conference on Artificial Intelligence and Applications (GCAIA 2020)*, pp. 819-826. Singapore: Springer Singapore, 2021.
- 65 Fayaz, Muhammad, and DoHyeun Kim. "A prediction methodology of energy consumption based on deep extreme learning machine and comparative analysis in residential buildings." *Electronics* 7, no. 10 (2018): 222.
- 66 Shamshirband, Shahaboddin, Amir Mosavi, and Kwok-wing Chau. "Sensitivity study of ANFIS model parameters to predict the pressure gradient with combined input and outputs hydrodynamics parameters in the bubble column reactor." *arXiv preprint arXiv:1907.09309* (2019).
- 67 Lounis, Hakim, Mounir Boukadoum, and Vincent Siveton. "Assessing hydro power system relevant variables: a comparison between a neural network and different machine learning approaches." In *Proc. International Conference on Neuro-Fuzzy Technology (Neuro-Fuzzy2002)*, pp. 45-51. 2002.
- 68 Egoigwe, Sochima Vincent, Chukwudi Chukwudozie, Chukwudumebi Nwobi, Timothy Oluwaseun Araoye, Chukwuemeka Igwe Arize, and Edward C. Anoliefo. "Application of a fuzzy logic controller for hydropower generator speed

- regulation." *European Journal of Engineering and Technology Research* 4, no. 3 (2019): 132-135.
- 69 Luna, Ivette, Ieda G. Hidalgo, Paulo SM Pedro, Paulo SF Barbosa, Alberto L. Francato, and Paulo B. Correia. "Fuzzy inference systems for multi-step ahead daily inflow forecasting." *Pesquisa operacional* 37, no. 1 (2017): 129-144.
 - 70 Abdulkadir, T. S., A. W. Salami, A. R. Anwar, and A. G. Kareem. "Modelling of hydropower reservoir variables for energy generation: neural network approach." *Ethiopian Journal of Environmental Studies and Management* 6, no. 3 (2013): 310-316.
 - 71 Li, Gang, Yongjun Sun, Yong He, Xiufeng Li, and Qiyu Tu. "Short-term power generation energy forecasting model for small hydropower stations using ga-svm." *Mathematical Problems in Engineering* 2014, no. 1 (2014): 381387.
 - 72 Stokelj, T., and Robert Golob. "Application of neural networks for hydro power plant water inflow forecasting." In *Proceedings of the 5th Seminar on Neural Network Applications in Electrical Engineering. NEUREL 2000 (IEEE Cat. No. 00EX287)*, pp. 189-193. IEEE, 2000.
 - 73 Shaktawat, Anuja, and Shelly Vadhera. "Fuzzy logic based determination of cost overrun of hydro power plant." In *2016 International Conference on Electrical Power and Energy Systems (ICEPES)*, pp. 301-304. IEEE, 2016.
 - 74 Li, Liang, Fuming Yao, Ying Huang, and Fan Zhou. "Hydropower generation forecasting via deep neural network." In *2019 6th International Conference on Information Science and Control Engineering (ICISCE)*, pp. 324-328. IEEE, 2019.
 - 75 Mamlook, Rustom, Bilal A. Akash, and Mousa S. Mohsen. "A neuro-fuzzy program approach for evaluating electric power generation systems." *Energy* 26, no. 6 (2001): 619-632.
 - 76 Valizadeh, N., A. El-Shafie, M. Mukhlisin, and A. H. El-Shafie. "Daily water level forecasting using adaptive neuro-fuzzy interface system with different scenarios: Klang Gate, Malaysia." *International Journal of the Physical Sciences* 6, no. 32 (2011): 7379-7389.
 - 77 Novák, Vilém, Irina Perfilieva, and Jiri Mockor. *Mathematical principles of fuzzy logic*. Vol. 517. Springer Science & Business Media, 2012.
 - 78 Cheng, Chun-Tian, Jian-Yi Lin, Ying-Guang Sun, and Kwokwing Chau. "Long-term prediction of discharges in Manwan Hydropower using adaptive-network-based fuzzy inference systems models." In *Advances in Natural Computation: First International Conference, ICNC 2005, Changsha, China, August 27-29, 2005, Proceedings, Part III 1*, pp. 1152-1161. Springer Berlin Heidelberg, 2005.

- 79 Dehghani, Majid, Hossein Riahi-Madvar, Farhad Hooshyaripor, Amir Mosavi, Shahaboddin Shamshirband, Edmundas Kazimieras Zavadskas, and Kwok-wing Chau. "Prediction of hydropower generation using grey wolf optimization adaptive neuro-fuzzy inference system." *Energies* 12, no. 2 (2019): 289.
- 80 Kucukali, Serhat. "Risk assessment of river-type hydropower plants using fuzzy logic approach." *Energy Policy* 39, no. 10 (2011): 6683-6688.
- 81 Ghosh, Soumya, Mrinmoy Majumder, and Manish Pal. "Development of performance index for evaluation of small scale hydro power plants by neural network and multi criteria decision making." *International Journal of Energy and Statistics* 4, no. 04 (2016): 1650019.
- 82 ALRAYESS, Hesham, Salem Gharbia, Neslihan Beden, and Asli ULKE KESKIN. "Using machine learning techniques and deep learning in forecasting the hydroelectric power generation in almus dam, turkey." *Safety* 72 (2018).
- 83 Hammid, Ali Thaeer, Mohd Herwan Bin Sulaiman, and Ahmed N. Abdalla. "Prediction of small hydropower plant power production in Himreen Lake dam (HLD) using artificial neural network." *Alexandria engineering journal* 57, no. 1 (2018): 211-221.
- 84 Stokelj, T., Dejan Paravan, and Robert Golob. "Enhanced artificial neural network inflow forecasting algorithm for run-of-river hydropower plants." *Journal of Water Resources Planning and Management* 128, no. 6 (2002): 415-423.
- 85 Feng, Guangliang, Guoqing Xia, Bingrui Chen, Yaxun Xiao, and Ruichen Zhou. "A method for rockburst prediction in the deep tunnels of hydropower stations based on the monitored microseismicity and an optimized probabilistic neural network model." *Sustainability* 11, no. 11 (2019): 3212.
- 86 Jalalkamali, Amir, Hossein Sedghi, and Mohammad Manshouri. "Monthly groundwater level prediction using ANN and neuro-fuzzy models: a case study on Kerman plain, Iran." *Journal of hydroinformatics* 13, no. 4 (2011): 867-876.
- 87 Kumar, Krishna, and R. P. Saini. "Application of machine learning for hydropower plant silt data analysis." *Materials Today: Proceedings* 46 (2021): 5575-5579.
- 88 Bina, Mohammad Tavakoli, and Danial Ahmadi. "Aggregate domestic demand modelling for the next day direct load control applications." *IET Generation, Transmission & Distribution* 8, no. 7 (2014): 1306-1317.
- 89 Simmhan, Yogesh, Saima Aman, Alok Kumbhare, Rongyang Liu, Sam Stevens, Qunzhi Zhou, and Viktor Prasanna. "Cloud-based software platform for big data analytics in smart grids." *Computing in Science & Engineering* 15, no. 4 (2013): 38-47.

- 90 Pal, Shalini, and Rajesh Kumar. "Price prediction techniques for residential demand response using support vector regression." In **2016 IEEE 7th Power India International Conference (PIICON)**, pp. 1-6. IEEE, 2016.
- 91 Park, Saehong, Seunghyoung Ryu, Yohwan Choi, Jihyo Kim, and Hongseok Kim. "Data-driven baseline estimation of residential buildings for demand response." **Energies** 8, no. 9 (2015): 10239-10259.
- 92 Jazaeri, Javad, Tansu Alpcan, Robert Gordon, Miguel Brandao, Tim Hoban, and Chris Seeling. "Baseline methodologies for small scale residential demand response." In **2016 IEEE Innovative Smart Grid Technologies-Asia (ISGT-Asia)**, pp. 747-752. IEEE, 2016.
- 93 Arunaun, Anut, and Wanchalerm Pora. "Baseline calculation of industrial factories for demand response application." In **2018 IEEE International Conference on Consumer Electronics-Asia (ICCE-Asia)**, pp. 206-212. IEEE, 2018.
- 94 Escrivá-Escrivá, Guillermo, Carlos Álvarez-Bel, Carlos Roldán-Blay, and Manuel Alcázar-Ortega. "New artificial neural network prediction method for electrical consumption forecasting based on building end-uses." **Energy and Buildings** 43, no. 11 (2011): 3112-3119.
- 95 Jiang, Haihao, and Zhenyu Tan. "Load forecasting in demand response." In **2012 Asia-Pacific Power and Energy Engineering Conference**, pp. 1-4. IEEE, 2012.
- 96 Chen, Qifang, Nian Liu, Cheng Wang, and Jianhua Zhang. "Optimal power utilizing strategy for PV-based EV charging stations considering Real-time price." In **2014 IEEE Conference and Expo Transportation Electrification Asia-Pacific (ITEC Asia-Pacific)**, pp. 1-6. IEEE, 2014.
- 97 Pal, Shalini, and Rajesh Kumar. "Effective load scheduling of residential consumers based on dynamic pricing with price prediction capabilities." In **2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)**, pp. 1-6. IEEE, 2016.
- 98 Takiyar, Swati. "Grid reliability enhancement by peak load forecasting with a PSO hybridized ANN model." In **2015 4th International Conference on Reliability, Infocom Technologies and Optimization (ICRITO)(Trends and Future Directions)**, pp. 1-6. IEEE, 2015.
- 99 Basnet, Saurav MS, Haneen Aburub, and Ward Jewell. "An artificial neural network-based peak demand and system loss forecasting system and its effect on demand response programs." In **2016 Clemson University Power Systems Conference (PSC)**, pp. 1-5. IEEE, 2016.
- 100 Paterakis, N. G., J. P. S. Catalao, A. Tascikaraoglu, A. G. Bakirtzis, and O. Erdinc. "Demand response driven load pattern elasticity analysis for smart households." In **2015 IEEE 5th International Conference on Power**

Engineering, Energy and Electrical Drives (POWERENG), pp. 399-404. IEEE, 2015.

- 101 Hammid, Ali Thaeer, Mohd Herwan Bin Sulaiman, and Ahmed N. Abdalla. "Prediction of small hydropower plant power production in Himreen Lake dam (HLD) using artificial neural network." *Alexandria engineering journal* 57, no. 1 (2018): 211-221.
- 102 Sun, Lei, Tianyuan Liu, Yonghui Xie, Di Zhang, and Xinlei Xia. "Real-time power prediction approach for turbine using deep learning techniques." *Energy* 233 (2021): 121130.
- 103 Bilgili, Mehmet, Sinan Keiyinci, and Firat Ekinici. "One-day ahead forecasting of energy production from run-of-river hydroelectric power plants with a deep learning approach." *Scientia Iranica* 29, no. 4 (2022).
- 104 Chapuis, Jacques, and Frantu Kraus. "Application of fuzzy logic for selection of turbines and weirs in hydro power plants." *IFAC Proceedings Volumes* 32, no. 2 (1999): 7190-7195.
- 105 Adhikary, Priyabrata, Pankaj Kr Roy, and Asis Mazumdar. "Safe and efficient control of hydro power plant by fuzzy logic." *IJESAT* 2, no. 5 (2012): 1270-1277.
- 106 Xu, Haoming, Deyi Wang, and Jiajun Liu. "Process control optimization for hydroelectric power based on neural network algorithm." *Adv Model Anal C* 72 (2017): 156-167.
- 107 Theophilus, Enebechi Chukwuemeka, and P. Eneh. "Design and development of NeuroFuzzy controller for hydropower generator stability." *Int J Sci Eng Res* 7, no. 6 (2016): 10561-1063.
- 108 OĞUZ, YÜKSEL, and KAMİL RİFAT İRFAN GÜNEY. "Adaptive neuro-fuzzy inference system to improve the power quality of variable-speed wind power generation system." *Turkish Journal of Electrical Engineering and Computer Sciences* 18, no. 4 (2010): 625-646.
- 109 Falchetta, Giacomo, Chisomo Kasamba, and Simon C. Parkinson. "Monitoring hydropower reliability in Malawi with satellite data and machine learning." *Environmental Research Letters* 15, no. 1 (2020): 014011.
- 110 Molina, José M., Pedro Isasi, Antonio Berlanga, and Araceli Sanchis. "Hydroelectric power plant management relying on neural networks and expert system integration." *Engineering Applications of Artificial Intelligence* 13, no. 3 (2000): 357-369.
- 111 Dao, Fang, Yun Zeng, Yidong Zou, and Jing Qian. "Wear fault diagnosis in hydro-turbine via the incorporation of the IWSO algorithm optimized CNN-LSTM neural network." *Scientific Reports* 14, no. 1 (2024): 25278.

- 112 Wotawa, Franz, Gerhard Friedrich, Ingo Pill, Roxane Koitz-Hristov, and Moonis Ali, eds. "Advances and Trends in Artificial Intelligence. From Theory to Practice: 32nd International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems, *IEA/AIE 2019*, Graz, Austria, July 9–11, 2019, Proceedings." (2019).
- 113 Li, Miao, Chang Hong Deng, Jin Tan, Wei Yang, and Li Zheng. "Research on small hydropower generation forecasting method based on improved BP neural network." In *2016 3rd International Conference on Materials Engineering, Manufacturing Technology and Control*, pp. 1085-1090. Atlantis Press, 2016.
- 114 Ak, Mümtaz, Elçin Kentel, and Serhat Kucukali. "A fuzzy logic tool to evaluate low-head hydropower technologies at the outlet of wastewater treatment plants." *Renewable and Sustainable Energy Reviews* 68 (2017): 727-737.
- 115 Yang, Bi, Zheng Bo, Zhang Yawu, Zhu Xi, Zhang Dongdong, and Jiang Yalan. "The vibration trend prediction of hydropower units based on wavelet threshold denoising and bi-directional long short-term memory network." In *2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA)*, pp. 575-579. IEEE, 2021.
- 116 Bai, V. Ramani, and Mohamad Rom Tamjis. "Fuzzy logic model on operation and control of hydro-power dams in Malaysia." *ICCES 4* (2007): 31-39.
- 117 Gunduz, Murat, and Haci Bayram Sahin. "An early cost estimation model for hydroelectric power plant projects using neural networks and multiple regression analysis." *Journal of Civil Engineering and Management* 21, no. 4 (2015): 470-477.
- 118 Tripathi, Pramesh, and Santosh Kumar Shrestha. "Risk assessment of boot hydropower projects in Nepal using fuzzy logic approach." *Journal of Advanced College of Engineering and Management* 3 (2017): 115-125.
- 119 Shimray, Benjamin A., Kh Manglem Singh, Thongam Khelchandra, and R. K. Mehta. "Ranking of sites for installation of hydropower plant using MLP neural network trained with GA: a MADM approach." *Computational intelligence and neuroscience* 2017, no. 1 (2017): 4152140.
- 120 Qu, Xudong, Jie Yang, and Meng Chang. "A Deep Learning Model for Concrete Dam Deformation Prediction Based on RS-LSTM." *Journal of Sensors* 2019, no. 1 (2019): 4581672.
- 121 Mosavi, Amir, Mohsen Salimi, Sina Faizollahzadeh Ardabili, Timon Rabczuk, Shahaboddin Shamshirband, and Annamaria R. Varkonyi-Koczy. "State of the art of machine learning models in energy systems, a systematic review." *Energies* 12, no. 7 (2019): 1301.

- 122 Pérez-Díaz, Juan I., and Jesús Fraile-Ardanuy. "Neural networks for optimal operation of a run-of-river adjustable speed hydro power plant with axial-flow propeller turbine." In *2008 16th Mediterranean Conference on Control and Automation*, pp. 309-314. IEEE, 2008.
- 123 Zaidi, Syed Mohammed Arshad, Varun Chandola, Melissa R. Allen, Jibonananda Sanyal, Robert N. Stewart, Budhendra L. Bhaduri, and Ryan A. McManamay. "Machine learning for energy-water nexus: challenges and opportunities." *Big Earth Data* 2, no. 3 (2018): 228-267.
- 124 Babar, M., P. H. Nguyen, V. Cuk, and I. G. Kamphuis. "The development of demand elasticity model for demand response in the retail market environment." In *2015 IEEE Eindhoven PowerTech*, pp. 1-6. IEEE, 2015.
- 125 Alves, Maria Joao, Carlos Henggeler Antunes, and Pedro Carrasqueira. "A hybrid genetic algorithm for the interaction of electricity retailers with demand response." In *Applications of Evolutionary Computation: 19th European Conference, EvoApplications 2016, Porto, Portugal, March 30--April 1, 2016, Proceedings, Part I 19*, pp. 459-474. Springer International Publishing, 2016.
- 126 Gao, Xin, Xiaobing Li, Bing Zhao, Weijia Ji, Xiao Jing, and Yang He. "Short-term electricity load forecasting model based on EMD-GRU with feature selection." *Energies* 12, no. 6 (2019): 1140.
- 127 He, Feifei, Jianzhong Zhou, Zhong-kai Feng, Guangbiao Liu, and Yuqi Yang. "A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm." *Applied energy* 237 (2019): 103-116.
- 128 Abumohsen, Mobarak, Amani Yousef Owda, and Majdi Owda. "Electrical load forecasting using LSTM, GRU, and RNN algorithms." *Energies* 16, no. 5 (2023): 2283.
- 129 Chuang, Shang-Yi, Nilima Sahoo, Hung-Wei Lin, and Yeong-Hwa Chang. "Predictive maintenance with sensor data analytics on a Raspberry Pi-based experimental platform." *Sensors* 19, no. 18 (2019): 3884.
- 130 James, Nicholas, Lee-Yeng Ong, and Meng-Chew Leow. "Exploring distributed deep learning inference using raspberry pi spark cluster." *Future internet* 14, no. 8 (2022): 220.
- 131 Klinkhammer, Dennis. "AI-ANNE:(A)(N) eural (N) et for (E) xploration: Transferring Deep Learning Models onto Microcontrollers and Embedded Systems." *arXiv preprint arXiv:2501.03256* (2025).
- 132 Li, En, Zhi Zhou, and Xu Chen. "Edge intelligence: On-demand deep learning model co-inference with device-edge synergy." In *Proceedings of the 2018 workshop on mobile edge communications*, pp. 31-36. 2018.

- 133 Ren, Haoyu, Darko Anicic, and Thomas A. Runkler. "TinyReptile: TinyML with federated meta-learning." In **2023 international joint conference on neural networks (IJCNN)**, pp. 1-9. IEEE, 2023.
- 134 Rashid, Hasib-Al, Pretom Roy Ovi, Carl Busart, Aryya Gangopadhyay, and Tinoosh Mohsenin. "Tinym2net: A flexible system algorithm co-designed multimodal learning framework for tiny devices." *ArXiv* (2022): arXiv-2202.
- 135 Kaur, Sukhmeet, Namita Kathpal, and Nitika Munjal. "Role of SCADA in hydro power plant automation." *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering* 4, no. 10 (2015): 8085-8090.
- 136 Gupta, Raju, S. N. Singh, and S. K. Singal. "Automation of small hydropower station." In *International Conference on Small Hydropower-Hydro Sri Lanka*, vol. 22, p. 24. 2007.
- 137 Newman, Teague, Tiffany Rad, L. L. C. ELCnetworks, John Strauchs, and L. L. C. Strauchs. "SCADA & PLC vulnerabilities in correctional facilities." *white paper* (2011): 1-14.
- 138 Toylan, Hayrettin, and Hilmi Kusu. "A research on SCADA application by the help of OPC server for water tank filling system." *Scientific Research and Essays* 5, no. 24 (2010): 3932-3938.
- 139 Lakhoua, Mohamed Najeh. "SCADA applications in thermal power plants." *International Journal of the Physical Sciences* 5, no. 6 (2010): 1175-1182.
- 140 Ruzhekov, G., Ts Slavov, and T. Puleva. "Modeling and implementation of hydro turbine power adaptive control based on gain scheduling technique." In **2011 16th International Conference on Intelligent System Applications to Power Systems**, pp. 1-6. IEEE, 2011.
- 141 Peng, Dao-gang, Hao Zhang, Li Yang, and Hui Li. "Design and realization of modbus protocol based on embedded linux system." In **2008 International Conference on Embedded Software and Systems Symposia**, pp. 275-280. IEEE, 2008.
- 142 MMajdalawieh, Munir, Francesco Parisi-Presicce, and Duminda Wijesekera. "DNP3Sec: Distributed network protocol version 3 (DNP3) security framework." *Advances in Computer, Information, and Systems Sciences, and Engineering* 1 (2006): 227-234.
- 143 Maynard, Peter, Kieran McLaughlin, and Berthold Haberler. "Towards understanding man-in-the-middle attacks on IEC 60870-5-104 SCADA networks." In **2nd International Symposium for ICS & SCADA Cyber Security Research 2014 (ICS-CSR 2014)**. BCS Learning & Development, 2014.

- 144 Stouffer, K., Falco, J., & Kent, K. Guide to Supervisory Control and Data Acquisition (SCADA) and Industrial Control Systems Security. USA: NIST (*National institute of Standards and Technology*), Special Publication 800-82. (2006).
- 145 Schneider. Canada: Schneider Electric, Telemetry and Remote SCADA solution. SCADA Systems [*White paper*]. March 2012.
- 146 Sayed, K. and Gabbar, H.A., SCADA and smart energy grid control automation. In Smart energy grid engineering (pp. 481-514). *Academic Press*. 2017.
- 147 Bailey, David, and Edwin Wright. *Practical SCADA for industry*. Elsevier, 2003.
- 148 Boyer, A. S. SCADA: Supervisory Control and Data Acquisition. (3th Ed.). ISBN 1-55617-877-8. USA: ISA- *The Instrumentation, Systems and Automation Society*. 2004
- 149 Carke, G., D. Rynders, and E. Wright. "Practical Modern SCADA Protocols." *Elsevier* (2003).
- 150 Arghira, Nicoleta, Daniela Hossu, Ioana Fagarasan, Sergiu Stelian Iliescu, and Daniel Razvan Costianu. "Modern SCADA philosophy in power system operation-A survey." *University "Politehnica" of Bucharest Scientific Bulletin, Series C: Electrical Engineering* 73, no. 2 (2011): 153-166.
- 151 Tracy Adams, P.E. SCADA System Fundamentals. Continuing Education and Development, Inc. Course No: E01-007, 9 *Greyridge Farm Court Stony Point*. 2014
- 152 Mackay, S., Wright, E., Reynders, D. "Practical Industrial Data Networks: Design, Installation and Troubleshooting", *Newnes*, 2004.
- 153 Hieb, Hieb, Jeffrey Lloyd. Security hardened remote terminal units for SCADA networks. *University of Louisville*, 2008.
- 154 Chelsea. Four Critical Components of Every SCADA System, 2018, <https://www.scadata.net/four-critical-components-of-every-scada-system/> (2025).
- 155 Sayed, Khairy, and Hossam A. Gabbar. "SCADA and smart energy grid control automation." In *Smart energy grid engineering*, pp. 481-514. Academic Press, 2017.
- 156 Brusso, Barry C. "50 Years of Industrial Automation [History]." *IEEE Industry Applications Magazine* 24, no. 4 (2018): 8-11.

- 157 Remote terminal unit, Wikipedia https://en.wikipedia.org/wiki/Remote_terminal_unit?utm_source=chatgpt.com, (2025).
- 158 Kasapbaşı, Ahmed. "Design and development of a smart control system to supply sustainable energy to a refugee camp." *Master's thesis, Fen Bilimleri Enstitüsü*, 2019.
- 159 Dias, Agnaldo Vieira, José Antenor Pomilio, and Saulo Finco. "A current limiting switch for applications in space power systems." In *2017 IEEE southern power electronics conference (SPEC)*, pp. 1-6. IEEE, 2017.
- 160 LEPORE, DW, RA WILLIAMSON, and BG LIPTÁK. "4.21 Switches, Pushbuttons, Keyboards." (2006).
- 161 Band, Erua J., and F. I. Anyasi. "Design of an automatic water level controller using mercury float switch." *IOSR Journal of Electronics and Communication Engineering* 9, no. 2 (2014): 16-21.
- 162 Efanov, Dmitry, Andrey Lykov, and German Osadchy. "Testing of relay-contact circuits of railway signalling and interlocking." In *2017 IEEE East-West Design & Test Symposium (EWDTS)*, pp. 1-7. IEEE, 2017.
- 163 Zihao, Sergiu Clima, Daniele Garbin, Robin Degraeve, Geoffrey Pourtois, Zhitang Song, and Min Zhu. "Chalcogenide ovonic threshold switching selector." *Nano-Micro Letters* 16, no. 1 (2024): 81.
- 164 Sourideth, P., Phonepaseuth, P., Panthongsy, K. and Marie-Cécile, P., 2024. Refill Water Management System Using an IoT-Based Water Flow Sensor. *Journal of Engineering, Technology, and Applied Science (JETAS)*, 6(2), pp.83-92.
- 165 Tandeske, Duane. Pressure sensors: selection and application. *CRC Press*, 1990.
- 166 He, Runjie, Chuanxin Teng, Santosh Kumar, Carlos Marques, and Rui Min. "Polymer optical fiber liquid level sensor: A review." *IEEE Sensors Journal* 22, no. 2 (2021): 1081-1091.
- 167 Rai, Vineet Kumar. "Temperature sensors and optical sensors." *Applied Physics B* 88 (2007): 297-303.
- 168 Haitjema, Han. "The calibration of displacement sensors." *Sensors* 20, no. 3 (2020): 584.
- 169 Zaitsev, Ievgen O., and Anatolii S. Levytskyi. "Determination of response characteristic of capacitive coplanar air gap sensor." In *2017 IEEE Microwaves, Radar and Remote Sensing Symposium (MRRS)*, pp. 85-88. IEEE, 2017.

- 170 Turner, R. C., Pa A. Fuierer, R. E. Newnham, and Thomas R. Shrout. "Materials for high temperature acoustic and vibration sensors: A review." *Applied acoustics* 41, no. 4 (1994): 299-324.
- 171 Antonovskaya, Galina N., Natalya K. Kapustian, Alexander I. Moshkunov, Alexey V. Danilov, and Konstantin A. Moshkunov. "New seismic array solution for earthquake observations and hydropower plant health monitoring." *Journal of Seismology* 21 (2017): 1039-1053.
- 172 Nässelqvist, M., Gustavsson, R. and Aidanpää, J.O., 2012. Bearing load measurement in a hydropower unit using strain gauges installed inside pivot pin. *Experimental mechanics*, 52, pp.361-369.
- 173 Ginting, Setiawan, Joni Welman Simatupang, Iksan Bukhori, and Emil Robert Kaburuan. "Monitoring of electrical output power-based internet of things for micro-hydro power plant." In *2018 International Conference on Orange Technologies (ICOT)*, pp. 1-7. IEEE, 2018.
- 174 Gajic, Z., D. Trišić, and S. Roxenborg. "Rotor DC current measurement by utilizing current transformers." In *12th IET International Conference on Developments in Power System Protection (DPSP 2014)*, pp. 4-1. Stevenage UK: IET, 2014.
- 175 Jarry-Bolduc, David, and Emmanuel Cote. "Hydro energy generation and instrumentation & measurement: hydropower plant efficiency testing." *IEEE Instrumentation & Measurement Magazine* 17, no. 2 (2014): 10-14.
- 176 Antonovskaya, Galina N., Natalya K. Kapustian, Alexander I. Moshkunov, Alexey V. Danilov, and Konstantin A. Moshkunov. "New seismic array solution for earthquake observations and hydropower plant health monitoring." *Journal of Seismology* 21 (2017): 1039-1053.
- 177 Peng, Z. Y., J. D. Yang, and W. C. Guo. "Time response of frequency of the hydro-turbine governing system under the coupled action of surge tank and power grid." In *IOP Conference Series: Earth and Environmental Science*, vol. 49, no. 5, p. 052014. IOP Publishing, 2016.
- 178 Chen, Jinbao, Shaohua Liu, Yunhe Wang, Wenqing Hu, Yidong Zou, Yang Zheng, and Zhihuai Xiao. "Generalized predictive control application scheme for nonlinear hydro-turbine regulation system: Based on a precise novel control structure." *Energy* 296 (2024): 130916.
- 179 Tiwari, Ritu, and Thanga Raj Chelliah. "Design improvement and tuning of excitation system ST5B with PSS3B and coordinated OEL in hydropower plant." *IEEE Transactions on Industry Applications* 58, no. 5 (2022): 5895-5907.

- 180 Agarwal, Tarun. "Know All about SCADA System Architecture and Types with Applications." <http://www.edgefxkits.com/blog/scadasystemarchitecture-types-applications> (2014).
- 181 Wali, Arwa. "Analysis of security challenges in cloud-based SCADA systems: A survey." *Authorea Preprints* (2022).
- 182 Gaushell, Dennis J., and Henry T. Darlington. "Supervisory control and data acquisition." *Proceedings of the IEEE* 75, no. 12 (1987): 1645-1658.
- 183 MathWorks. (2021). MATLAB Documentation. Retrieved from <https://www.mathworks.com/help/matlab>. (2025).
- 184 Moler, Cleve, and Jack Little. "A history of MATLAB." *Proceedings of the ACM on Programming Languages* 4, no. HOPL (2020): 1-67.
- 185 Ogata, K. Modern Control Engineering (5th Ed.). *Prentice Hall*. (2010).
- 186 Shankar, K. MATLAB for Engineers. *Oxford University Press*. c
- 187 MathWorks. 2020. Simulink Documentation. <https://www.mathworks.com/help/simulink/>. (2020).
- 188 Beyer, R., & Kowalski, T. Control Systems Design with MATLAB. *Springer*. (2017).
- 189 Jump up to:a b "Command line vs. GUI". *Computer Hope*. March 2025.
- 190 Fellmann, Tom, and Manolya Kavakli. "A command line interface versus a graphical user interface in coding vr systems." In *Proceedings of the 2nd IASTED International Conference on Human-Computer Interaction, HCI*, pp. 142-147. 2007.
- 191 "The GUI versus the Command Line: Which is better? (Part 2)". *Microsoft.com Operations*. Microsoft Learn. 2007-03-26.
- 192 Jansen, Bernard J. "The graphical user interface." *ACM SIGCHI Bulletin* 30, no. 2 (1998): 22-26.
- 193 Božić, Milivoj, Dušan Živkov, Ištvan Pap, and Goran Miljković. "Scriptable graphical user interface engine for embedded platforms." In *2013 21st Telecommunications Forum Telfor (TELFOR)*, pp. 971-974. IEEE, 2013.
- 194 Martinez, Wendy L. "Graphical user interfaces." *Wiley Interdisciplinary Reviews: Computational Statistics* 3, no. 2 (2011): 119-133.
- 195 Wilson, Greg. "Off with their huds!: Rethinking the heads-up display in console game design." *Retrieved April 17* (2006): 2013.

- 196 Slinger, Chris, Colin Cameron, and Maurice Stanley. "Computer-generated holography as a generic display technology." *Computer* 38, no. 8 (2005): 46-53.
- 197 Fox, John. "The R commander: a basic-statistics graphical user interface to R." *Journal of statistical software* 14 (2005): 1-42.
- 198 Nielsen, Jakob (January 29, 2012). "Browser and GUI Chrome". *Nngroup*. Archived from the original on August 25, 2012.
- 199 Martinez, Wendy L. "Graphical user interfaces: Graphical user interfaces". Wiley Interdisciplinary Reviews: Computational Statistics. 3 (2): <https://www.nngroup.com/topic/webusability/?apage=9&p age=10&vpage=2> (2011).
- 200 Hira ChoSusan S. FioritoSusan S. Fiorito, Self-Service Technology in Retailing. *The Case of Retail Kiosks*, 2010.
- 201 "What is a graphical user interface (GUI) ". *IONOS Digitalguide*. 14 September 2020.
- 202 Babich, Nick (30 May 2020). "Mobile UX Design: List View and Grid View". *Medium*. 2020.
- 203 Schema of the layers of the graphical user interface.svg https://en.wikipedia.org/wiki/File:Schema_of_the_layers_of_the_graphical_user_interface.svg, 2025.
- 204 The new Raspberry Pi 5 launches today, https://kitronik.co.uk/blogs/resources/raspberrypi5launchtoday?srsltid=AfmBOooCdhFwWI8r7uGwORSjPupCbdBBT5rEKjNFMXTapvbwZkP_gNB4, 2025.
- 205 Abed, A.A. and Rahman, S.A., 2017. Python-based Raspberry Pi for hand gesture recognition. *International Journal of Computer Applications*, 173(4), pp.18-24.
- 206 Pajankar, A., Raspberry Pi computer vision programming: design and implement computer vision applications with Raspberry Pi, OpenCV, and Python 3. *Packt Publishing* Ltd. 2020.
- 207 "predict". Oxford English Dictionary (Online ed.). *Oxford University Press*. (2025).
- 208 Silver, Nate The Signal and the Noise: Why so many predictions fail—but some don't. New York: Penguin Press. *ISBN 978-1-59420-411-1*. (2012).
- 209 Cox, David Roxbee. Principles of statistical inference. *Cambridge university press*, 2006.

- 210 Siegel, Eric (2013). Predictive Analysis: The Power to Predict Who Will Click, Buy, Lie, or Die. Hoboken, NJ: John Wiley & Sons. **ISBN 978-1-118-35685-2**. (2013).
- 211 Julier, S. J.; Uhlmann, J. K. (2004). "Unscented filtering and nonlinear estimation". *Proceedings of the IEEE*. 92 (3). 2004.
- 212 Fox, John (2016). Applied Regression Analysis and Generalized Linear Models (Third ed.). **London**: Sage. ISBN 978-1-4522-0566-3. 2016.
- 213 Jennifer T PentzAparna. BiswasAparna Biswas. Bassel Alsaed. Peter A Lind. Forecasting of phenotypic and genetic outcomes of experimental evolution in *Pseudomonas syringae* and *Pseudomonas savastanoi*, **DOI: 10.1101/2024.02.10.579745**. 2024.
- 214 Garcia Hernandez, Maria Inmaculada "Life time prediction for low energy and ecological effects bituminous mixtures". *Construction and Building Materials*. (2018).
- 215 Califf, Robert M. "Biomarker definitions and their applications." *Experimental biology and medicine* 243, no. 3 (2018): 213-221.
- 216 Amar, J., Rahimi, S., Surak, Z., & von Bismarck, N. AI-driven operations forecasting in data-light environments. *McKinsey & Company*. (2022).
- 217 IMB, forecasting, <https://www.ibm.com/think/topics/forecasting>. 2025.
- 218 Danese, P. and Kalchschmidt, M., The role of the forecasting process in improving forecast accuracy and operational performance. *International journal of production economics*, 131(1), pp.204-214. 2011.
- 219 Jain, Sharad Kumar, Pankaj Mani, Sanjay K. Jain, Pavithra Prakash, Vijay P. Singh, Desiree Tullos, Sanjay Kumar, Shefali P. Agarwal, and Ashok P. Dimri. "A Brief review of flood forecasting techniques and their applications." *International journal of river basin management* 16, no. 3 (2018): 329-344.
- 220 Significance and Challenges of Hydropower Energy <https://www.shankariasparliament.com/current-affairs/significance-and-challenges-of-hydropower-energy>. 2025.
- 221 Kumar, Krishna, and R. P. Saini. "Application of Artificial Intelligence for the Optimization of Hydropower Energy Generation." *EAI Endorsed Trans. Ind. Networks Intell. Syst.* 8, no. 28 (2021): e1.
- 222 AWS, Recurrent Neural Network, https://aws.amazon.com/what-is/recurrent-neural-network/?nc1=h_ls. 2025.

- 223 Bobat, Alaeddin. "Thermal pollution caused by hydropower plants." In *Energy systems and management*, pp. 19-32. Springer International Publishing, 2015.
- 224 A Guide to Recurrent Neural Networks (RNNs), <https://www.ibm.com/think/topics/forecasting?hl=en-US>. 2025.
- 225 Schmidt, Robin M. "Recurrent neural networks (rnns): A gentle introduction and overview." *arXiv preprint arXiv:1912.05911* (2019).
- 226 Jump up to:a b c Hochreiter, Untersuchungen zu dynamischen neuronalen Netzen (PDF) (diploma thesis). *Technical University Munich, Institute of Computer Science*. Sepp (1991).
- 227 Ahmad, A.M., Ismail, S. and Samaon, D.F., 2004, October. Recurrent neural network with backpropagation through time for speech recognition. In *IEEE International Symposium on Communications and Information Technology*, 2004. ISCIT 2004. (Vol. 1, pp. 98-102). IEEE.
- 228 Hochreiter, Sepp, and Jürgen Schmidhuber. "LSTM can solve hard long time lag problems." *Advances in neural information processing systems* 9 (1996).
- 229 Gers, Felix A., Jürgen Schmidhuber, and Fred Cummins. "Learning to forget: Continual prediction with LSTM." *Neural computation* 12, no. 10 (2000): 2451-2471.
- 230 Graves, Alex, Santiago Fernández, Faustino Gomez, and Jürgen Schmidhuber. "Connectionist temporal classification: labelling unsegmented sequence data with recurrent neural networks." In *Proceedings of the 23rd international conference on Machine learning*, pp. 369-376. 2006.
- 231 Karim, Fazle, Somshubra Majumdar, Houshang Darabi, and Shun Chen. "LSTM fully convolutional networks for time series classification." *IEEE access* 6 (2017): 1662-1669.
- 232 Schmidhuber, Jürgen, Daan Wierstra, and Faustino J. Gomez. "Evolino: Hybrid neuroevolution/optimal linear search for sequence prediction." In *Proceedings of the 19th International Joint Conference on Artificial Intelligence (IJCAI)*. 2005.
- 233 Sak, Hasim, Andrew W. Senior, and Françoise Beaufays. "Long short-term memory recurrent neural network architectures for large scale acoustic modeling." In *Interspeech*, vol. 2014, pp. 338-342. 2014.
- 234 Li, Xiangang, and Xihong Wu. "Constructing long short-term memory based deep recurrent neural networks for large vocabulary speech recognition." In *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 4520-4524. IEEE, 2015.

- 235 Yonghui, Mike Schuster, Zhifeng Chen, Quoc V. Le, Mohammad Norouzi, Wolfgang Macherey, Maxim Krikun et al. "Google's neural machine translation system: Bridging the gap between human and machine translation." *arXiv preprint arXiv:1609.08144* (2016).
- 236 Jump up to:a b Ong, "Facebook's translations are now powered completely by AI". www.allthingsdistributed.com. Retrieved 2019-02-15. Thuy (2017).
- 237 Sahidullah, Md, Jose Patino, Samuele Cornell, Ruiqing Yin, Sunit Sivasankaran, Hervé Bredin, Pavel Korshunov et al. "The speed submission to DIHARD II: Contributions & lessons learned." *arXiv preprint arXiv:1911.02388* (2019).
- 238 Mayer, Hermann, Faustino Gomez, Daan Wierstra, Istvan Nagy, Alois Knoll, and Jürgen Schmidhuber. "A system for robotic heart surgery that learns to tie knots using recurrent neural networks." *Advanced Robotics* 22, no. 13-14 (2008): 1521-1537.
- 239 Andrychowicz, OpenAI: Marcin, Bowen Baker, Maciek Chociej, Rafal Jozefowicz, Bob McGrew, Jakub Pachocki, Arthur Petron et al. "Learning dexterous in-hand manipulation." *The International Journal of Robotics Research* 39, no. 1 (2020): 3-20.
- 240 Rodriguez, J. "The science behind OpenAI Five that just produced one of the greatest breakthrough in the history of AI." *Towards Data Science* (2018).
- 241 Stanford, S. "DeepMind's AI, AlphaStar, showcases significant progress towards AGI." *Medium ML Memoirs* (2019).
- 242 Schmidhuber, Jürgen, and A. Blog. "The 2010s: our decade of deep learning/outlook on the 2020s." *The recent decade's most important developments and industrial applications based on our AI, with an outlook on the 2020s, also addressing privacy and data markets* (2020).
- 243 Joudaki, Majid, Mehdi Imani, and Hamid R. Arabnia. "A New Efficient Hybrid Technique for Human Action Recognition Using 2D Conv-RBM and LSTM with Optimized Frame Selection." *Technologies* 13, no. 2 (2025): 53.
- 244 Venna, Siva R., Amirhossein Tavanaei, Raju N. Gottumukkala, Vijay V. Raghavan, Anthony S. Maida, and Stephen Nichols. "A novel data-driven model for real-time influenza forecasting." *Ieee Access* 7 (2018): 7691-7701.
- 245 Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." *Neural computation* 9, no. 8 (1997): 1735-1780.
- 246 Fan, Hongxiang, Mingliang Jiang, Ligang Xu, Hua Zhu, Junxiang Cheng, and Jiahu Jiang. "Comparison of long short term memory networks and the hydrological model in runoff simulation." *Water* 12, no. 1 (2020): 175.

- 247 Yu, Yong, Xiaosheng Si, Changhua Hu, and Jianxun Zhang. "A review of recurrent neural networks: LSTM cells and network architectures." *Neural computation* 31, no. 7 (2019): 1235-1270.
- 248 Ardizzon, Guido, Giovanna Cavazzini, and Giorgio Pavesi. "A new generation of small hydro and pumped-hydro power plants: Advances and future challenges." *Renewable and Sustainable Energy Reviews* 31 (2014): 746-761.
- 249 Xie, Judy Jingwei, Elina Brutschin, Joeri Rogelj, and Iain Staffell. "Past socio-political transitions away from coal and gas show challenges and opportunities ahead." *Environmental Research Letters* (2025).
- 250 Energy Institute. "Statistical review of world energy." *Bnergy Institute* (2023).
- 251 Chala, Girma T., M. I. N. Ma'Arof, and Rakesh Sharma. "Trends in an increased dependence towards hydropower energy utilization—a short review." *Cogent Engineering* 6, no. 1 (2019): 1631541.
- 252 Moran, Emilio F., Maria Claudia Lopez, Nathan Moore, Norbert Müller, and David W. Hyndman. "Sustainable hydropower in the 21st century." *Proceedings of the national academy of sciences* 115, no. 47 (2018): 11891-11898.
- 253 Karre, Ravi Kiran, Kasangottu Srinivas, Khaja Mannan, B. Prashanth, and Ch Rajendra Prasad. "A review on hydro power plants and turbines." In *AIP Conference Proceedings*, vol. 2418, no. 1. AIP Publishing, 2022.
- 254 U. S. Energy Information Administration "Hydropower explained" <https://www.eia.gov/energyexplained/hydropower/>, 2024.
- 255 Alagöz, I., Mehmet Bulut, Veysel Geylani, and Arif Yıldırım. "Importance of real-time hydro power plant condition monitoring systems and contribution to electricity production." *Turk. J. Electr. Power Energy Syst* 1, no. 1 (2021): 1-11.
- 256 CIGRE Study Committee SC11, EG11.02. Hydrogenerator failures-results of the survey. <https://www.e-cigre.org/publications/detail/392-survey-of-hydrogenerator-failures.html>, 2024.
- 257 Lai, Jung-Pin, Yu-Ming Chang, Chieh-Huang Chen, and Ping-Feng Pai. "A survey of machine learning models in renewable energy predictions." *Applied Sciences* 10, no. 17 (2020): 5975.
- 258 Er. R.K. Aggarwal, Dynamic Stresses Hydro Power Plant RKAggarwal, <https://www.scribd.com/document/141411086/DynamicStressesHydroPowerPlantRKAggarwal>, 2013.
- 259 S.K. Singh, (Research Scholar, Dept. Of Mech. Engg., IITG), *Acoustics Based ondition Monitoring*, 2022.

- 260 J.R. Stack, T.G. Habetler, R.G. Harley, Effects of machine speed on the development and detection of rolling element bearing faults, *IEEE Power Electron. Lett.* 1 (2003) 19–21.
- 261 V. Mircea, T. Radu, D. Danut, Critical analysis of vibration sources of hydro aggregates in operating regime, *J. Sustainable Energy* 2 (2011) –8.
- 262 Åsnes, Asgeir Øen. "Condition monitoring of hydroelectric power plants." *Master's thesis*, NTNU, 2018.
- 263 I. Ahmad, A. Rashid, On-line monitoring of hydro power plants in Pakistan, *nf. Technol. J.* (2007) 919–923.
- 264 Wang, KeSheng. Vibration monitoring on electrical machine using vold-Kalman filter order Tracking. *University of Pretoria* (South Africa), 2008.
- 265 Xue, Hongtao, Huaqing Wang, Peng Chen, Ke Li, and Liuyang Song. "Automatic diagnosis method for structural fault of rotating machinery based on distinctive frequency components and support vector machines under varied operating conditions." *Neurocomputing* 116 (2013): 326-335.
- 266 P. Sridharan, N. Kuppuswamy, Mitigation of vibration on bulb turbine in mall hydroelectric power plants, *Int. J. Eng. Technol.* 5 (2014) 4968–4979.
- 267 Muhsen, Abdulmuttalib A., Grzegorz M. Szymański, Tahseen A. Mankhi, and Bashar Attiya. "Selecting the most efficient maintenance approach using AHP multiple criteria decision making at haditha hydropower plant." *Zeszyty Naukowe Politechniki Poznańskiej. Organizacja i Zarządzanie* 78 (2018): 113-136.
- 268 Aronsen, Kristoffer Høyem. "An experimental investigation of in-line and combined in-line and cross-flow vortex induced vibrations." (2007).
- 269 Jiang, Dongyue, Minyi Xu, Ming Dong, Fei Guo, Xiaohua Liu, Guijun Chen, and Zhong Lin Wang. "Water-solid triboelectric nanogenerators: An alternative means for harvesting hydropower." *Renewable and Sustainable Energy Reviews* 115 (2019): 109366.
- 270 Choi, Young-Do, Jae-Ik Lim, You-Taek Kim, and Young-Ho Lee. "Performance and internal flow characteristics of a cross-flow hydro turbine by the shapes of nozzle and runner blade." *Journal of fluid science and technology* 3, no. 3 (2008): 398-409.
- 271 Brennen, Christopher E. Hydrodynamics of pumps. *Cambridge University Press*, 2011.
- 272 Xue, Hongtao, Huaqing Wang, Peng Chen, Ke Li, and Liuyang Song. "Automatic diagnosis method for structural fault of rotating machinery based on

- distinctive frequency components and support vector machines under varied operating conditions." *Neurocomputing* 116 (2013): 326-335.
- 273 Staino, Andrea, and Biswajit Basu. "Dynamics and control of vibrations in wind turbines with variable rotor speed." *Engineering Structures* 56 (2013): 58-67.
 - 274 Mankhi, Tahseen Ali, Stanisław Legutko, Jasim H. Al-Bedhany, and Abdulmuttalib A. Muhsen. "Selecting the Most Efficient Bearing of Wind Turbine Gearbox Using (Analytical Hierarchy Process) Method "AHP"." In *IOP Conference Series: Materials Science and Engineering*, vol. 518, no. 3, p. 032050. IOP Publishing, 2019.
 - 275 Bobat, Alaeddin. "Thermal pollution caused by hydropower plants." In *Energy systems and management*, pp. 19-32. Springer International Publishing, 2015.
 - 276 Nandi, Subhasis, Hamid A. Toliyat, and Xiaodong Li. "Condition monitoring and fault diagnosis of electrical motors—A review." *IEEE transactions on energy conversion* 20, no. 4 (2005): 719-729.
 - 277 Wang, KeSheng. Vibration monitoring on electrical machine using vold-Kalman filter order Tracking. *University of Pretoria* (South Africa), 2008.
 - 278 Brennen, Christopher E. Cavitation and bubble dynamics. *Cambridge university press*, 2014.
 - 279 AVEVA, Thames Water SCADA System, *Thames Water Seminars*, Izmit, 2007.
 - 280 Bobat, Alaeddin, Tolga Gezgin, and Hüseyin Aslan. "The SCADA system applications in management of Yuvacik Dam and Reservoir." *Desalination and Water Treatment* 54, no. 8 (2015): 2108-2119.
 - 281 Bobat, Alaeddin. "Thermal pollution caused by hydropower plants." In *Energy systems and management*, pp. 19-32. Springer International Publishing, 2015.
 - 282 Østby, Petter TK, Jan Tore Billdal, Kjell Sivertsen, Bjørn Haugen, and Ole G. Dahlhaug. "Dynamic stresses in high head francis turbines." *Int. J. Hydropower Dams* 23, no. 3 (2016): 88-92.
 - 283 Bobat, Alaeddin, Tolga Gezgin, and Hüseyin Aslan. "The SCADA system applications in management of Yuvacik Dam and Reservoir." *Desalination and Water Treatment* 54, no. 8 (2015): 2108-2119.
 - 284 Jozefowicz, Rafal, Oriol Vinyals, Mike Schuster, Noam Shazeer, and Yonghui Wu. "Exploring the limits of language modeling." *arXiv preprint arXiv:1602.02410* (2016).

- 285 Graves, Alex, and Jürgen Schmidhuber. "Framewise phoneme classification with bidirectional LSTM and other neural network architectures." *Neural networks* 18, no. 5-6 (2005): 602-610.
- 286 Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." *Neural computation* 9, no. 8 (1997): 1735-1780.
- 287 Million, Elizabeth. "The hadamard product." *Course Notes* 3, no. 6 (2007): 1-7.
- 288 Draper, Norman R., and Harry Smith. Applied regression analysis. Vol. 326. *John Wiley & Sons*, 1998.
- 289 Hoerl, Arthur E., and Robert W. Kennard. "Ridge regression iterative estimation of the biasing parameter." *Communications in Statistics-Theory and Methods* 5, no. 1 (1976): 77-88.
- 290 Hoerl, Arthur E., Robert W. Kannard, and Kent F. Baldwin. "Ridge regression: some simulations." *Communications in Statistics-Theory and Methods* 4, no. 2 (1975): 105-123.
- 291 Kowalski, Br R., and M. B. Seasholtz. "Recent developments in multivariate calibration." *Journal of Chemometrics* 5, no. 3 (1991): 129-145.
- 292 J. MacGregor, T. Kourti, Statistical process control of multivariate processes, *Control Engineering Practice* 3 (3) (1995).
- 293 Joe Qin, S. "Statistical process monitoring: basics and beyond." *Journal of Chemometrics: A Journal of the Chemometrics Society* 17, no. 8-9 (2003): 480-502.
- 294 Wise, Barry M., and Neal B. Gallagher. "The process chemometrics approach to process monitoring and fault detection." *Journal of Process Control* 6, no. 6 (1996): 329-348.
- 295 H. Hotelling, Analysis of a complex of stati stical variables into pri ncipal components, *Journal of Educational Psychology* 24 (6) (1933) 417.
- 296 H. Abdi, L.J.WilJ iams, Principal component analysis, Wiley Interdisciplinary Reviews: *Com- putational Statistics* 2 (4) (2010) 433-459.
- 297 P. Ralston, G. DePuy, J.H. Graham, Computer-based monitoring and fault diagnosis: a chem- ical process case study, *ISA Transactions* 40 (1) (2001) 85-98.
- 298 M. Zhu, A. Ghodsi, Automatic dimensional i ty selecti on from the scree plot via the use of profile likelihood, *Computatio nal Statistics & Data Analysis* 51 (2) (2006) 918-930.

- 299 (HARROU, Fouzi, et al. Statistical process monitoring using advanced data-driven and deep learning approaches: theory and practical applications. *Elsevier*, 2020.) (4)
- 300 HARROU, Fouzi, et al. Statistical process monitoring using advanced data-driven and deep learning approaches: theory and practical applications. *Elsevier*, 2020.
- 301 Jaramillo, Manuel, Wilson Pavón, and Lisbeth Jaramillo. "Adaptive forecasting in energy consumption: A bibliometric analysis and review." *Data* 9, no. 1 (2024): 13.
- 302 Zhang, J.; Xu, Z.; Wei, Z. Absolute logarithmic calibration for correlation coefficient with multiplicative distortion. *Commun. Stat.-Simul. Comput.* 2020, 52, 482–505.
- 303 Aggarwal, C.C. *Data Mining: The Textbook*; Springer: **Berlin/Heidelberg, Germany**, 2015; Volume 1.
- 304 Punyani, P., Gupta, R. and Kumar, A., 2022. A multimodal biometric system using match score and decision level fusion. *International Journal of Information Technology*, 14(2), pp.725-730.
- 305 Yuan, Bin, Biao He, Jiang Yan, Jianwen Jiang, Zetao Wei, and Xiaodong Shen. "Short-term electricity consumption forecasting method based on empirical mode decomposition of long-short term memory network." In *IOP Conference Series: Earth and Environmental Science*, vol. 983, no. 1, p. 012004. IOP Publishing, 2022.

ÖZGEÇMİŞ

Omer Farhan AL-HARDANEE; yüksek lisans derecelerini Ankara Yıldırım Beyazıt Üniversitesi'nden, Elektrik-Elektronik Mühendisliği bölümünden 2019 yılında almıştır. Halen Anbar Üniversitesi Elektrik Mühendisliği bölümünde öğretim görevlisidir ve aynı zamanda Karabük Üniversitesi'nde doktora öğrencisidir. Araştırma ilgi alanları iki ana alana odaklanmaktadır: kontrol sistemleri ve yapay zeka.

