

**T.C.
DOKUZ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
İŞLETME PROGRAMI
DOKTORA TEZİ**

**ENDÜSTRİ 4.0 ENTEGRASYONU İLE TÜRKİYE
ELEKTRİK ENERJİSİ DAĞITIM AĞI ARIZALARININ
GERÇEK ZAMANLI VE YAPAY ZEKÂYA DAYALI
ÖNGÖRÜ SİSTEMİNİN GELİŞTİRİLMESİ:
İZMİR-ÇEŞME UYGULAMASI**

Mahmut SAYAR

**Danışman
Prof. Dr. Hilmi YÜKSEL**

İZMİR - 2021

TEZ ONAY SAYFASI



YEMİN METNİ

Doktora Tezi olarak sunduğum “Endüstri 4.0 Entegrasyonu ile Türkiye Elektrik Enerjisi Dağıtım Ağı Arızalarının Gerçek Zamanlı ve Yapay Zekâya Dayalı Öngörü Sisteminin Geliştirilmesi: İzmir-Çeşme Uygulaması” adlı çalışmanın, tarafımdan, akademik kurallara ve etik değerlere uygun olarak yazıldığını ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

....../....../.....

Mahmut SAYAR

ÖZET

Doktora Tezi

**Endüstri 4.0 Entegrasyonu ile Türkiye Elektrik Enerjisi Dağıtım Ağı
Arızalarının Gerçek Zamanlı ve Yapay Zekâya Dayalı Öngörü Sisteminin
Geliştirilmesi: İzmir-Çeşme Uygulaması
Mahmut SAYAR**

Dokuz Eylül Üniversitesi

Sosyal Bilimler Enstitüsü

İşletme Anabilim Dalı

İşletme Programı

Dünya, yapay zekâ, donanım ve yazılım alanlarındaki gelişmelerin sağladığı imkânlar neticesinde; farklı sistemler arasında sürekli veri akışlarının olduğu, sistemlerin birbirini uyarabildiği, operasyon kararlarının ve düzeltmelerin otonom şekilde gerçekleştirildiği ve tüm işlemlerin gerçek zamanlı yapılabildiği bir dönüşümün içinde hızla ilerlemektedir. Endüstri 4.0 olarak adlandırılan; ürünlerin, nesnelerin, süreçlerin, makinaların, teçhizatların ve daha birçok platformun gerçek zamanlı birbirine bağlanabildiği ve operasyonların yine gerçek zamanlı gerçekleştirildiği akıllı dönüşüm sayesinde günlük yaşam birçok noktada etkilenmektedir. Türkiye kamu ve özel sektör sistemlerinde Endüstri 4.0 entegrasyon seviyesinin yükseltilmesiyle devlet yönetim ve operasyon etkinliği yanında; kurumlardan alınan hizmet kalitesinde önemli artışlar sağlanacaktır. Devletin yüksek maliyetli operasyonlarında iyileşmeler yaşanacaktır. Bu çalışmada enerji sektöründe yer alan elektrik enerjisi dağıtım ağları için Endüstri 4.0 bileşenleri entegrasyonuna ait kazanımlar yanında; dağıtım şebekelerinin saatlik sistem çalışma durumu tahmini için derin öğrenme yöntemi ile hedef programlama tekniğinin hibrit şekilde kullanıldığı model önerilmektedir. Çalışmada, Çeşme’ de kurulu dağıtım şebekesinin çalışma durumuna, elektrik tüketimine ve ilçenin meteorolojik faktörlerine ait saatlik veriler kullanılmıştır. Yüz farklı derin öğrenme modelinin tahmin sonuçları alınmıştır. Hedef programlama modeli sayesinde, derin

öğrenme modelleri tarafından oluşturulan tahmin sonuçları kullanılarak; enerjiye kesintisiz ulaşım konusunda bireylerin, kamu ve özel sektör işletmelerinin aldığı hizmet kalitesinin artırılmasını ve elektrik dağıtım işletmesinin operasyon maliyetinin minimizasyonunu sağlayan derin sinir ağı modelinin seçimi hedeflenmektedir. Derin öğrenme ve hedef programlama modellerini gerçek zamanlı çalıştıracak ve optimal tahmin modelini önerecek algoritma geliştirilmiştir. Çalışma, şebekeleri etkileyen faktör sayısının ve veri hacminin artırılması yanında; kullanılan tekniklerin geliştirilerek Türkiye’ de kurulu ve kurulacak olan tüm elektrik enerjisi dağıtım şebekelerine uygulanması konusunda ön çalışma özelliğini taşımaktadır.

Anahtar Kelimeler: Endüstri 4.0, Yapay Zekâ, Derin Öğrenme, Hedef Programlama, Optimizasyon, Operasyon Yönetimi, Elektrik Enerjisi Dağıtım Ağı, Arıza Öngörüsü, Üretim ve Hizmet Sistemleri, Kamu Sektörü, Güvenilirlik.

ABSTRACT

Doctoral Thesis

Doctor of Philosophy (PhD)

Improvement of Real Time and Artificial Intelligence Based Fault Prediction

System of Electricity Distribution Network of Turkey With Industry 4.0

Integration: Izmir-Cesme Case Study

Mahmut SAYAR

Dokuz Eylül University

Graduate School of Social Sciences

Department of Business Administration

Business Administration Program

World is going fast forward inside of a transformation in which there is continues flow of data between different systems, systems can alert each other, operational decisions and improvements can be executed autonomously by reason of means of developments in fields of artificial intelligence, hardware and software. Thanks to smart transformation, named as Industry 4.0, products, things, processes, machines, equipments and many more platforms are connected to each other in real time and again operations are executed in real time; daily life is affected in many aspects. Along with increase of Industry 4.0 integration level in Turkish public and private sectors, not only effectiveness of state governance and operation will increase; there will be an increase of quality in services of institutions give. There will be improvements of cost savings in State cost sections. In this study, together with integration of Industry 4.0 technologies gains in electricity distribution networks; hybrid model deep learning method for predicting hourly system status of distribution network and goal programming technique is suggested. In this study, status of distribution network and energy consumption in Çeşme and hourly data meteorological factors of the district are used. Prediction results of one hundred different deep learning models are obtained. The prediction results of deep learning models are used in the goal programming model. In terms of access to energy without interruption, it is

aimed to increase the quality of service provided to individuals, public and private sector enterprises and to choose deep neural network model that minimizes the operating cost of the electricity distribution enterprise. An algorithm is developed that enables deep learning and goal programming models to work in real time, and suggests optimal prediction model. Study is featured as preliminary work in terms of its application in established and planned to be established electric distribution networks in Turkey by developing techniques in use with increase in number of factors that affect networks and increase of data volume.

Keywords: Industry 4.0, Artificial Intelligence, Deep Learning, Goal Programming, Optimization, Operations Management, Electric Power Distribution Network, Fault Diagnosis, Production and Service Systems, Public Sector, Reliability.

**ENDÜSTRİ 4.0 ENTEGRASYONU İLE TÜRKİYE ELEKTRİK ENERJİSİ
DAĞITIM AĞI ARIZALARININ GERÇEK ZAMANLI VE YAPAY ZEKÂYA
DAYALI ÖNGÖRÜ SİSTEMİNİN GELİŞTİRİLMESİ:
İZMİR-ÇEŞME UYGULAMASI**

İÇİNDEKİLER

TEZ ONAY SAYFASI	ii
YEMİN METNİ	iii
ÖZET	iv
ABSTRACT	vi
İÇİNDEKİLER	viii
KISALTMALAR	xi
TABLolar LİSTESİ	xiii
ŞEKİLLER LİSTESİ	xiv
EKLER LİSTESİ	xviii
GİRİŞ	1

BİRİNCİ BÖLÜM

**ENDÜSTRİ 4.0, TEKNOLOJİLERİ VE TÜRKİYE KAMU SEKTÖRÜNDE
ENDÜSTRİ 4.0 DÖNÜŞÜMÜ**

1.1. ENDÜSTRİ 4.0 VE TEKNOLOJİLERİ	13
1.1.1. Nesnelerin İnterneti (Internet of Things)	19
1.1.2. Bulut Bilişim (Cloud Computing)	21
1.1.3. Büyük Veri (Big Data)	22
1.1.4. Simulasyon (Simulation)	24
1.1.5. Otonom Robotlar (Autonomous Robots)	25
1.1.6. Eklemeli Üretim (Additive Manufacturing)	25
1.1.7. Siber Güvenlik (Cyber Security)	26
1.1.8. Artırılmış Gerçeklik (Augmented Reality)	27
1.1.9. Yatay ve Dikey Sistem Entegrasyonu (Horizontal and Vertical System Integration)	28

1.1.10. Yapay Zekâ (Artificial Intelligence-AI)	29
1.2. ENDÜSTRİ 4.0 ALANINDA YAPILAN ÇALIŞMALAR	31
1.3. TÜRKİYE KAMU KURUMLARI VE ÖZEL SEKTÖR İŞLETMELERİNDE ENDÜSTRİ 4.0 DÖNÜŞÜMÜ	42
1.3.1. Endüstri 4.0 ve Sağlık Sektörü (Sağlık 4.0)	43
1.3.2. Endüstri 4.0 ve Ulaştırma Sektörü (Ulaştırma 4.0)	43
1.3.3. Endüstri 4.0 ve Kamu Kurumları (Kamu 4.0)	44
1.3.4. Endüstri 4.0 ve Enerji Sektörü (Enerji 4.0)	45

İKİNCİ BÖLÜM

ELEKTRİK ENERJİSİ DAĞITIM AĞI, FARKLI SEKTÖRLERDE BAKIM VE ARIZA ÇALIŞMALARI

2.1. ELEKTRİK ENERJİSİ DAĞITIM AĞI	46
2.2. FARKLI SEKTÖRLERDE BAKIM VE ARIZA ÇALIŞMALARI	53
2.3. ELEKTRİK DAĞITIM AĞI ARIZALARINA DAYALI ÇALIŞMALAR	56
2.3.1. Meteorolojik Faktörlere Dayalı Çalışmalar	56
2.3.2. Şebeke Bileşenlerine Dayalı Çalışmalar	67

ÜÇÜNCÜ BÖLÜM

YAPAY ZEKÂ, MAKİNE ÖĞRENMESİ, DERİN ÖĞRENME VE HEDEF PROGRAMLAMA

3.1. YAPAY ZEKÂ (ARTIFICIAL INTELLIGENCE)	79
3.2. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORK)	80
3.2.1. Çok Katmanlı Algılayıcı (The Multilayer Perceptron)	84
3.2.2. Yapay Sinir Ağlarının Eğitimi	86
3.3. MAKİNE ÖĞRENMESİ (MACHINE LEARNING)	87
3.4. DERİN ÖĞRENME (DEEP LEARNING)	88
3.4.1. Derin Öğrenme Tekniğinin Ortaya Çıkışı	93
3.4.2. Derin Öğrenme Yapıları	94
3.4.2.1. Evrişimsel Sinir Ağları (Convolutional Neural Networks)	94
3.4.2.2. Tekrarlayan Sinir Ağları (Recurrent Neural Network)	97
3.4.2.3. Uzun Kısa Süreli Hafıza Ağları (Long Short Term Memory)	99

3.4.2.4. Kısıtlı Boltzman Makineleri (Restricted Boltzmann Machines)	99
3.4.2.5. Derin İnanç Ağları (Deep Belief Network)	100
3.4.2.6. Derin Oto-Kodlayıcılar (Deep Autoencoders)	101
3.4.3. Literatürde Derin Öğrenme ve Yapay Sinir Ağı Çalışmaları	102
3.5. HEDEF PROGRAMLAMA (GOAL PROGRAMMING)	113

DÖRDÜNCÜ BÖLÜM

DERİN ÖĞRENME VE HEDEF PROGRAMLAMA YÖNTEMLERİ İLE ÇEŞME ELEKTRİK DAĞITIM AĞININ GERÇEK ZAMANLI ÖNGÖRÜ SİSTEMİNİN OLUŞTURULMASI

4.1. KULLANILAN VERİLER	119
4.2. ELEKTRİK ENERJİSİ DAĞITIM AĞI VE METEOROLOJİK FAKTÖRLERE AİT ANALİZLER (ÇEŞME)	122
4.2.1. Meteorolojik Faktörlere Ait Analizler	123
4.2.2. Elektrik Enerjisi Dağıtım Ağına Ait Analizler	129
4.3. DERİN ÖĞRENME MODELLERİ	144
4.4. DERİN ÖĞRENME MODELLERİ ŞEBEKE TAHMİN SONUÇLARI	152
4.5. TAHMİN MODELİ SEÇİM SÜRECİNDE DERİN ÖĞRENME VE HEDEF PROGRAMLAMA YÖNTEMLERİNİN HİBRİT MODELLENMESİ	158
4.5.1. Derin Öğrenme ve Hedef Programlama Modellerinin Hibrit Kullanımı İçin Önerilen Algoritma	159
SONUÇ	169
KAYNAKÇA	177
EKLER	

KISALTMALAR

AI	Yapay Zekâ /Artificial Intelligence
ANFIS	Uyarlamalı Nöro Bulanık Çıkarım Sistemi / Adaptive Neuro Fuzzy Inference System
ANN/YSA	Yapay Sinir Ağları / Artificial Neural Network
BP	Geri Yayılım / Back Propagation
CAIDI	Müşteri Ortalama Kesinti Süresi İndeksi / Customer Average Interruption Duration Index
CAIFI	Müşteri Ortalama Kesinti Frekans İndeksi / Customer Average Interruption Frequency Index
CBM	Durum Bazlı Bakım / Condition Based Maintenance
CNN	Evrişimsel Sinir Ağları / Convolutional Neural Networks
CPS	Siber Fiziksel Sistem / Cyber Physical System
DAE	Derin Oto Kodlayıcılar / Deep Autoencoders
DBN	Derin inanç ağları / Deep Belief Network
DL	Derin Öğrenme / Deep Learning
ERP	Kurumsal Kaynak Planlama / Enterprise Resource Planning
IIoT	Endüstriyel Nesnelerin İnterneti / Industrial Internet of Things
IoT	Nesnelerin İnterneti / Internet of Things
KPI	Anahtar Performans Göstergeleri / Key Performance Indicator
LSTM	Uzun Kısa Süreli Hafıza / Long Short Term Memory
M2M	Makineden Makineye / Machine 2 Machine
M2P	Makineden İnsana / Machine 2 People
ML	Makine Öğrenimi / Machine Learning
MLP	Çok Katmanlı Algılayıcı / The Multilayer Perceptron
NN	Sinir Ağı / Neural Network
OEE	Genel Ekipman Verimliliği / Overall Equipment Effectiveness
P2P	İnsandan İnsana / People 2 People
PCA	Temel Bileşenler Analizi / Principal Component Analysis
PG	Güç Şebekesi / Power Grid
PV	Fotovoltaik

RBM	Kısıtlı Boltzman Makineleri / Restricted Boltzmann Machines
ReLU	Doğrultulmuş Lineer Birim / Rectified Linear Unit
RFID	Radyo Frekansı ile Tanımlama / Radio Frequency Identification
RL	Pekiştirmeli Öğrenme / Reinforcement Learning
RNN	Tekrarlayan Sinir Ağı / Recurrent Neural Network
SAIDI	Sistem Ortalama Kesinti Süresi İndeksi / System Average Interruption Duration Index
SAIFI	Sistem Ortalama Kesinti Sıklık İndeksi / System Average Interruption Frequency Index
SCADA	Denetim Kontrolü ve Veri Toplama / Supervisory Control and Data Acquisition
SGI 4.0	Akıllı Şebeke Endüstri 4.0 / Smart Grid Industry 4.0
SL	Gözetimli Öğrenme / Supervised Learning
SVM	Destek Vektör Makinesi / Support Vector Machine
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
USL	Gözetimsiz Öğrenme / Unsupervised Learning
3D	3 Boyut / 3 Dimension

TABLÖLER LİSTESİ

Tablo 1: Endüstri 4.0 Teknolojileri	s. 17
Tablo 2: Endüstri 4.0 Yayınlarının Araştırma Kategorileri	s. 32
Tablo 3: Endüstri 4.0 Alanlarında Araştırma Düzeyi (2012-2017)	s. 39
Tablo 4: 1991–2005 ve 2006–2015 Aralıklarında Yapılan Araştırmalar	s. 52
Tablo 5: Meteorolojik Olayların Arıza Olasılıkları	s. 59
Tablo 6: Çalışmada Kullanılan Saatlik Veriler	s. 120
Tablo 7: Veri Setinin Bir Bölümü	s. 122
Tablo 8: Meteorolojik Faktörlere Ait Tanımlayıcı İstatistikler	s. 123
Tablo 9: Arıza Sayısı, Toplam Kesinti Süresi ve Ortalama Kesinti Süresi (Ay)	s. 129
Tablo 10: Haftanın Günleri Bazında Arıza Yüzdesi	s. 132
Tablo 11: Yıllara Göre Kesintiden Etkilenen Kullanıcı Sayısı	s. 133
Tablo 12: Kesinti Sayısı ve Süresi	s. 141
Tablo 13: Derin Öğrenme Modeli Girdi Faktörlerinin Korelasyon Analizi	s. 145
Tablo 14: Derin Öğrenme Modellerinde Kullanılan Veri Seti Örneği	s. 146
Tablo 15: Seçilen Derin Öğrenme Modellerinin Katman Yapıları	s. 148
Tablo 16: Derin Öğrenme Modeli Parametreleri (Model 52, 14, 72)	s. 151
Tablo 17: Hata Matrisi (Confusion Matrix)	s. 153
Tablo 18: Derin Öğrenme Modelleri (Model 52, 14, 72) Tahmin Hata Matrisleri	s. 154
Tablo 19: Derin Öğrenme Modellerinin Tahmin Genel Doğrulukları	s. 154
Tablo 20: Tahmin Başarısı En Düşük Derin Sinir Ağı Mimarisi (Model 38)	s. 156
Tablo 21: Hedef Programlama Modelinin Hedef Öncelik Katsayıları	s. 163
Tablo 22: Hedef Programlama Modeline Ait Maliyet Senaryoları	s. 164
Tablo 23: Tahmin Hata Matrisi İçin Hedef Değerler	s. 164
Tablo 24: Hedef Programlama İle Seçilen En İyi Derin Öğrenme Modelleri	s. 165

ŞEKİLLER LİSTESİ

Şekil 1: Endüstri 4.0 Kapsamında Endüstriyel Kablosuz Ağlar İle İlgili Şema	s. 7
Şekil 2: Endüstri 4.0 Tasarım İlkeleri	s. 8
Şekil 3: Sürdürülebilir Endüstri 4.0 Sistemi	s. 9
Şekil 4: Dijital Pusula	s. 11
Şekil 5: Endüstri 4.0 Alanındaki Yayın Eğilimi (Başlık, Özet, Anahtar Kelime)	s. 12
Şekil 6: Endüstri 4.0 ve Teknolojileri	s. 15
Şekil 7: Endüstri 4.0 Teknolojilerinin İlişkileri	s. 18
Şekil 8: IoT Teknolojileri ve Unsurları	s. 19
Şekil 9: Birbirine Bağlanacak Nesnelerin Tahmini Sayıları	s. 20
Şekil 10: Bilgi Tabanlı Sistem, Bilgi Keşfi ve Makine Öğrenmesi İlişkisi	s. 30
Şekil 11: Endüstri 4.0 Konusunda Alanlara Göre Yayın Sayısı	s. 31
Şekil 12: Yayın Sayılarının ve Atıfların Dağılımı (2011–2016)	s. 33
Şekil 13: Endüstri 4.0 Alanında Yıllara Göre Yayın Sayısı	s. 36
Şekil 14: Endüstri 4.0 Konusunda Sık Kullanılan Anahtar Kelimeler (Sayı ≥ 2)	s. 36
Şekil 15: Endüstri 4.0 Alanında Ülkelerin Yayın Sayıları (≥ 2 makale)	s. 37
Şekil 16: Endüstri 4.0 Alanında Makale Başlıklarındaki Anahtar Kelimeler	s. 37
Şekil 17: Endüstri 4.0 Alanında Araştırma Yaklaşımlarının Dağılımı	s. 38
Şekil 18: Endüstri 4.0 Alanında Araştırma Kategorilerinin Dağılımı 2012-2017	s. 38
Şekil 19: Çevre Koruma, Süreç Güvenliği ve Endüstri 4.0 Yayınlarının	s. 41
Şekil 20: Güç Sistemi Etkileşim Şeması	s. 46
Şekil 21: Elektrik Enerjisi Dağıtım Ağı	s. 48
Şekil 22: Geleneksel Güç Şebekesi & Akıllı Şebeke	s. 49
Şekil 23: Endüstri 4.0' ın Akıllı Şebeke İçin Temel İletişim ve Servis Mimarisi	s. 51
Şekil 24: Dağıtım Sistemi Güvenilirliği Alanında Yoğun Çalışma Yapılan	s. 52
Şekil 25: Elektrik Enerjisi Dağıtım Ağı Siber Fiziksel Sistem Mimarisi	s. 55
Şekil 26: Endüstriyel Sektörler ve Tanımlayıcı Öngörü İçin Çözümler	s. 56
Şekil 27: Şebeke Arızaları ve Müşterilere Etkisi	s. 61
Şekil 28: Elektrik Kesintisi Maliyetleri (2007–2016)	s. 62
Şekil 29: Güneybatı İngiltere' de İletim Sistemindeki Arızalar	s. 64
Şekil 30: Güç Trafo Bileşenlerine Ait Arıza İstatistikleri	s. 70
Şekil 31: Güç Trafosu Arızalarına Ait Sebep-Sonuç Diyagramı	s. 71

Şekil 32: Kesinti Kategorilerinin Arıza Frekansları	s. 72
Şekil 33: Kesintilerin Ortalama Onarım Süresinin Yıllık Dağılımı	s. 73
Şekil 34: Güç Transformatörlerinin Arıza Sebepleri	s. 74
Şekil 35: Güç Transformatörü Güvenilirliğinin Değerlendirilmesi	s. 75
Şekil 36: Trafo Arızalarının Nedenleri (1991-2010)	s. 76
Şekil 37: Trafo Sağlık Endeksi	s. 77
Şekil 38: Trafo Arıza Tespiti İçin Geri Yayılımlı YSA Mimarisi (BP-ANN)	s. 78
Şekil 39: Yapay Sinir Ağının Genel Mimarisi	s. 80
Şekil 40: Yapay Sinir Ağlarının Ana Bileşenleri	s. 81
Şekil 41: Yapay Nöronun Temel Yapısı	s. 82
Şekil 42: Sinir Ağı Yapılarının Sınıflandırılması	s. 84
Şekil 43: Üç Katmanlı Geri Yayılım Sinir Ağı	s. 85
Şekil 44: Geri Yayılım (Back Propagation) Algoritması	s. 86
Şekil 45: Temel Elementler Yapılı Nöron	s. 91
Şekil 46: Derin Öğrenme ve Diğer Öğrenme Algoritmaları	s. 92
Şekil 47: Derin Öğrenme Süreci	s. 94
Şekil 48: Evrimsel Sinir Ağı Katmanları	s. 95
Şekil 49: Tekrarlayan Sinir Ağı (RNN)	s. 98
Şekil 50: Kısıtlı Boltzman Makinesi (Restricted Boltzmann Machines-RBM)	s. 100
Şekil 51: Derin İnanç Ağları (Deep Belief Network-DBN)	s. 101
Şekil 52: Kablosuz Sistem Ağı (WSN) Hata Bulma Teknikleri	s. 105
Şekil 53: Deniz Rüzgâr Türbini Bileşen Ömrünün Tahmini İçin YSA Modeli	s. 106
Şekil 54: Öngörülü Arıza Tahmininde Kullanılan Yapay Sinir Ağı Modeli	s. 107
Şekil 55: Yenilenebilir Enerji Tahmini için Genel Çerçeve	s. 110
Şekil 56: Çeşme İlçesi' nin Konumu	s. 118
Şekil 57: İzmir Elektrik Dağıtım Ağı Gerçek Zamanlı Görüntüleme Sistemi	s. 119
Şekil 58: Çeşme Elektrik Dağıtım Ağı Gerçek Zamanlı Görüntüleme Sistemi	s. 120
Şekil 59: İzmir Otomatik Meteoroloji Gözlem İstasyonu	s. 121
Şekil 60: Aktüel Basınç Dağılımı	s. 124
Şekil 61: Aylara Göre Aktüel Basınç Değer Aralıkları	s. 124
Şekil 62: İşba Sıcaklığı Dağılımı	s. 125
Şekil 63: İşba Sıcaklığı Değer Aralıkları	s. 126

Şekil 64: Değer Aralıklarına Göre Nisbi Nem Frekansları	s. 126
Şekil 65: Değer Aralıklarına Göre Rüzgâr Hızı Frekansları	s. 127
Şekil 66: Rüzgâr Yönü Yoğunluğu	s. 128
Şekil 67: Değer Aralıklarına Göre Sıcaklık Frekansları	s. 128
Şekil 68: Yağış Miktarı	s. 129
Şekil 69: Aylara Göre Arıza Başına Ortalama Kesinti Süresi	s. 130
Şekil 70: Yıl Bazında Aylara Göre Arıza Sayıları	s. 131
Şekil 71: Haftanın Günlerine Ait Enerji Tüketimi-Arıza Sayısı	s. 131
Şekil 72: Yıl Bazında Haftanın Günlerinde Meydana Gelen Arıza Sayıları	s. 132
Şekil 73: Toplam Arıza Sayısının Haftanın Günlerine Olan Dağılımı	s. 133
Şekil 74: Etkilenen Kullanıcı Sayısı (Orta Gerilim-İmar İçi)	s. 134
Şekil 75: Etkilenen Kullanıcı Sayısı (Alçak Gerilim-İmar İçi)	s. 135
Şekil 76: Etkilenen Kullanıcı Sayısı (Orta Gerilim-İmar Dışı)	s. 135
Şekil 77: Etkilenen Kullanıcı Sayısı (Alçak Gerilim-İmar Dışı)	s. 136
Şekil 78: Etkilenen Kullanıcı Sayısı (Genel)	s. 137
Şekil 79: Toplam Etkilenme Süresi (Orta Gerilim-İmar İçi)	s. 138
Şekil 80: Toplam Etkilenme Süresi (Alçak Gerilim-İmar İçi)	s. 138
Şekil 81: Toplam Etkilenme Süresi (Orta Gerilim-İmar Dışı)	s. 139
Şekil 82: Toplam Etkilenme Süresi (Alçak Gerilim-İmar Dışı)	s. 140
Şekil 83: Etkilenme Süresi Genel Durum	s. 141
Şekil 84: Arıza Sayısı ve Kesinti Süresi	s. 142
Şekil 85: Arıza Başına Ortalama Kesinti Süresi	s. 143
Şekil 86: Ortalama Kesinti Süresi, Arıza Sayısı ve Kesinti Süresi İlişkisi	s. 143
Şekil 87: Derin Öğrenme Süreci	s. 147
Şekil 88: Yaygın Kullanılan Aktivasyon Fonksiyonları	s. 147
Şekil 89: Derin Öğrenme Modeli (Model 52: Çeşme Dağıtım Ağı Durumu)	s. 149
Şekil 90: Derin Öğrenme Modeli (Model 14: Çeşme Dağıtım Ağı Durumu)	s. 150
Şekil 91: Derin Öğrenme Modeli (Model 72: Çeşme Dağıtım Ağı Durumu)	s. 150
Şekil 92: Epoch ve Loss Değerleri (Model 52)	s. 152
Şekil 93: Epoch ve Loss Değerleri (Model 14)	s. 153
Şekil 94: Epoch ve Loss Değerleri (Model 72)	s. 153
Şekil 95: Derin Öğrenme Modellerinin Genel Tahmin Başarıları	s. 155

Şekil 96: Derin Öğrenme Modelleri Tahmin Genel Doğruluğu	s. 155
Şekil 97: Tahmin Genel Doğruluğu ve Arızalı Durum Tahmin Genel Doğruluğu	s. 156
Şekil 98: Derin Öğrenme-Hedef Programlama Hibrit Modeli ile Gerçek Zamanlı Tahmin Modeli Seçim Süreci	s. 160
Şekil 99: Durum-1' e Göre Seçilen Derin Öğrenme Modelleri	s. 166
Şekil 100: Durum-2' ye Göre Seçilen Derin Öğrenme Modelleri	s. 167
Şekil 101: Durum-3' e Göre Seçilen Derin Öğrenme Modelleri	s. 168



EKLER LİSTESİ

EK 1: Faktörler İçin Korelasyon Tablosu	ek s.1
EK 2: Elektrik Kesintilerinde Yaşanan Etkilenme Süreleri (Saat)	ek s.2
EK 3: Çeşme Elektrik Dağıtım Ağı Çalışma Durumuna Ait Derin Öğrenme Modelleri ve Tahmin Başarıları	ek s.3
EK 4: Hedef Programlama Modeli Hedeflere ve Amaç Fonksiyonuna Ait Ceza Maliyetleri (Penalty Cost)	ek s.6



GİRİŞ

Ülkelerin genelini ilgilendiren süreçlerin, operasyonların ve işlerin yönetilmesi ve düzenlenmesinden sorumlu olan kamu kurumları ile özel sektör işletmelerinin; teknolojik altyapılarını geliştirerek verimlilik ve performans artışı sağlamaları, toplumun refah ve medeniyet düzeyinin yükseltilmesi için oldukça önemli bir bileşendir. Endüstri 4.0 veya ilgili sektör türüne göre Kamu 4.0, Enerji 4.0, Sağlık 4.0, Ulaşım 4.0 ve Tarım 4.0 gibi terimler ile adlandırılan; ürünlerin, nesnelerin, süreçlerin, makinaların, teçhizatların ve daha birçok platformun gerçek zamanlı birbirine bağlanabildiği ve operasyonların gerçek zamanlı gerçekleştirildiği akıllı dönüşüm sayesinde günlük yaşam birçok noktada doğrudan etkilenmektedir. Bu çalışmada Endüstri 4.0 bileşenleri, yapay zeka ve optimizasyon konuları araştırılarak; Türkiye kamu kurumlarının Endüstri 4.0 dönüşümü ile eş zamanlı olarak yapay zeka ve optimizasyon tekniklerinin kullanımı sonucunda elde edilecek kazanımlar konusunda tespitler vurgulanmıştır. Kamu kurumları bilgiye dayalı strateji ve politikaların belirlenmesi amacıyla sektörlerden ve piyasalardan yüksek boyutlu ve çok çeşitli veri setlerini elde etmektedir. Üretilen büyük hacimdeki verilerin işlenerek anlamlandırılması ve saklı olan katma değerli kısımların ortaya çıkarılması; yeni stratejilerin geliştirilebilmesi açısından oldukça önemlidir. Endüstri 4.0' ın literatürde farklı sektörlerle göre Kamu 4.0, Enerji 4.0, Sağlık 4.0 ve Ulaşım 4.0 gibi farklı isimlendirmeleri bulunsa da; bu çalışmada kavram karmaşası olmaması açısından Endüstri 4.0 terimi tercih edilmektedir.

Dünya genelinde çalışmalarına yakın zamanda başlanan Endüstri 4.0 dönüşümünün; enerji sektörü gibi stratejik ve kamu hizmeti bakımından yüksek önem arz eden bir alanda yapılması, ülkemiz açısından önemi büyük bir kazanımdır. Elektrik enerjisi dağıtım ağları, tüm tüketici gruplarına enerjinin ulaştırılması ve ekonominin sürekliliği açısından kritik öneme sahiptir. Dağıtım ağlarının sağlıklı ve verimli çalışması, arızaların tahminine, erken tespitine ve ortaya çıkan arızaların hızlı şekilde giderilmesine bağlıdır. Çalışmada İzmir' in Çeşme ilçesinde kurulu olan elektrik enerjisi dağıtım ağının arızalı ve sağlıklı çalışma durumları, Endüstri 4.0 bileşenleri entegrasyonunun sağladığı imkânlar sayesinde gerçek zamanlı tahmin edilirken; tahmin için saatlik şebeke durumu (arızalı/sağlıklı), saatlik enerji tüketimi ve saatlik

meteorolojik faktörlere ait geçmiş verilerden faydalanılmıştır. Şebekede gerçek zamanlı tahmin ve öngörü sistemi kurulumu için bir yapay zeka tekniği olan derin öğrenme yöntemi ve optimizasyon modeli olan hedef programlama tekniği hibrit şekilde kullanılmıştır. Elektrik enerjisi iletim hatlarının mevcut durum (elektrik iletimi var/yok) tahmini, meydana gelecek arızaların öngörüsü, enerji güvenliği, arızaların ortaya çıkmadan gerekli önleyici bakımların yapılması, arıza durumunda erken müdahale, arıza ve bakım sürelerinin kısaltılması, elektrik enerjisi üretim ve tüketim arasında dengenin sağlanması ve hatlardaki yük dağılımlarının sağlıklı şekilde yapılması konularına katkıda bulunulması hedeflenmektedir.

Elektrik enerjisi dağıtım ağlarında meydana gelen arızalar (enerji kesintisi) şebeke içi ve şebeke dışı faktörlerden kaynaklı olarak ortaya çıkmaktadır. Literatürde farklı sektörlerde meydana gelen arızaların tahmini için farklı tekniklerin kullanıldığı birçok çalışma bulunmaktadır. Günümüzde giderek önem kazanan yapay zekâ tekniklerinin arıza ve sistem durumu tahminlerinde kullanımı; tahmin başarısı ve etkinliği bakımından diğer tekniklere kıyasla birçok avantaj sağlamaktadır. Enerji sektöründe yapay zekâ teknikleri kullanılarak yapılan önceki çalışmalarda, genellikle şebekenin bir bileşeni, elektrikli cihaz ve teçhizatların kullanım ömrü, enerji talep tahmini, pil ömrü ve ürün arızaları gibi başlıklara odaklanılmıştır. Sayar ve Yüksel' in yapay sinir ağı tekniğini kullanarak Manisa-Salihli' de kurulu olan elektrik dağıtım ağı için yaptıkları çalışma haricinde; meteorolojik faktörlerin elektrik dağıtım ağlarının çalışma durumu üzerindeki etkisini yapay zekâ tekniklerini kullanarak inceleyen çalışmaya rastlanılmamıştır (Sayar ve Yüksel, 2020: 307). Bu çalışmada yapay zekâ modellerine meteorolojik faktörlerin yanında; saatlik elektrik tüketimi girdisi de eklenmiştir.

Çalışmada kullanılan, elektrik enerjisi dağıtım ağının çalışma durumu (arızalı/sağlıklı) verileri, elektrik tüketim verileri ve meteorolojik faktörlere ait veriler saat bazında alınıp; elde edilen tüm veri setleri 27 aylık zaman dilimini kapsamaktadır. Saatlik veri setleri GDZ Elektrik Dağıtım AŞ, Türkiye Elektrik İletim AŞ (TEİAŞ) ve Meteoroloji Genel Müdürlüğü'nden elde edilmiştir. Çalışmanın uygulama bölümünde bir yapay zeka tekniği olan derin öğrenme yöntemi (deep learning) ve hedef programlama (goal programming) modeli hibrit şekilde kullanılmıştır. Derin öğrenme modelleri, saatlik geçmiş veri setleri kullanılarak eğitilmiş olup; elektrik tüketimi ile

meteorolojik faktör tahminlerinden oluşan gerçek zamanlı veriler kullanılarak şebekenin gelecekteki çalışma durumlarının tespiti için tahmin modelleri oluşturulmuştur. Oluşturulan hedef programlama modeli sayesinde, derin öğrenme yöntemiyle oluşturulan tahmin modelleri arasından; enerjiye kesintisiz ulaşım konusunda bireylerin, kamu ve özel sektör işletmelerinin aldığı hizmet kalitesinin artırılması ve elektrik dağıtım işletmesinin operasyon maliyetinin minimizasyonunu sağlayan modelin seçimi hedeflenmektedir. Derin öğrenme ve hedef programlama modellerini gerçek zamanlı çalıştıracak ve elektrik dağıtım işletmesine en uygun tahmin modelini sunacak algoritma önerilmiştir. Hedef programlama modeli birbirinden farklı 3 senaryo ile çalıştırılarak; bu senaryoların herbiri için 100 derin öğrenme modeli arasından hedefleri karşılayan en iyi derin öğrenme modeli seçilmiştir. Çalışmada, küresel rekabet için gerekli Endüstri 4.0 ve bileşenleri konularında literatür incelenmiştir. Ülkemizdeki çeşitli sektörlerde Endüstri 4.0 dönüşümün katkılarına değinilmiştir. Enerji sektöründe ve elektrik enerjisi dağıtım ağlarında yaşanan arızalarla ilgili kapsamlı literatür taraması yapılmıştır. Yapay zekâ, makine öğrenmesi ve derin öğrenme konuları incelenmiştir. Çeşme’de kurulu elektrik dağıtım ağının çalışma durumuna ait tahmin modellerinin gerçek zamanlı ve dinamik şekilde üretilmesi için Endüstri 4.0 bileşenleri altyapısından sağlanan ayrıcalıklar ile derin öğrenme ve hedef programlama modelleri oluşturulmuştur. Sonrasında bu modelleri hibrit şekilde çalıştıran algoritma önerilmiştir. Derin öğrenme ve hedef programlama modeli, geliştirilen algoritma sayesinde birbiriyle gerçek zamanlı haberleşmektedir. Hedef programlamaya ait hedefler ve kısıtlar derin öğrenme modellerinden gelen güncellemenin yanında; kamu ve dağıtım işletmesinin yararı doğrultusunda alınan kararlar neticesinde dinamik şekilde güncellenmektedir. Bu şekilde, güncel durum şartlarına dayalı olarak (anlık durum bazlı) optimal çözüme sürekli yaklaşılmaktadır.

Bu çalışmada, elektrik enerjisi dağıtım işletmesinin sağladığı kamu hizmet kalitesinin ve mevcut operasyonlarına ait verimin artırılması amacıyla ihtiyaç duyulan Endüstri 4.0 bileşenlerine ait altyapının geliştirilmesi ve yapay zekaya dayalı operasyon kararlarının verilmesi hedeflenmektedir. Çalışmada, şebekeyi etkileyen faktör sayısının ve faktörlere ait veri hacminin artırılması yanında kullanılan

tekniklerin geliştirilerek Türkiye’ de kurulu ve kurulacak olan tüm elektrik enerjisi dağıtım şebekelerine uygulanması için ön çalışma olması amaçlanmaktadır.

Çalışmadaki hedefler ve beklenen kazanımlardan bazıları şunlardır:

- Endüstri 4.0 bileşenlerinin, yapay zekâ ve derin öğrenme tekniklerinin kamu, enerji, sağlık ve savunma gibi kritik öneme sahip sektörlerde kullanımının yaygınlaşması.
- Enerjiye kesintisiz ulaşım konusunda bireylerin, kamu ve özel sektör işletmelerinin aldığı hizmet kalitesinin artırılması.
- Elektrik enerjisi dağıtım işletmelerinin operasyon maliyetlerinin azaltılması.
- Kamuya verilen hizmetlerde devlet harcamalarının azaltılması.
- Dinamik ortam koşullarında enerji dağıtım altyapısının gerçek zamanlı güvenilirlik analizlerinin yapılması, arıza öngörü sisteminin oluşturulması, sistemin güvenlik seviyesinin artırılması ve sistem arıza olasılıklarının azaltılması.
- Elektrik tüketimi, meteorolojik faktörler ve diğer faktör ve parametrelere ait geçmiş, gerçek zamanlı ve tahminsel veriler baz alınarak; elektrik dağıtım ağlarının çalışma durumlarının saatlik tahmin edilmesi.
- Arızalı trafolara ve diğer bileşenlere erken ulaşılması ve arıza giderme sürelerinin minimizasyonu.
- Öngörülü bakım planları için modellerin önerilmesi.
- Sistem hakkında geleceğe ait dinamik davranış modellerinin kurulması.
- Enerji dağıtım altyapısının güvenlik seviyesi kontrolünün otomatikleştirilmesi.
- Enerji kesinti sürelerinin azaltılması ile ekonomiye verilen zararın minimum seviyelere indirilmesi.

BİRİNCİ BÖLÜM

ENDÜSTRİ 4.0, TEKNOLOJİLERİ VE TÜRKİYE KAMU SEKTÖRÜNDE

ENDÜSTRİ 4.0 DÖNÜŞÜMÜ

Endüstri 4.0 kavramı, insanlar, sistemler, operasyonlar, işler, fonksiyonlar, tedarikçiler, müşteriler ve diğer tüm paydaşların gerçek zamanlı birbiriyle etkileşimde olduğu, veri paylaşımında bulunduğu ve paydaşlar arasındaki tüm ilişkilerin yapay zekâ ve algoritmalar ile otomatikleştirildiği sistemler bütünü olarak tanımlanabilmektedir. Endüstri 4.0, canlı organizmaların yaşamsal faaliyetlerinden ilham alan ve günümüzde kullanılan birçok teknolojinin belirli sistematik çerçevesinde bir araya getirilerek oluşturulduğu sistemler bütünüdür.

Endüstri 4.0 dönüşümü sayesinde, akıllı süreç, akıllı ürün ve akıllı prosedürlerin geliştirilmesine yoğunlaşmaktadır. Hannover Fuarı'nda 2011 yılında ilk tanıtım sunumu yapılan Endüstri 4.0 için ilk uygulama Nisan 2013' te gerçekleştirilmiştir (Bunse, Kagermann ve Wahlster, 2014: 24). Endüstri 4.0 dönüşümü sayesinde bireysel müşteri istekleri doğrultusunda hazırlanan yeni tasarım ve yeni ürünlerin pazara dâhil olma süreleri kısalmaktadır. Bu dönüşümde sanayi komponentleri ile akıllı üretim teknolojileri bir araya getirilerek kitlesel üretimin yerine bireysel üretime geçiş hedeflenmektedir (Pisching, Junqueira, Filho ve Miyagi, 2015: 65). Endüstri 4.0, üretim faaliyetlerinin genelinde uçtan uca dijital dönüşümü gerektirmektedir. Bu dönüşüm sayesinde, arızaların önlenmesi, arıza sürelerinin kısaltılması ve maliyetlerin azaltılabilmesi amacıyla sistem durumunun gerçek zamanlı izlenebildiği, birbirine bağlı, akıllı ve birlikte çalışabilen üretim sistemlerinin oluşturulması amaçlanmaktadır (Foresight, 2013: 58), (Giannetti ve Ransing, 2016: 70).

Endüstri 4.0, entegre edildiği sistem bileşenleri arasında veri toplama ve analiz imkanlarını sunarak; süreçlerde hız, esneklik ve verimi sağlamaktadır. Yüksek kaliteli ve düşük maliyetli üretimi destekleyerek; verimliliği artıracak, endüstriyel büyüme ile ekonomiye katkılar sunacak ve işgücü profilini nitelikli hale getirecektir (Gerbert ve diğerleri, 2015: 1). Endüstri 4.0, geleneksel sanayi sektörünün güçlü özelliklerini ileri teknolojiler ile donatmaktadır. Bünyesinde, akıllı ürünlerde bulunan fiziksel ve dijital süreç entegrasyonunu sağlayan teknolojileri bulundurmaktadır (Schmidt ve diğerleri,

2015: 16). Endüstri 4.0 dönüşümünün hedefi, IoT' u başarılı şekilde yaygınlaştırarak; üretim sistemlerini yüksek seviyede esnek ve adaptif yapıya dönüştürmektir (Weyer, Schmitt, Ohmer ve Gorecky, 2015: 579). Endüstri 4.0 entegrasyonunun sağlanabilmesi için, gelişmiş otomasyon, dijitalleşme süreçleri, elektronik ve bilgi teknolojilerinin kullanımı önemlidir. Büyük verilerin gerçek zamanlı analiz edilmesi, üretim süreçlerinde kaynakları optimize edecek ve daha iyi performans sağlayacaktır. Mobil bilgi işleme, bulut bilgisayar, büyük veri ve IoT, Endüstri 4.0'ın kilit teknolojileri arasındadır. Çok etmenli ürünler, siparişler, makine süreçleri, kontroller, yapay zeka ve genetik algoritmalar bir araya gelerek çalışabilirlik için kapsamlı olanaklar sağlamaktadır (Lu, 2017: 6–7).


Endüstri 4.0 dönüşümünün vizyonu, akıllı fabrika ortamında, akıllı, otonom, yetenekli ve büyük çaplı makine ağını oluşturmaktır. Endüstri 4.0 entegrasyonu olan bir makina, bir hammadde ve/veya yarı mamule uygulayacağı üretim sürecini ve yapacağı değişikliği bilmektedir. Böylece ürün, üretim hattında konfigürasyonu ve rotası benzersiz olan aktif bir varlık olarak tanımlanabilmektedir. Teknolojide yaşanan gelişmeler, siber fiziksel sistem (CPS) altyapısında farklı merkezlerden gelen bilgiler kullanılarak insanların ve makinelerin birbiriyle entegre olabilmelerini sağlamakla kalmayıp; makine-makine arasındaki doğrudan iletişimi de mümkün kılmaktadır. Bu şekilde iletişimlerin olduğu ağların üretim ve işletme sahalarında uygulanması sayesinde Endüstri 4.0 dönüşümü gerçekleşmektedir. Endüstri 4.0' ın üretim sürecinde entegrasyonunun tüm tedarik zinciri üzerinde birçok etkisi bulunmaktadır. Tedarikçiler, üreticiler ve müşteriler arasındaki iş birliği, siparişin gönderildiği andan başlayan ve ürün ömrünün tamamlandığı ana kadar geçen süreç boyunca tüm aşamalarda şeffaflığı artırmak için oldukça önemlidir.

Endüstri 4.0 entegrasyonu, bulut sistemlerine, CPS' lere ve endüstriyel nesnelerin internetine (IIoT) dayanmaktadır. Bunun yanında büyük veri, makineden makineye (M2M), makineden insanlara (M2P) ve insanlardan insanlara (P2P) olan iletişim, arayüzü, görselleştirmeler, emniyet, güvenlik, yerelleşme, dijitalleşme ve makineler-insanlar arasındaki işbirliğini kapsamaktadır (Zolotov , Papcun, Kaj ti, Mi kuf ve Mocnej, 2020: 3). Endüstri 4.0 dönüşümünün gerçekleşmesi; yatay ve dikey entegrasyon, ürünlerin, hizmetlerin, süreçlerin ve değer zincirlerinin dijitalleşmesi yanında; yenilikçi işletme modellerinin tercih edilmesi unsurlarına

bağlıdır (Gilchrist, 2016: 197). Stock and Seliger' e göre, Endüstri 4.0' ın ana uygulama alanları akıllı fabrika, akıllı üretim, akıllı ürün ve akıllı şehir olarak sıralanmaktadır (Stock ve Seliger, 2016: 536). Endüstri 4.0' ın tanımına dayanarak, üretim perspektifinden üç teknolojinin uygulama seviyesi (Diez-Olivan, Del Ser, Galar ve Sierra, 2019: 93):

- Dikey entegrasyon: Üretim ve otomasyon bağlamında, çeşitli bilgi işlem teknoloji sistemlerinin en temelinden (sensörler ve aktüatörler); uygulama, planlama ve çizelgeleme gibi en yüksek üretim yönetimine kadar farklı hiyerarşik seviyelerdeki entegrasyondur. Bu entegrasyon seviyesi üretim süreçlerini desteklemekte ve daha esnek hale getirmektedir.
- Yatay entegrasyon: Bu seviye bilgi işlem teknolojilerinin, üretim süreçlerinin ve iş planlamasının farklı aşamalarında yer alan mekanizmalarla ve birimlerle olan entegrasyonunu içermektedir.
- Dairesel entegrasyon: Son kullanıcıyı ve ürün yaşam döngüsünü birbirine bağlamak için dikey ve yatay entegrasyonların birleştirilmesidir. Bu entegrasyon üretim döngüsünü sonlandırmaktadır. Bu nedenle, ilk tasarım aşamalarından, planlama, üretim, lojistik ve kaynak yönetimi mekanizmalarına; nihayetinde son kullanıcı ve ürünle ilgili hizmetlere kadar baştan sona dijitalleşme gerçekleştirilebilmektedir.


Şekil 1: Endüstri 4.0 Kapsamında Endüstriyel Kablosuz Ağlar İle İlgili Şema



Kaynak: X. Li ve diğerleri, 2017: 36.

Geleneksel fabrika ile Endüstri 4.0 entegre edilmiş fabrika arasında önemli farklılıklar bulunmaktadır. Çeşitli veri kaynakları, fabrikanın farklı yönleriyle ilgili değerli bilgiler sağlayabilmektedir. Bu nedenle mevcut çalışma koşullarını anlamak; hataları ve arızaları tespit etmek için veri kullanımı oldukça önemlidir. Üretim sırasında, sorunların temel nedenlerini ve sistemdeki olası hataları vurgulamak için mevcut durumda genel ekipman verimliliği (OEE) bilgisini fabrika yönetimine sağlamak üzere çeşitli araçlar kullanılmaktadır. Endüstri 4.0 entegre edilmiş bir fabrikada mevcut durumu izlemeye ve hata tespitine ek olarak; bileşenler ve sistemler fabrikanın durumuyla ilgili daha detaylı içgörü sağlayarak fabrikaya yönetim, öz farkındalık ve öz öngörülük yeteneği kazandırmaktadır (Sung, 2018: 42).

Şekil 2: Endüstri 4.0 Tasarım İlkeleri




Kaynak: Sung, 2018: 42; Hermann, Pentek ve Otto: 2016.

Fraunhofer Enstitüsü tarafından yayınlanan “Endüstri 4.0” çalışmasının sonuçlarına göre, birlikte çalışabilirlik, sanallaştırma, otonomlaştırma, gerçek zamanlı yetenek, hizmet yönelimi ve modülerlik olarak altı tasarım ilkesini bileşenlerden türetmek mümkündür: Birlikte çalışabilirlik, fiziksel bileşenler, insanlar ve akıllı fabrikalar arasındaki bağlantı ve iletişimi sağlarken; sanallaştırma, fiziksel nesnelerin sanal kopyası olarak gerçekleştirilmektedir. Otonomlaştırma ve gerçek zamanlı yetenek nedeniyle, bileşenlerin gerçek zamanlı toplanan ve analiz edilen verilere dayanarak kendi başlarına karar almaları sağlanmaktadır (Mrugalska ve Wyrwicka, 2017: 470).

Stock ve Seliger değer oluşturma faaliyetlerinin gelecekte olması beklenen gelişmeleri için aşağıdaki tespitlerde bulunmuştur (Stock ve Seliger, 2016: 539):

- Üretim ekipmanları, otomatik tezgah ve robotlar tarafından kullanılacaktır. Ekipmanlar değişimlere kolay uyum sağlayacaktır. Robotlar ve operatörler uyum içinde birlikte çalışabilecektir.
- Üretimin genelinde otomasyona geçilecektir. Operatör sayısı azalır; kalan çalışanların yetenekleri geliştirilecektir. Çalışanlar otonom karar sürecini yönlendirebilecektir.
- Karar verme işlemleri modül bazlı gerçekleşecektir. Merkezi durumdan lokal birimlere aktarılacaktır. Merkez, otonom karar verirken yerel birimlerden gelen bilgileri kullanacaktır. Kararlar, yapay zeka gömülü ekipmanlar ve/veya çalışanlar tarafından alınacaktır.
- 3D baskı teknolojilerinin gelişmesiyle; eklemeli üretim yönteminin kullanımı her alanda artacaktır. Müşterinin talebi doğrultusunda düşük maliyetli olarak tek bir ürün üretilebilecektir.

Şekil 3: Sürdürülebilir Endüstri 4.0 Sistemi



Kaynak: Kamble, Gunasekaran ve Gawankar, 2018: 419.

Gelecekteki üretim sistemleri, değişen koşullara yüksek adaptasyon sağlayabilen, kaynak verimliliğini, insan ve teknolojinin akıllı entegrasyonunu

artırabilen, akıllı, sürekli öğrenen ve geliştiren yapıya dönüşecektir. Sensör sistemlerinde ortaya çıkan teknolojik gelişmeler, otomasyon ve üretimde kullanılan bilgi ve iletişim teknolojileri bu gelişmede önemli rol oynamaktadır. Bu ilerleme literatürde dördüncü sanayi devrimi (Endüstri 4.0) olarak adlandırılmaktadır. Temel teknolojiler; esnek otomasyon, kablosuz sensör sistemleri, CPS, yapay zekâ, büyük veri ve IoT olarak sıralanabilmektedir. Siber fiziksel üretim sistemleri (CPS), bilgisayar öğelerinin, fiziksel öğelerin, yazılımların ve insanların birleşiminden meydana gelmektedir (Tvenge ve Martinsen, 2018: 261). Günümüzde gelişmiş üretim sistemleri, kablolu ve kablosuz ağ bağlantılarının sağladığı avantajlarla karmaşık akıllı fabrikalarda, birlikte çalışabilen ve çalışanlarla iletişim halindeki siber fiziksel sistemler altyapısı ile tasarlanmaktadır. Yeni üretim sistemlerinde veri bilimi ve tahminsel analiz çalışmalarına önem verilip; kolay şekilde özelleştirilmiş ürün üretebilme, verimlilik ve maliyet avantajları elde edilmektedir (Deloitte, 2015: 6). Bu sistemler gerçek zamanlı karar verme ve süreçlerden elde edilen verileri bilgiye dönüştürme özellikleri sayesinde sürekli iyileştirme özelliklerini geliştirebilmektedir (Giannetti ve Ransing, 2016: 70).

Şekil 4: Dijital Pusula




Kaynak: Baur ve Wee, 2015: 3; Sung, 2018: 41.

Endüstri 4.0 dönüşümünde dinamik işletme ve mühendislik süreçleri, üretimde anlık değişiklikleri mümkün kılmakta ve tedarikçi kaynaklı olası başarısızlıklara yüksek esneklikle yanıt verme yeteneği sunmaktadır. Optimize edilmiş karar alma süreçlerini kolaylaştırarak üretim sürecinde baştan sona şeffaflığı sağlamaktadır. Endüstri 4.0, değer oluşturma ve yenilikçi iş modelleri oluşturmayı desteklemektedir. Endüstri 4.0 konseptinin değer önerisi; ağ sınırlarında olan fiziksel varlıkların tamamının dijitalleşmesi ve değer zincirlerinin tamamının dijital ekosistemlere olan entegrasyonunu ifade etmektedir. Bu siber teknolojiler, “akıllı” ve çok yönlü bir siber-fiziksel üretim ortamının oluşturulmasına öncülük etmektedir (Pereira, Barreto ve Amaral, 2017: 1254–55). Akıllı fabrikanın veya akıllı işletme ortamının oluşturulabilmesi için değer zincirinin tamamında akıllı makinelerin, akıllı ürünlerin, akıllı bileşenlerin, bireylerin ve bilgi iletişim teknolojilerinden oluşan ağı oluşturulması gerekmektedir. Endüstri 4.0 dönüşümü, diğer katma değerlerin yanında; işletmelere yalınlaşma konusunda çok büyük ayrıcalıklar sağlamaktadır. Yalın, Toyota

üretim sistemine dayanan, daha azıyla daha fazlasının yapılmasını sağlayan ve sürekli iyileştirmelerle organizasyonun gelişmesine yönelik katkılar sunan girişimler bütünü olarak tanımlanmaktadır. Ürün veya hizmetlerde değer katmayan herhangi bir eylem olarak algılanan israfın ortadan kaldırılmasını, gereksiz sapma ve çalışma sürecindeki adımların azaltılmasını amaçlamaktadır. Yeniden işlem gerektiren hatalar, gereksiz işlem adımları, malzemelerin veya insanların hareketi, bekleme süresi, fazla stok ve aşırı üretim gibi israfların giderilmesine odaklanmaktadır (Mrugalska ve Wyrwicka, 2017: 466). Endüstri 4.0 sahip olduğu teknolojiler sayesinde işletmelerin süreçlerinde yalınlaşmayı kolaylaştırmakta ve yalınlaşma sürecinde gerçek zamanlı izleme, çözüm üretme ve kontrol alanlarında fırsatlar sunmaktadır.

Endüstri 4.0 konusunda 2012 yılından itibaren yapılan araştırmalar çeşitli alanlarda artan şekilde devam etmektedir. Endüstri 4.0 konusunda yıllara göre yapılan yayın sayılarının eğilimi Şekil 5’ te bulunan grafikte yer almaktadır (Chiarello, Trivelli, Bonaccorsi ve Fantoni, 2018: 244).

Şekil 5: Endüstri 4.0 Alanındaki Yayın Eğilimi (Başlık, Özet, Anahtar Kelime)



Kaynak: Chiarello ve diğerleri, 2018: 245. Scopus. Tarih: 06.06.2017

Trstenjak and Cosic çalışmasında Endüstri 4.0 ‘da "ürün planlayıcısı" olarak sunulan süreç planlayıcısının rolünü değiştirmektedir. Ürün planlamacısı aynı zamanda tedarik zincirinin diğer bölümlerine bağlı olan ve süreç planını, işlem sırasını ve zamanlamayı otomatik olarak oluşturmak için gelişmiş optimizasyon algoritmaları kullanan yazılım olarak tanımlanmaktadır. Endüstri 4.0 entegrasyonunun hayata geçmesiyle birlikte çalışma ortamları CPS’lerle otomatikleştirilmekte ve veriler içeren IoT, bulut bilişimi kullanarak çevrimiçi olarak işlenmektedir. Yakın zamanda, sürekli

iyileştirme prensibine önem veren ve ar-ge için yüksek standartları olan uluslararası büyük şirketler, Endüstri 4.0 entegrasyonu sayesinde kendilerini pazarda daha da rekabetçi hale getirecektir. Kobilerin geri kalıp; piyasa değişimlerine ve taleplerine karşılayamayacak duruma gelebilmeleri ise olasıdır. Bu nedenle, kobilerin gecikmeden Endüstri 4.0 entegrasyonu için kendi stratejilerini geliştirmeleri oldukça önemlidir. Endüstri 4.0 fabrikadaki yeni bütünleştirici, tüm üretim kaynaklarının sürekli kalite ve süreç kontrolü ile veri ve bilgi alışverişine bağlı olmasına imkan sağlayan sanayi devrimidir. Ayrıca Endüstri 4.0, şirketlerin iş ağı, müşteriler ve tedarikçilerle yüksek teknoloji iletişimi üzerinde etkiye sahiptir (Trstenjak ve Cosic, 2017: 1744–45).

Dördüncü sanayi devrimi ile beraber işletmelerin yeni dönemde süreç planlama prosedürlerinde önemli değişikliklere gitmeleri beklenmektedir. Süreç planlama dönüşüm projesi; pratik uygulama ve gerekli eylemleri yürütmek için uygun yazılımın oluşturulması sayesinde kolayca yönetilebilecektir. Yeni yaklaşımı uygulamadan önce, hazırlık faktörü oldukça iyi hesaplanmalıdır. Mevcut durumda Endüstri 4.0 dönüşümüne hazır olmayan şirketler yatırım maliyeti yüksek radikal değişiklikler talep etmektedirler. Tam sistem otomasyonu ve ileri teknolojilerin kullanımı, nesnelerin interneti ve büyük veri analizi, süreçlerde insan faktörünü en aza indirmektedir. Bunun yanında günümüzde bilinen meslekleri ve iş tanımlarını da değiştirmektedir. Süreç planlamasının otonomlaştırılarak tedarik zincirinin ve üretim sürecinin diğer bölümleriyle ilişkilendirilmesi gerekmektedir (Trstenjak ve Cosic, 2017: 1748–49).

1.1. ENDÜSTRİ 4.0 VE TEKNOLOJİLERİ

Endüstri 4.0' ı meydana getiren donanım, yazılım ve teknikler incelendiğinde bu bileşenlerin veya teknolojilerin bir kısmının uzun zamandır kullanıldığı; bir kısmının ise yakın zamanda geliştirildiği görülmektedir. Endüstri 4.0 alanında yapılan çalışmalarda araştırmacıların bir kısmı Endüstri 4.0' ı meydana getiren söz konusu teknik, yazılım ve donanımlar için teknoloji ifadesini kullanırken; diğer kısmı da bileşen ifadesini kullanmaktadır. İki ifadede de vurgulanmak istenen anlam aynı olmakla birlikte; bu çalışmada iki ifadenin de kullanımı tercih edilmektedir.

Endüstri 4.0' ı oluşturan yapılardan biri olan akıllı ürün, sistemin bütünü ile gerçek zamanlı haberleşebilmektedir. Akıllı ürün, süreç verilerini ve kendi ihtiyaçlarını bünyesindeki kayıt cihazına anlık kaydederek; nihai ürünün tamamlanabilmesi için ihtiyaç duyulan operasyon ve kaynakları gerçek zamanlı olarak ilgili birimlerden talep ederek tüm üretim sürecinin etkin şekilde yönetilmesini kolaylaştırmaktadır (Loskyl, Heck, Schlick ve Schwarz, 2012: 737). Akıllı makina, makinaların siber fiziksel sistem (CPS) yapısına dönüşme sürecinde önemli bir bileşendir (Zamfirescu, Pirvu, Loskyl ve Zuehlke, 2014: 4346). Akıllı makinalar, akıllı ürünler, çeşitli ağlar, saha cihazları ve farklı üretim modülleri ile iletişim kurabilen ve lokal olarak kontrol edilebilen otonom bileşenlerdir. Üretim sistemlerinde makinaların otonom şekilde organize olmaları sayesinde; üretim hatları esnek ve modüler yapıya kavuşmaktadır. Bu şekilde küçük parti büyüklüklerinde olan siparişler de ekonomik olarak üretilebilmektedir. CPS tabanlı üretim hatları esneklikleri sayesinde; yeni üretim birimlerinin kolayca eklenebilmesini ve eskilerinin çıkarılabilmesini sağlamaktadır (Weyer, Schmitt, Ohmer ve Gorecky, 2015: 580).

Günümüzde teknolojik imkanların artması sayesinde üretkenlik becerileri de hızla gelişmektedir. Yeni endüstriyel teknolojilerinin oluşturduğu Endüstri 4.0' ın yükselişi, dokuz temel teknolojinin ilerlemesi ile desteklenmektedir (Gerbert ve diğerleri, 2015: 1). Bu çalışmada, Rüßmann, Gerbert ve arkadaşlarının belirlemiş oldukları Endüstri 4.0' a ait dokuz temel teknolojiye (Rüßmann ve diğerleri, 2015: 56) ek olarak; donanım ve yazılım alanlarında yaşanan gelişmeler sonucunda, karmaşık ve yüksek boyutlu hesaplama kabiliyetleri yanında her sektörde önemi giderek artan yapay zeka teknolojileri de Endüstri 4.0 teknolojileri arasına eklenmiştir (Şekil 6).

Şekil 6: Endüstri 4.0 ve Teknolojileri



Endüstri 4.0, çeşitli akıllı sensörler, kendini yapılandıran robotlar, bulut bilişim, 3D baskı, cihazdan cihaza (D2D) iletişim, büyük veri analizleri ve büyük miktarda veri gönderip alan iletişim kanallarını içermektedir. Siber teknolojilerin entegrasyonu, ürün ve hizmetleri internet bazlı yapıya dönüştürmektedir. Bu sayede süreçlerin ve sistemlerin sektörler ve teknolojiler arasında entegrasyonu kolaylaşmakta ve daha iyi iletişim ve iş birliğine katkıda bulunmaktadır. Nesnelerin interneti (IoT) sayesinde sanayi sektöründe kısaltılmış üretim döngüleri, müşteri ihtiyaçlarının gerçek zamanlı olarak sürece dahil edilmesi, bakımların büyük ölçüde otomatik şekilde yapılması, siparişlerin otomatik olarak doldurulması, ürünlerin doğru sırada sevk edilmesi gibi müşteriler için yeni faydalar sağlanmaktadır (Pereira ve diğerleri, 2017: 1254–55). Endüstri 4.0 aynı zamanda büyük verilerin, IoT ve yapay zekanın (AI) kullanımını da desteklemektedir (Tjahjono, Esplugues, Ares ve Pelaez, 2017: 1175–76). Üretim işletmelerinde Endüstri 4.0 adaptasyonu için, endüstriyel IoT, büyük veri analitiği, bulut bilişim, simulasyon, eklemeli üretim, robotik, siber güvenlik, artırılmış gerçeklik ve makine öğrenmesi gibi birçok teknoloji bulunmaktadır (Moktadir ve diğerleri, 2018: 730-32). Endüstri 4.0 veya akıllı üretim, dijital dönüşümü gerçekleştirmek için nesnelerin interneti, yapay zeka, bulut bilişim, makine öğrenimi ve veri analitiği gibi teknolojileri kullanmaktadır. Zamanla değişen çevresel şartlara göre sistemin kendi kendini düzeltebilmesi amacıyla makina ve

sistemler enterkonnekte biçimde birbirine bağlanmaktadır (Fatorachian ve Kazemi, 2020: 71).

Endüstri 4.0 dönüşümü için ilgili sistemi oluşturan ürün, nesne, sensör ve sistem hareketini sağlayan nesneler gibi bileşenlerin gerçek zamanlı ve kesintisiz veri paylaşımında bulunması gerekmektedir (Lasi, Fettke, Kemper, Feld ve Hoffmann, 2014: 240). Endüstri 4.0' ın sahip olduğu bu yetenek, siber fiziksel sistemler (Cyber-Physical Systems-CPS) ve nesnelerin interneti (Internet of Things-IoT) sayesinde elde edilmektedir. Siber fiziksel sistemler hesaplama teknolojilerinin fiziksel süreçlerle olan entegrasyonu olarak tanımlanıp; gömülü sistemler ile fiziksel ortamdan gerçek zamanlı veri aktarımının sağlandığı mimariye dayanmaktadır (Pisching ve diğerleri, 2015: 65-67). Endüstri 4.0 bünyesindeki CPS' lerin büyük hacimlerdeki verileri üretmeleri ve bu verilerin sağlıklı şekilde işlenmesi neticesinde Endüstri 4.0 dönüşümünün üretim endüstrisinde çığır açması beklenmektedir (Giannetti ve Ransing, 2016: 70). Siber-fiziksel sistemler, birbiriyle etkileşim kurabilmektedir. Hata ve arıza tahmini, kendini düzeltme ve yaşanabilecek değişkenliğe uyum amacıyla veri analizleri gerçekleştirebilmektedir (Gerbert ve diğerleri, 2015: 1). CPS' ler bağımsız veri paylaşımı yapabilen, farklı sistemleri denetleyebilen ve süreçleri tetikleyebilen yapılardan oluşmaktadır. Günümüzde fabrika otomasyonu konusundaki genel beklenti; dinamik şartlarda yeniden mühendislik süreçlerini kolaylaştıran, hata ve arızalara esnek müdahaleleri mümkün kılan akıllı fabrika ağlarının entegrasyonu olarak belirtilebilmektedir (Weyer, Schmitt, Ohmer ve Gorecky, 2015: 580).

Endüstri 4.0 dönüşümünün altyapısında bulunan siber fiziksel sistemler (CPS) sayesinde işletmeler arıza gibi olaylara daha hızlı adapte olabilmektedir. Bu sistemler, enerji tasarrufu için akıllı şebekelerde kullanılarak kaynak kullanımının daha verimli olmasını sağlamaktadır. Endüstri 4.0' da ticari büyümenin fırsat ve faydaları bulunmaktadır. İşletmeler arasındaki işbirlikçi ağlar yatay entegrasyon konsepti sayesinde; kaynakları birleştirmekte, riskleri bölmekte, pazardaki değişikliklere hızlı şekilde adapte olabilmekte ve yeni fırsatları yakalayabilmektedir. Endüstri 4.0 teknolojileri, işletmelerin esnek üretim süreçlerine sahip olmalarını, büyük hacimli verileri gerçek zamanlı analiz etmelerini, stratejik ve operasyonel karar yeteneklerini geliştirmelerini sağlamaktadır. Yeni endüstriyel dönüşüm; bilgi iletişimi teknolojilerinin endüstriyel ortamlarda kullanılması ve sensör-donanım maliyetlerinin

azalarak fiziksel nesnelerle olan entegrasyonun yaygınlaşması ile mümkün olmaktadır. Bu teknolojilerdeki gelişmeler gömülü ve bağlı sistemlerin geliştirilmesini sağlamaktadır. Söz konusu sistemler, ekipman, konveyör ve ürünleri, büyük miktarda veri toplayan geri bildirimler döngüsünü (büyük veriler), gerçek zamanlı izleme ve kontrolü, sanal modelleri ve akıllı fabrika ortamını sağlamaktadır. Bu nedenle, üretim sistemleri için 1980' lerden itibaren bulut bilişim ve devreye alma için simulasyon gibi farklı teknolojiler ortaya çıkmıştır. Dalenogare ve arkadaşlarının Endüstri 4.0 teknolojilerine ait açıklamaları Tablo 1' de yer almaktadır (Dalenogare, Benitez, Ayala ve Frank, 2018: 384-85).


Tablo 1: Endüstri 4.0 Teknolojileri

Bilgisayar destekli tasarım-imalat	Bilgisayarlı sistemlere dayalı ürün ve imalat için proje ve iş planlarının geliştirilmesi
Entegre mühendislik sistemleri	Ürün geliştirme ve üretimde bilgi alışverişi için IT destek sistem entegrasyonu
Sensörlü dijital otomasyon	Veri toplama yoluyla izleme için yerleşik sensör teknolojisine sahip otomasyon sistemlerinin kullanılması
Esnek üretim hatları	Yeniden yapılandırılabilir üretim sistemlerini teşvik etmek ve ürünün endüstriyel ortamla düşük maliyetli bir şekilde entegrasyonunu ve yeniden düzenlenmesini sağlamak için üretim işlemlerinde sensör teknolojili dijital otomasyonun (RFID) kullanılması
Üretim işletim sistemleri (MES) ve denetleyici kontrol ve veri toplama (SCADA)	SCADA ve uzaktan kontrol sistemlerinin kullanılması. Üretim sahasının gerçek zamanlı veriler toplanarak izlenmesi. Kısıtları dikkate alarak kısa vadeli siparişlerde uzun vadeli programların üretim işletim sistemi ile dönüştürülmesi
Simulasyonlar ve sanal model analizi	Sentetik modellerin, özelliklerini taklit ettiği mühendislik projeleri ve model tabanlı sistem tasarımlarının devreye alınması için sonlu elemanlar, hesaplamalı akışkanlar dinamiği vb. tekniklerin kullanımı
Büyük veri toplama ve analiz	Tahmini analitik, veri madenciliği, istatistiksel analiz ve diğer uygulamalar için büyük verilerin analizi
Dijital ürün-servis sistemleri	IoT platformlarına, yerleşik sensörlere, işlemcilere ve yeni yetenekler sağlayan yazılıma dayalı ürünlere dijital hizmetlerin dahil edilmesi
Katmanlı üretim, hızlı prototipleme veya 3B izlenim	Esnek 3B modelleri fiziksel ürünlere dönüştüren esnek üretim sistemleri (FMS) için çok yönlü üretim makineleri
Ürünler için bulut hizmetleri	Bulut bilişimin ürünlere uygulanması, kapasitelerinin ve ilgili hizmetlerin genişletilmesi

Kaynak: Dalenogare, Benitez, Ayala ve Frank, 2018: 385.

Gobbo ve arkadaşlarının anahtar kelimelerle yaptıkları araştırmada Endüstri 4.0 ile ilişkili başlıklar; akıllı tasarım, büyük veri analizi, genetik algoritma, dijital fabrika, akıllı üretim, yalın üretim, öğrenen fabrika, önleyici bakım, sanal gerçeklik, dijital ikiz, siber fiziksel sistemler, nesnelerin interneti, bulut bilişim, artırılmış gerçeklik, insan faktörü, sürdürülebilirlik, bakım, otomasyon, iş modelleri, üretim, inovasyon, optimizasyon, çizelgeleme ve lojistik olarak sıralanmaktadır (Gobbo, Busso, Gobbo ve Carreño, 2018: 378).

Şekil 7: Endüstri 4.0 Teknolojilerinin İlişkileri




Kaynak: Chiarello, Trivelli, Bonaccorsi ve Fantoni, 2018: 255.

Endüstri 4.0 dönüşümünün teknoloji ile ilgili bileşenleri yeni keşfedilmemiş olmakla beraber mevcut durumda çeşitli alanlarda kullanılmaktadır. Endüstri 4.0, mevcut teknolojide yer alan 30'dan fazla farklı alanın toplamı ile entegre edilmektedir. Birçok paydaş bu teknolojileri hâlihazırda süreçlerinde kullanmadıklarından dolayı kendilerini Endüstri 4.0 konusunda yetersiz görmektedir. Chiarello ve arkadaşları çalışmalarında işletmelerin Endüstri 4.0 konusunda bu ve buna benzer eksikliklerini gidermek üzere; tanımları ve bağlantıları olan zenginleştirilmiş bir Endüstri 4.0 içeriğine sahip teknolojiler sözlüğünün geliştirilmesine odaklanmıştır (Chiarello ve diğerleri, 2018: 244). Endüstri 4.0 teknolojileri; IoT, bulut bilişim, büyük veri, simulasyon, otonom robot, eklemeli üretim, siber güvenlik (cyber security), artırılmış gerçeklik, yatay ve dikey sistem entegrasyonu ve yapay zekâ olarak sıralanmaktadır.

1.1.1. Nesnelerin İnterneti (Internet of Things)

Günümüzde üretim tesislerinde makinelerin ve sensörlerin gömülü bir sistem oluşturmak amacıyla birbirleriyle bağlantılı olduğu az sayıda işletme bulunmaktadır. Endüstriyel IoT sayesinde üretim ekipmanları yatay ve dikey şekilde birbirine daha etkin bağlanabilmektedir. Bu şekilde gerçek zamanlı ve etkin veri transferleri mümkün olmaktadır (Rüßmann ve diğerleri, 2015: 58). IoT, makina, ekipman ve ürün gibi birçok fiziksel varlığı internete bağlayan, bu varlıklar tarafından üretilen veri ve bilgilerin diğer varlıklarla paylaşabildiği ağ olarak tanımlanmaktadır (Trappey, Trappey, Hareesh Govindarajan, Chuang ve Sun, 2017: 208). Endüstri 4.0 entegrasyonu sayesinde, IoT, büyük veri ve bulut bilişim gibi teknolojiler kullanılarak; değişen faktör veya şartlarda hedefe ulaşabilme olarak tanımlanan taktik zekaya dayalı üretim yeteneği kazanılmaktadır (Trappey ve diğerleri, 2017: 209).

Şekil 8: IoT Teknolojileri ve Unsurları




Kaynak: Ahuett-Garza ve Kurfess, 2018: 61.

IoT, nesnelerin tanımlanması, dijitalleşmesini ve kolayca kontrolünü sağlamaktadır (Rosemann, 2013: 6). Fiziksel dünyada gerçek görevleri yerine getiren cihazlardan internete gelen bilgi ve veri alışverişidir (Badri, Boudreau-Trudel ve Souissi, 2018: 405). Nesnelerin internet teknolojisi, RFID sistemlerini kullanarak; nesnelerin ve ürünlerin entegrasyon ortamını oluşturmaktadır. Bu ortamla birlikte

nesne ve ürünlerden üretilen verilerin tanımlanması ve analiz edilmesi yeteneği kazanılarak; ürün ve nesnelerin uzaktan kontrolü sağlanmaktadır (Zhong ve diğerleri, 2015: 260). Sağlık alanında hastaların uzaktan takibi, enerji alanında akıllı sayaçlarla gerçek zamanlı enerji tüketimi takibi ve üretim sektöründe öngörülü bakım nesnelerin interneti teknolojisinin sağladığı imkânlardan bazılarıdır (Kees, Oberländer, Röglinger ve Rosemann, 2015: 2). 2020 yılına kadar 26 milyar akıllı nesnenin olacağı beklenmektedir (Rivera ve Van der Muelen, 2013: 26). IoT teknolojisi sayesinde çeşitli sektörlerde üretim, lojistik, çevre, coğrafî ve operasyon gibi alanlara ait yüksek hacimde veriler anlık toplanabilmektedir (Addo-Tenkorang ve Helo, 2016: 535). Nesnelerin interneti, bu özelliği sayesinde ürün, hizmet, güvenlik ve müşteri deneyimi gibi birçok alanda yapılabilecek iyileştirmelere olanak sağlamaktadır. RFID gibi sensör ve algılama sistemlerinin makina, ekipman ve teçhizat gibi değer zincirindeki bileşenlere entegre edilmesi sayesinde bu bileşenlerle gerçek zamanlı iletişim kurulabilmektedir. Bu sayede bileşenler arasında veri transferi ve çalışma uyumu sağlanarak; müşteri perspektifiyle ek katma değerler oluşturulabilmektedir (Kees, Oberländer, Röglinger ve Rosemann, 2015: 1; Addo-Tenkorang ve Helo, 2016: 536; Zhong ve diğerleri, 2015: 260).

Şekil 9: Birbirine Bağlanacak Nesnelerin Tahmini Sayıları



Kaynak: Cisco, Farooq, Waseem, Mazhar, Khairi ve Kamal, 2015: 1.

IoT, verimliliği, etkinliği ve güvenilirliği artırmak için otonom (akıllı) makineleri, gelişmiş öngörülü analiz yeteneğini ve makine-insan işbirliğini bir araya getiren yeni bir endüstriyel ekosistem olarak tanımlanmaktadır (Wong ve Kim, 2017:

17). IoT sayesinde gerçek zamanlı algılama-harekete geçme ve verinin-bilginin hızlı aktarım yetenekleri kazanılmaktadır. Bu sayede süreçlerin uzaktan kontrolü ve paydaşlar arasında etkin işbirliği sağlanmaktadır (C. Yang ve diğerleri, 2017: 1717). Milyonlarca gömülü sensöre ve iletişim cihazına bağlı olan IoT tabanlı CPS' ler, artan veri transferi ile ilgili risklere ve sistematik ihlallere ait risklere neden olmaktadır (Kamble ve diğerleri, 2018: 417-18). IoT, sürekli iyileştirme için üretim faaliyetlerine yardımcı olacak dijital dünyadaki verilerin tek çatı altında birleştirilmesine yardımcı olmaktadır (Minerva, Biru ve Rotondi, 2015: 1). IoT tabanlı yazılım, makinelerin akıllı planlama ve kontrolünde kullanılmaktadır (Moktadir ve diğerleri, 2018: 732).

1.1.2. Bulut Bilişim (Cloud Computing)

Endüstri 4.0 entegrasyonu sonrasında nesneler, makineler, teçhizatlar, ürünler ve birimler arasında çapraz veri paylaşım miktarında yüksek seviyede artışlar meydana gelmektedir. Bulut teknolojilerinin sahip olduğu yüksek performans avantajı sayesinde; sistem sınırlarında yoğun şekilde gerçekleşen veri paylaşımları elverişli biçimde gerçekleştirilmektedir. Bulut teknolojisiyle üretim bileşenlerine ait veriler bulut üzerinden aktarılarak üretim sistemlerinin etkinliği artırılırken; süreçlerin izlenmesi ve denetlenmesi işlemleri de bulut tabanlı gerçekleştirilmektedir (Rüßmann ve diğerleri, 2015: 58). Endüstri 4.0 ve bulut tabanlı üretim, üretim-hizmet-veri-insan kavramlarını internet ağı üzerinden birbirine bağlayarak akıllı ve ağ tabanlı sistemin oluşturulmasına katkıda bulunmaktadır (Yue, Cai, Yan, Zou ve Zhou, 2015: 1262). Endüstri 4.0' da yaygın olarak kullanılan bulut teknolojileri, şirket sınırlarını aşır; sağladığı artan veri paylaşımı, artan sistem performansı (çeviklik ve esneklik gibi) ve gerçek zamanlılık yeteneği sayesinde maliyetleri düşürmede oldukça etkin bir rol oynamaktadır (Kamble ve diğerleri, 2018: 417). Günümüzde işletmeler büyük ölçüde gerçek zamanlı verilerin analizine ve veri depolama olanaklarına ihtiyaç duymaktadır. Endüstri 4.0' da bulut bilişim, endüstriyel üretim amaçlı olarak çeşitli kaynaklardan toplanan bu gerçek zamanlı büyük verilerin depolanmasına yardımcı olmaktadır (Gao ve Zhao, 2011: 175). Bulut bilişim üretim sürecini kolaylaştırmak için iletişim araçlarının bir şirketten diğerine bağlanmasına ve verilerin paylaşılmasına imkan tanımaktadır. Dijital üretim kavramı, bir ülkeden diğerine şirketler arasındaki bulut

bilişim tabanlı bağlantı yoluyla elde edilebilmektedir (Vaidya, Ambad ve Bhosle, 2018: 236). Bulut sistemine kaydedilen verilere, çeşitli siber güvenlik alyapıları altında, internete bağlanılabilen ortamlarda izin verilen kişi, kurum ve sistemler tarafından gerçek zamanlı ulaşılabilir. Bu özelliğiyle bulut bilişim Endüstri 4.0 dönüşümü için oldukça önemi bir teknolojidir.

1.1.3. Büyük Veri (Big Data)

Büyük veri kümeleri, insanların sezgisel ve analitik kapasiteleri yanında; veritabanı ve bilgi yönetimi için kullanılan geleneksel bilgisayar araçlarının hesaplama kabiliyetlerini aşacak kadar büyük yapılardır (Badri ve diğerleri, 2018: 405). Büyük veri analitiği ve kullanılan teknolojiler, farklı kaynaklardan elde edilen gerçek zamanlı verilerin toplanmasını ve detaylı şekilde analizini gerçekleştirerek; gerçek zamanlı karar vermeyi desteklemektedir (Diez-Olivan ve diğerleri, 2019: 92). Süreçlerin detaylı analizi, kalite optimizasyonu, enerji verimliliği, makina-teçhizat verimliliği ve servis hizmetlerinin iyileştirilmesi gibi birçok alanda oldukça önemlidir. Endüstri 4.0 entegrasyonu sayesinde gerçek zamanlı değerlendirme için çeşitli kaynaklardan toplanan veriler kapsamlı olarak analiz edilmektedir. Üretim sistemleri ve müşteri yönetim sistemlerine ait süreçler bu analizler neticesinde standartlaştırılmaktadır (Rüßmann ve diğerleri, 2015: 56-57). Elektronik cihazların yaygınlaşması sonucunda dünya genelinde toplanan veri miktarlarının giderek artması; büyük veri analitiğinin önemini hissettirmektedir. (Zhong ve diğerleri, 2015: 260). Büyük veri, geleneksel teknikler kullanılarak sonuca ulaşmanın zor olduğu karmaşık ve yüksek hacimli veri kümelerini belirtmektedir (Zhong ve diğerleri, 2015: 262).

Büyük veri teknolojisinden önce ve günümüzde; süreçlerde, veri madenciliği teknikleri yaygın olarak kullanılmaktadır. Veri madenciliği yeteneklerinin geliştirilmesi amacıyla, yapay sinir ağları, karar ağaçları, genetik algoritmalar ve çeşitli istatistiksel teknikler kullanılabilmektedir (Shahbaz, Masood, Shaheen ve Khan, 2010: 999). Büyük veri analizi işletmelere kurumsallaşma yolunda çok önemli avantajlar sağlamaktadır. Bu teknoloji, katma değer için farklı kaynaklarda üretilen yığın haldeki verilerin toplanmasını ve analizini sağlayan güçlü bir araçtır. Büyük hacimdeki bu veriler genellikle, sensörler, akıllı telefonlar ve bilgisayar sistemleri gibi

üretim, lojistik ve tedarik zinciri ağlarında bulunan bileşenler kullanılarak toplanmaktadır (Addo-Tenkorang ve Helo, 2016: 528). Büyük veri teknolojisinin temel amacı, gerçek zamanlı analizine ihtiyaç duyulan yığın haldeki verilerden anlamlı bilgilerin üretilmesi olarak açıklanabilmektedir (Chen, Mao ve Liu, 2014: 171). Büyük veri teknolojisi sayesinde, katma değerli uygulamaların keşfi ve stratejik kararların alınması açısından önemli fırsatlar sunmaktadır. Anlamlandırılmamış yığın halde bulunan verilerde gizli olan bilgilerin ortaya çıkarılması hedeflenmektedir. Sağladığı bu avantajlarla dünya genelinde birçok ülkenin kamu kurum ve kuruluşları, ürettikleri veri yığınlarının anlamlandırılması hedefiyle büyük veri teknolojisine ilgi duymaya başlamıştır (Addo-Tenkorang ve Helo, 2016: 529). Büyük veri, veri ve bilgilerin dinamik şekilde sürekli değiştiği ortamlarda; bu verilerin gerçek zamanlı olarak kısa sürede analiz edilebileceği çevrimdışı çalışan yöntemdir (Addo-Tenkorang ve Helo, 2016: 533). Üretim ve hizmet sağlayan sistemler operasyonları sırasında kullandıkları IoT teknolojileri, RFID, kablosuz sensörler, mobil cihaz, kamera ve mikrofon gibi teknolojiler sayesinde gerçek zamanlı ve sürekli artan veri yığınlarını oluşturmaktadır. (Dimakopoulou, Pramatarı ve Tsekrekos, 2014: 191; Zhong, Newman, Huang ve Lan, 2016: 572).

Büyük veri yığınlarının özellikleri değer, hacim, hız, çeşitlilik ve doğrulama olarak dört gupta incelenmektedir (G. Q. Huang, Zhong ve Tsui, 2015: 172). Hız özelliği, verilerin toplanması, aktarım güvenilirliği, depolama kapasitesinin etkinliği ve katma değerli bilgilerin ortaya çıkarılması amacıyla yapılan madencilik hızının yanı sıra; oluşturulan algoritmalar ve karar modellerinin başarısına bağlıdır. Büyük veri yığınlarında kaynak çeşitliliği ve farklı formatlar nedeniyle veriler çoğu zaman standart özellikte değildir. Büyük veri kümelerinde katma değeri bulunmayan verilerle bir arada bulunan, değer katan verilerin ayırt edilebilmesi amacıyla bu veriler üzerinde; belirli otoriteler ve güvenlik kontrolleri eşliğinde doğrulama işlemi gerçekleştirilmektedir. Büyük verilerde uyum ve kaliteyi otomatik şekilde doğrulayan araçların varlığı oldukça önemlidir. Büyük veride makro ve mikro ölçekte katma değerli sonuçlar elde etme, sektör değerlendirmeleri, süreç analizleri ve menfaatler gibi çok yönlü değerlendirme esasına dayandığından; analiz işlemi zorlu bir süreçtir (Zhong ve diğerleri, 2016: 573). Lim ve arkadaşları çalışmasında veriye dayalı değer oluşturmayı simgeleyen dokuz temel faktör belirlemiştir. Bu faktörler: veri kaynağı,

veri toplama, veri, veri analizi, veri kaynağı bilgisi, bilgi dağıtımı, bilgi kullanıcısı, bilgi kullanımındaki değer ve sağlayıcı ağıdır. Çalışmada, altı projeden oluşan araştırma ile 149 vaka analizi birleştirilerek; veriye dayalı değer oluşturmaya etki eden faktörler geliştirilmiştir (Lim ve diğerleri, 2018: 121–24).

1.1.4. Simulasyon (Simulation)

Simülasyon, süreçleri, makineleri, teçhizatları, ekipmanları, ürünleri ve insanı içeren sanal bir modelde fiziksel dünyayı yansıtmak için gerçek zamanlı verilerden yararlanmaktadır. Sanal ortamda modeller oluşturulup yine sanal ortamda gerçek zamanlı verilerle modeller çalıştırılarak sonuçlar analiz edilmektedir. Süreçlere ait girdiler; ihtiyaçlar doğrultusunda ve esnek şekilde güncellenip değişik modeller üretilmektedir. Simulasyon, optimal değerlerin bulunmasının işlem yükü ve model kurma bağlamında zor olduğu karmaşık problemlerin çözümünde etkin bir yöntemdir. Optimal değerlere yakın çözümler üretilmesinde oldukça etkilidir.

Endüstri 4.0 dönüşümüyle birlikte simulasyon teknolojisi süreç ve operasyonlarda yoğun şekilde kullanılmaktadır. Simulasyon teknolojisi sayesinde üretimdeki fiziksel ortam sanal ortama yansıtılmaktadır. Makina-teçhizat ayarları, kurulumlar, makina-teçhizat yerleşimleri, kapasite ayarları gibi birçok parametre sanal ortamda kolaylıkla modellenilebilir; test edilebilmektedir. Alınan sonuçlara göre ayarlamalar optimize edilebilmektedir (Rüßmann ve diğerleri, 2015: 57). Simulasyon sayesinde gerçek hayattaki fiziksel değişimden önce operatörler tarafından sanal ortamda bir sonraki ürün için gerekli makine ayarlarının yapılması; ayarların optimize edilerek makine kurulum sürelerinin düşürülmesi ve kalitenin artırılması sağlanmaktadır (Bahrin, Othman, Azli ve Talib, 2016: 139). Simulasyon, gerçek dünya süreçlerine ait işlemlerin, makinelerin, insanların ve ürünlerin sanal ortamda taklit edilmesidir. Tasarım sürecini optimize etmek için teknoloji simulasyonu, sistem güvenliği için güvenlik mühendisliği ve operasyonel sistemi görselleştirmek için bilimsel modelleme gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. İki boyut ve üç boyut simulasyonlar, işlem çevrim süresi, ergonomik tasarım, enerji tüketimi ve verimlilik simulasyonu için yaygın olarak kullanılmaktadır. Endüstri 4.0 yolculuğunda

simulasyonun kullanımı, üretim sürecini, atık üretimini ve üretim başarısızlık oranını azaltmaya yardımcı olmaktadır (Moktadir ve diğerleri, 2018: 732).

1.1.5. Otonom Robotlar (Autonomous Robots)

Üretim süreçlerinde gerçekleştirilecek Endüstri 4.0 dönüşümünde fiziksel manada en aktif kullanılacak teknoloji robot teknolojisi. Robotlardan alınan hizmetlerin esneklik seviyelerinin artırılma isteği nedeniyle bu teknoloji donanım ve yazılımsal alanlarda sürekli geliştirilmektedir. Robot teknolojisinin otonom ve işbirliği yetenekleri de sürekli geliştirilmektedir. Robotların kendi aralarında iletişim ve etkileşim halinde olmaları yanında; insanlarla birlikte güvenli şekilde çalışmaları beklenmektedir. Robot teknolojilerinin yaygın biçimde kullanılmaları sonucunda üretim maliyetleri azalırken; yetenekler gelişmektedir (Rüßmann ve diğerleri, 2015: 57). Süreçlerde otonom şekilde karar verme ve operasyon işlemleri; farklı birimler arasındaki işbirliği sayesinde, yüksek esnekliği sağlamaktadır (S. Wang, Wan, Zhang, Li ve Zhang, 2016: 158).

Modern robotlar otonomluk, esneklik ve iş birliği sunan sistemler olarak tanımlanmaktadır. Robotların yakın zamanda birbirleriyle etkileşime girmeye başlayacakları, insanlarla güvenli çalışacakları ve hatta insanlardan çeşitli yetenekleri öğrenecekleri tahmin edilmektedir. Bu robotlar akıllı fabrikalardaki operasyonların çoğunu gerçekleştirip maliyet avantajı sunacaktır (Kamble, Gunasekaran ve Gawankar, 2018: 418). Otonom robot, Endüstri 4.0 yolculuğu için kilit teknolojiler arasında yer almaktadır. Otonom robot, modüler çalışabilen, kendi kararını kendisi verebilen, hassas operasyonları başarılı şekilde gerçekleştirebilen, insan gücünün yetersiz olduğu alanlarda çalışabilen ve daha birçok avantaj sunabilen önemli bir Endüstri 4.0 teknolojisi (Moktadir ve diğerleri, 2018: 732).

1.1.6. Eklemeli Üretim (Additive Manufacturing)

Eklemeli üretim teknolojisi, geleneksel üretim yöntemlerinden farklı olarak üretim süreçlerini yönlendirmektedir. Bu teknoloji kullanılarak üretim prosesinin zor olduğu çeşitli parçaların üretiminin yanında; organik ürün üretme çalışmaları da

devam etmektedir. Endüstri 4.0 dönüşümü sayesinde süreçler, 3D yazıcı gibi eklemeli üretim teknolojileri ile adaptif çalışabilmektedir. Eklemeli üretim teknolojisi sayesinde basit veya kompleks parçalar küçük partilerde ekonomik şekilde üretilmektedir (Rüßmann ve diğerleri, 2015: 58-59). Eklemeli üretim teknikleri, organizasyonların özelleştirilmiş, karmaşık, küçük ve hafif tasarım ürün serilerini üretebilme avantajı sağladığından bu teknikler Endüstri 4.0 için oldukça önemlidir (Stock ve Seliger, 2016: 539). Eklemeli üretim teknolojileri, yüksek verim, modüler çalışma ve taşıma giderlerini azaltma özellikleri sayesinde ürün stok seviyelerini azaltabilmektedir (Strange ve Zucchella, 2017: 178; Kamble, Gunasekaran ve Gawankar, 2018: 418).

Eklemeli üretim, imalat firmalarına tasarım optimizasyonu ile az miktarda özelleştirilmiş ürün üretme konusunda yardımcı olmaktadır. Nakliye mesafelerinin ve stokların azaltılmasına da yardımcı olabilmektedir. Müşteri talepleri gün geçtikçe değişmektedir ve eklemeli üretim, ürünlerin tasarımını sürekli değiştirerek müşterilerin talebini karşılamaya yardımcı olmaktadır. Günümüzde, birçok üretim işletmesi müşteri talebini çok hızlı bir şekilde yerine getirmek için eklemeli üretimi kullanmaya başlamıştır (Moktadir ve diğerleri, 2018: 732). İşletmeler, eklemeli üretim teknolojilerini kullanarak ürünlerini müşterileri ile birlikte tasarlayabilmekte ve yüksek oranda özelleştirilmiş ürünler elde ederek; algılanan marka değerlerini arttırabilmektedir (Dalenogare ve diğerleri, 2018: 385).

1.1.7. Siber Güvenlik (Cyber Security)

Endüstri 4.0 entegrasyonunda yüksek seviyede iletişimin sağlanması amacıyla, insan, ürün, makina ve teçhizatlar için ihtiyaç duyulan kesintisiz ağ ve internet bağlantıları; siber tehditleri ve güvenlik açısından çeşitli riskleri beraberinde getirmektedir. Kritik sistem, hat ve bileşenlerin siber güvenliği oldukça önemlidir. Siber güvenlik sağlanırken; kullanıcı ve makinelerin sistemlere erişimleri, kimlik güvenlikleri ve haberleşme sistemleri dikkate alınmaktadır (Rüßmann ve diğerleri, 2015: 58). IoT aracılığıyla oluşturulan büyük veriler, işlerin gidişatı ve iyileştirilebilecek alanlar hakkında faydalı bilgiler verebilmektedir. Bununla birlikte, yeni uygulama ve yaklaşımlar genellikle beklenmeyen güvenlik açıkları ve çeşitli tehditlerini beraberinde getirebilmektedir. Saldırılarına karşı müdahale eden prosedürler

yerine önleyici güvenlik politikalarını, yani akıllı güvenliği uygulamak olası güvenlik açığı tehditlerinin etkilerini azaltabilmektedir. Endüstri 4.0 dönüşümü, günümüz üretim endüstrisindeki birçok alanda, özellikle güvenlik alanında yüksek etkileri olan çeşitli teknolojik zorlukları beraberinde getirmektedir. Endüstri 4.0' ın ortaya çıkardığı teknolojik zorlukların üstesinden gelmek için, değer zincirinde yer alan tüm aktörler için çeşitli stratejiler geliştirerek; güvenlik konuları ve uygulamalar başlamadan önce ilgili mimari üzerinde fikir birliğine ulaşmak oldukça önemlidir (Pereira ve diğerleri, 2017: 1259).

Endüstri 4.0 yolculuğunda, sistem optimizasyonu, planlama ve kalite kontrol için fiziksel sistemi dijital verilere bağlamak oldukça önemlidir. Siber-fiziksel sistem, fiziksel sistemi sanal sisteme entegre etmeye yardımcı olmaktadır. İmalat endüstrisinde, siber-fiziksel sisteme dayalı akıllı araç depo yönetimi için kullanılırken; veri madenciliği rotayı tahmin etmeye yardımcı olmaktadır. Endüstri 4.0 dönüşümünün gerektirdiği bu bağlantı ağının her aşamasında siber güvenlik konusu oldukça önemli olup; bu dönüşümde karşılaşılan önemli zorluklardan biridir. Endüstri 4.0 entegrasyonu konusunda, operasyonel amaç için standart iletişim protokolü ile ağı bağlanmak ve bu ağı kullanmak gerekmektedir. Bu nedenle endüstriyel üretim sistemini siber güvenlik tehditlerinden korumak için, makineler ve operatörler için daha güvenli ve güvenilir yapılar gerekmektedir. (Zhong, Xu, Klotz ve Newman, 2017: 618; Moktadir ve diğerleri, 2018: 732).

1.1.8. Artırılmış Gerçeklik (Augmented Reality)

Endüstri 4.0 dönüşümüyle kullanılan artırılmış gerçeklik teknolojisi sayesinde operatörler sanal ortamda makineler ve teçhizatlar ile etkileşimde olup; bu bileşenlerin çeşitli parametre ve ayarlarını değiştirebilmektedir. Bu teknoloji sayesinde özellikle bakım talimatı ve operasyon emirlerini vermek kolaylaşmaktadır. Sağladığı imkânlar neticesinde; süreç ve karar verme etkinliğinin geliştirilmesi bakımından artırılmış gerçeklik uygulamaları birçok işletmenin ilgisini çekmektedir (Rüßmann ve diğerleri, 2015: 59). Artırılmış gerçeklik, endüstriyi iletişim aracıyla desteklemeye yardımcı olan bir hizmet sistemidir. İşletmeyi iyileştirmek ve çoklu kararları analiz etmek için artırılmış gerçeklik, endüstrinin müşterilerden gerçek zamanlı veri toplamasına

yardımcı olmaktadır (Vaidya ve diğerleri, 2018: 237). Artırılmış gerçeklik, arıza giderme işlemleri için oldukça elverişlidir. Çalışanların onarım işlemleri talimatlarını yerine getirmelerine etkin bir şekilde yardımcı olmaktadır (Moktadir ve diğerleri, 2018: 732). Artırılmış operatör (augmented operator), üretim sistemlerinde yüksek insan gücü veya karmaşık işler için operatörlere gerekli teknolojik desteğin verilmesini amaçlamaktadır. Endüstri 4.0 dönüşümünün yapıldığı sistemlerde; operatörler, ağır çalışma şartlarına azami ölçüde uyum sağlayabilen en esnek Endüstri 4.0 bileşeni olarak kabul edilmektedir (Weyer, Schmitt, Ohmer ve Gorecky, 2015: 580).

1.1.9. Yatay ve Dikey Sistem Entegrasyonu (Horizontal and Vertical System Integration)

Endüstri 4.0 dönüşümü sayesinde farklı işletmeler, departmanlar, birimler, fonksiyonlar ve süreçler; çapraz işletmeler, farklı ağlar ve makina bazlı değer zincirleri ile olan etkileşimlerinde uyumluluk seviyelerini artırmaktadır (Rüßmann ve diğerleri, 2015: 57-58). Yatay entegrasyon, değer ağları boyunca işletme içi ve işletmeler arasında gerçekleşen, veri, bilgi, mamul, yarı mamul, enerji ve malzeme gibi paylaşımları içermektedir. Yatay entegrasyon, üretim süreçleri ile planlama süreçlerinin farklı katmanlarında kullanılan birbirinden farklı bilgi teknoloji sistemlerinin entegrasyonudur. Dikey entegrasyon, değer ağları boyunca işletmelerin farklı düzeylerinde çeşitli bilgi teknoloji sistemlerinin uçtan uca çözüm entegrasyonu olarak tanımlanmaktadır (Bartodziej, 2017: 36).

Tüm değer zinciri ve akıllı üretim sisteminde dikey entegrasyon, üretim tesisinin siber fiziksel üretim sistemi aracılığıyla sayısallaştırılması ve akıllı entegrasyonunu ifade etmektedir. Dikey entegrasyon sayesinde talep ve stok seviyesindeki hızlı değişiklikler göz önünde bulundurularak dinamik üretim sistemi oluşturulabilmektedir. Bu sistemde, kaynaklar ve ürünler dikey entegrasyonla birbirine ağ üzerinden bağlanmaktadır. Akıllı sensör teknolojisi tüm sistemi izlemek için kullanılmaktadır. Yatay entegrasyon, tüm değer zinciri ağı boyunca kurum içi ve kurumlararası zeka ve dijitalleşme entegrasyonunu ifade etmektedir (Erol, Jäger, Hold, Ott ve Sihn, 2016: 13–14). Bu sistem entegre şeffaflığı kolaylaştıran ve yüksek düzeyde esneklik sunan optimize edilmiş ağları oluşturmaktadır. Yatay entegrasyon,


tüm süreç zinciri boyunca tedarikten üretim ve satışa kadar dinamik üretim sistemini oluşturmaktadır (Moktadir ve diğerleri, 2018: 732).

1.1.10. Yapay Zekâ (Artificial Intelligence-AI)

Yapay zekâ, zekayı simüle edebilecek makineler geliştirmek için uygulanan multidisipliner teoriler, teknikler, kavramlar ve teknolojiler olarak tanımlanmaktadır (Badri ve diğerleri, 2018: 405). Yapay zekâ (Artificial Intelligence-AI), görüntü işleme, doğal dil işleme, robotik, makine öğrenmesi vb. birçok alanda araştırma faaliyetlerine sahip bilişsel bir bilimdir. Yapay zekâ veri odaklı endüstrilerde kilit teknoloji olarak kullanılmaktadır. Günümüzde akıllı kişisel asistanlar veya otonom taşıt kullanımı gibi uygulamalarda etkisi giderek artmaktadır. Endüstri 4.0 'ın yaygınlaşması ile AI teknolojileri aynı zamanda üretim endüstrisinde de faydalarını günden güne daha fazla hissettirmektedir (Mayr ve diğerleri, 2018: 40). Ayrıca yapay zeka sektörlerine; süreçlerine ait operasyonlarını otonom şekilde sürdürebilme yeteneği kazandırmaktadır.

Beyin sinir yapısı ve çalışma sistemi taklit edilerek yapay sinir ağlarına ait modeller oluşturulmaktadır. Beyin öğrenmesi temel olarak deneye bağlıdır. Sinir ağı sistemleri, etkinlikleri örneklerle öğrenmek için algoritmik bir yöntem uygulayan geleneksel bilgisayarlardan farklı bir problem çözme yaklaşımını kullanmaktadır. Bu örneklerin seçimi zaman kaybının olmaması ve ağın doğru çalıştığından emin olunması açısından önemli bir konudur. Yapay sinir ağı algoritması yaygın olarak uygulanan yapay zeka algoritmalarından biri olarak düşünülebilmektedir. Giriş, gizli katman ve çıktı katmanları olan üç ana bölümden oluşmaktadır. Giriş katmanındaki giriş değerleri ağa taşınmakta ve nöronlar bilgiyi başka bir katmana değer olarak taşımaktadır. Gizli katman giriş ve çıkış katmanları arasında bir konumda yer almaktadır. Gizli katmanda var olan nöron ve katman sayısının tespiti deneysel çözümlerle yapılmaktadır. Çıktı katmanında ağın çıktı değerleri oluşturulmaktadır (Shaban, Hazzaa ve El-Tayebany, 2019: 322–23).

Şekil 10: Bilgi Tabanlı Sistem, Bilgi Keşfi ve Makine Öğrenmesi İlişkisi



Kaynak: Mayr ve diğerleri, 2018: 42.

Makine öğrenimi, yapılandırılmış ve yapılandırılmamış büyük verilerde saklı olan faydalı bilgilerin alınması için kullanılan dinamik yapay zekâ tekniği olarak tanımlanmaktadır (Cárdenas, Manadhata ve Rajan, 2013: 74–76). Makine öğrenme tekniklerinin başarısı geliştirici tercih ve deneyimleri ile şekillendiğinden; bu tekniklerin endüstriyel uygulamalardaki başarısı insan odaklı olup, çeşitli sınırlara sahiptir. Endüstriyel uygulamalar için gerçekleştirilen yapay zekâ uygulamaları, farklı performans öğrenme algoritmalarını geliştirmeye, doğrulamaya ve dağıtmaya odaklanmaktadır. Endüstri 4.0 dönüşümü sayesinde, yapay zekâ teknolojisinin; IoT, büyük veri, bulut bilişim ve siber güvenlik teknolojileriyle entegrasyonu sağlanmaktadır. Bu şekilde sektörler verimli, esnek ve sürdürülebilir yetenekler kazanmaktadır (J. Lee, Davari, Singh ve Pandhare, 2018: 20; Mayr ve diğerleri, 2018: 40). Bilgi tabanlı sistem üretim sisteminin planlama ve tasarım aşamasında karar vermeyi desteklerken; makine öğrenimi (ML) tabanlı yaklaşımlar, üretim süreçlerini optimize etmek için büyük bir potansiyele sahiptirler. Bu bağlamda, süreç kontrolü, kalite yönetimi (QM) ve öngörülü bakım üç ana uygulamayı temsil etmektedir. Makine öğreniminin proses kontrolünde uygulanmasıyla; değişen koşullara daha iyi adapte olunması ve hata oranlarının düşürülürken çıktı kalitesinin artırılması beklenmektedir (Mayr ve diğerleri, 2018: 43).

Derin öğrenme yöntemi, insan beyninin çalışma sistematüğini örnek alarak hesaplama yapan sistemlere dayanmaktadır. Derin öğrenme, mimarisinde bir veya


daha fazla gizli katman bulunduran yapay sinir ağı modeli olup; önemli bir makine öğrenmesi tekniğidir. Çalışmanın uygulama bölümünde derin öğrenme modellerinden, elektrik dağıtım ağlarının çalışma durumuna ait saatlik tahminlerde faydaniılmaktadır. Yapay zekâ, makine öğrenmesi ve derin öğrenme konuları çalışmanın üçüncü bölümde detaylı olarak açıklanmaktadır.

1.2. ENDÜSTRİ 4.0 ALANINDA YAPILAN ÇALIŞMALAR

Günümüz dünyasında önemi tüm sektörler tarafından farkedilmeye başlanan Endüstri 4.0 dönüşümü, geçmişten günümüze uygulanan ve yenilerinin de geliştirildiği birçok teknolojinin entegrasyonundan oluşmaktadır. Endüstri 4.0 alanında yapılan çalışmalara bakıldığında; süreçlerin otonomlaştırılması ve sistemlerin akıllı şekilde operasyonlarını yerine getirmeleri hedeflenmektedir. Çalışmalarda işletmelerin Endüstri 4.0 dönüşümü hazırlıkları, yetkinlikleri ve ihtiyaçları ele alınmaktadır. Bunun yanında Endüstri 4.0 teknolojilerine ait uygulamalar ve gelişmeler konularında birçok araştırma bulunmaktadır. Bu bölümde Endüstri 4.0 ve teknolojileri konularında yapılan çalışmalara yer verilmektedir.

Endüstri 4.0 konusunda 2012 yılından itibaren yapılan araştırmalar çeşitli alanlarda artan şekilde devam etmektedir. Chiarello ve arkadaşlarının tespit ettiği alanlara göre yapılan Endüstri 4.0 yayınlarının sayıları Şekil 11' de yer almaktadır (Chiarello ve diğerleri, 2018: 244).

Şekil 11: Endüstri 4.0 Konusunda Alanlara Göre Yayın Sayısı



Kaynak: Chiarello ve diğerleri, 2018: 245. SCOPUS: 06.06.2017.

McKinsey araştırma şirketi tarafından Endüstri 4.0 konusunda yapılan ankete göre şirketlerin ortaya çıkan teknolojilerin farkında olmadığı gözlemlenmiştir. Ocak 2015' te 300 imalat lideri ile yapılan görüşmede üreticilerin sadece %48' inin kendilerini Endüstri 4.0 için hazır hissettiği ortaya çıkmıştır. Araştırmada tedarikçilerin ise %78' inin kendilerini hazır hissettiğine dair sonuçlar elde edilmiştir (Sung, 2018: 41), (Baur ve Wee, 2015: 1). Lu' ya göre IoT, CPS ve bilgi-iletişim teknolojileri; kurumsal yapı ve kurumsal entegrasyon ile etkileşim halindedir. Lu araştırmasında Endüstri 4.0' ın içeriği, kapsamı ve bulgularını Web of Science kapsamındaki tüm veritabanlarında bulunan yayınları incelemiştir. Çalışmada Endüstri 4.0 ile ilgili 88 makale beş kategorisinde gruplandırılmıştır (Tablo 2).


Tablo 2: Endüstri 4.0 Yayınlarının Araştırma Kategorileri

Araştırma Kategorileri	Yayın Sayısı
Endüstri 4.0 kavramı ve bakış açıları	18
CPS tabanlı Endüstri 4.0	12
Endüstri 4.0 dönüşümü ile birlikte çalışabilirlik	11
Endüstri 4.0 dönüşümünün kilit teknolojileri	20
Endüstri 4.0 uygulamaları	27
Toplam	88

Kaynak: Lu, 2017: 2.

Endüstri 4.0, RFID, kurumsal kaynak planlama (ERP), IoT, bulut tabanlı üretim ve sosyal ürün geliştirme dâhil olmak üzere çok sayıda teknoloji incelenmiştir. Çalışma ayrıca kritik öneme sahip olan Endüstri 4.0 ile birlikte çalışabilirliği ana hatlarıyla belirtirken; Endüstri 4.0 ile ilgili gelecekteki araştırmalar için zorluklar ve eğilimleri tartışmaktadır (Lu, 2017: 1). Ayrıca araştırma kategorisindeki 27 makalenin 13' ü akıllı fabrika ve imalat, 10' u akıllı üretim ve diğer 4' ü akıllı şehir alanlarına yönelmiştir (Lu, 2017: 6-7).

Şekil 12: Yayın Sayılarının ve Atıfların Dağılımı (2011–2016)



Kaynak: Lu, 2017: 3.

Hermann ve arkadaşları, Kagermann ve arkadaşları ve Li ve arkadaşlarının Endüstri 4.0 kavramı ve bakış açıları konularında çalışmaları bulunmaktadır (Hermann ve diğerleri, 2016: 3928–29), (Kagermann, Wahlster ve Helbig, 2013: 19), (X. Li ve diğerleri, 2017: 23–25). Ivanov ve arkadaşları ile Mosterman ve arkadaşları siber-fiziksel sistemler ekseninde Endüstri 4.0 konularını incelemiştir (Ivanov, Dolgui, Sokolov, Werner ve Ivanova, 2016: 386), (Mosterman ve Zander, 2016: 17–18). Bunların yanında Kolberg ve arkadaşları ile Shafiq ve arkadaşları akıllı fabrika ve üretim (Kolberg ve Zühlke, 2015: 1872–73), (Shafiq, Sanin, Szczerbicki ve Toro, 2016: 32–33) konularında çalışmalar yapmıştır (Lu, 2017: 3-8). Kiraz ve arkadaşları, Endüstri 4.0 eğilimini etkileyen kriterleri ortaya koymuş ve bu kriterlerin Endüstri 4.0 üzerindeki etkilerinin analizini yapısal eşitlik modeli (SEM) kullanarak gerçekleştirmiştir. Modelde, iş modelleri-ürünler-hizmetler, pazar-müşteri erişimi, değer zincirleri-süreçler, bilgi teknolojisi mimarisi, uyumluluk-risk-güvenlik, organizasyon-kurumsal kültür, liderlik-strateji-kültür-yönetim, IoT-veri koruma-işleme-ekip uzmanlığı ve analiz için veri entegrasyonu dahil olmak üzere dokuz kriter kullanılmıştır. Dokuz kriterin de Endüstri 4.0 üzerinde olumlu etkisinin olduğu ve bunlardan altısının önemli ölçüde etkili olduğu tespit edilmiştir. Sonuçlara göre en

önemli kriter pazar ve müşteri erişimi olarak belirlenmiştir (Kiraz, Canpolat, Özkurt ve Taşkın, 2020: 1).

Dalenogare ve arkadaşları Brezilya endüstrisinin 2225 şirketini temsil eden 27 sanayi sektöründe yaptıkları anketten elde ettikleri ikincil verilere dayanarak, farklı Endüstri 4.0 teknolojilerinin benimsenmesinin ürün, operasyon ve yan etkiler konularında beklenen faydalar arasındaki ilişkiyi araştırmaktadır. Araştırmacılar regresyon analizini kullanarak, Endüstri 4.0 teknolojilerinin bir kısmının, endüstriyel bilgiyi ümit verici olarak gördüğünü, yeni ortaya çıkan teknolojilerin ise, geleneksel akıllı kısıtlamadığını göstermektedir. Gelişmiş ülkelerde oluşturulan Endüstri 4.0 kavramlarının kısmen uygulanmasını gerektirebilecek Brezilya endüstrisinin içeriksel koşulları tartışılmaktadır (Dalenogare ve diğerleri, 2018: 383). Yüksel çalışmasında, Türkiye’ de faaliyetine devam eden 1000’ den fazla işletmedeki Endüstri 4.0 uygulamalarının düzeyini araştırmaktadır. Çalışmada işletmelerde Endüstri 4.0 uygulamalarının mevcut seviyesi, üretilen ürünlerin teknolojik düzeyi, Ar-Ge departmanının varlığı ve firma büyüklüğünün Endüstri 4.0 uygulamalarına olan etkilerine cevap aranmıştır. Çalışmada genel olarak, gelişmekte olan ülkelerdeki işletmelerin Endüstri 4.0 teknolojilerine yatırım yapmaları hususunda elde edilecek kazanımlara vurgu yapılmıştır. Ayrıca teknik beceri eksikliği ve uzmanlığın yeterli düzeyde olmayışı; Türkiye'deki işletmelerin Endüstri 4.0 dönüşümünün en önemli sorunları olduğu belirtilmiştir (Yüksel, 2020: 3).

Tjahjono ve arkadaşları Endüstri 4.0 dönüşümünün tedarik zinciri yönetimi (SCM) üzerindeki etkisini incelenmiş ve çalışmada Tedarik Zinciri 4.0' a yönelik katkılar sunulmuştur. Analiz kapsamında bir tedarik zincirini, tedarik, nakliye lojistiği, depo ve sipariş karşılamayı içerecek şekilde sınırlandırmıştır. Depolama süreci ile nakliye lojistiği süreci için teknolojilere değinmiş olup; bu süreçlere ait anahtar performans göstergelerini (KPI) belirlemiştir. Ayrıca tedarik zinciri kaldıraçları üzerindeki fırsat ve tehditleri incelemiştir (Tjahjono, Esplugues, Ares ve Pelaez, 2017: 1175–81). Endüstri 4.0, operatörleri de kapsayan, üretimde verimlilik ve etkinlik için yeni ihtiyaçları tanımlamaktadır. Yeni nesil sistemlerde geleneksel operatör, Operatör 4.0' a dönüşmektedir. Zolotová ve arkadaşları fabrikalardaki operatörlerin gelişen rollerini açıklamaktadır. Operatörün fiziksel, algılayıcı ve bilişsel yeteneklerini geliştirmenin birçok yolu bulunmaktadır. Eski sistemlerde, sağlık durumu izleme


platformuna, öngörücü bakım konseptine ve makinenin operatör pozisyonuna dayalı insan etkileşim sistemine odaklanılmıştır. Çalışmada, Endüstri 4.0 konseptinde insan merkezli yaklaşım ve Operatör 4.0 fikrini uygulayan vaka çalışmaları yer almaktadır (Zolotová ve diğerleri, 2020: 1–2). Zonta ve arkadaşları Endüstri 4.0’ da kestirimci bakım faaliyetlerinin, yöntemlerinin, standartlarının ve uygulamalarının tanımlanması ve kataloglanması konularında sistematik bir literatür taraması sunmaktadır. Çalışma, öngörücü bakımda yaşanan mevcut zorlukları ve sınırlamaları tartışmanın yanı sıra; bu konuda Endüstri 4.0’ ın ihtiyaçlarını dikkate alarak bir sınıflandırma önermektedir. Yapay zekâ ve dağıtılmış bilgi işlem alanlarını kapsayan bilgisayar bilimine, baskın uzmanlık gerektiren mühendislik alanlarında gittikçe daha fazla ihtiyaç duyulduğu sonucuna varılmaktadır (Zonta ve diğerleri, 2020: 1).

Tvenge ve Martinsen’ in çalışmasında şirket içi öğrenmenin gerçekleştirmesi için siber-fiziksel üretim sistemine entegre, kesintisiz, bütünleşik bir bilgi ve iletişim teknolojileri öğrenimi, veri analizi ve simülasyonların yapıldığı hibrit bir insan-makine zekâsı modeli önerilmektedir (Tvenge ve Martinsen, 2018: 261). Abbas ve arkadaşları, Rani ve arkadaşları ve Farooq ve arkadaşlarının nesnelerin interneti konusunu çalışmıştır (Abbas ve Yoon, 2015: 24820; Rani ve diğerleri, 2015: 28604; Farooq ve diğerleri, 2015: 1–2). Shakshuki ve arkadaşları ile Nawaz ve arkadaşları siber fiziksel sistem konusunu araştırmıştır (Shakshuki, Malik ve Sheltami, 2014: 93–94), (Nawaz, Petrov ve Buchmann, 2014: 3–7). Klievink ve arkadaşları ile Khan ve arkadaşları büyük veri (big data) konusunu incelemiştir (Klievink, Romijn, Cunningham ve de Bruijn, 2017: 269–70), (Khan ve diğerleri, 2014: 1–2). Bunun yanında Kim ve arkadaşları bulut bilişim (J. Kim ve Kim, 2016: 3522–23) ve Sun ve arkadaşları siber güvenlik (C.-C. Sun, Hahn ve Liu, 2018: 45–46) konularına katkıda bulunmuştur (Faheem ve diğerleri, 2018: 12). Badri ve arkadaşları Endüstri 4.0 ile ilgili teknolojik kategorilerin potansiyel etkisini incelemiştir (Badri ve diğerleri, 2018: 405). Chiarello dördüncü sanayi devriminde iş sağlığı ve güvenliği konusunu inceleyerek oluşabilecek iş sağlığı risklerini ele almıştır. Bunun yanında Fransa, İngiltere, Almanya, İtalya, ABD, Avrupa, Macaristan, İspanya ve Çin’ de Endüstri 4.0 alanında yapılan çalışmalarla ilgili literatür araştırması yapmıştır (Chiarello ve diğerleri, 2018: 245).

Kamble ve arkadaşları tarafından literatürden 85 makale incelenmiştir. Makaleler, Endüstri 4.0, insan-makine etkileşimleri, makine-makine etkileşimleri,

Endüstri 4.0 teknolojileri ve sürdürülebilirlik başlıklarında kavramsal makaleler olarak beş araştırma kategorisinde sınıflandırılmıştır. Endüstri 4.0 alanında yapılan araştırmaların mevcut durumları ve araştırma yaklaşımları sorgulanmıştır.


Şekil 13: Endüstri 4.0 Alanında Yıllara Göre Yayın Sayısı



Kaynak: Kamble, Gunasekaran ve Gawankar, 2018: 410.

Araştırmanın bulgularıyla Endüstri 4.0 teknolojileri, süreç entegrasyonu ve sürdürülebilir Endüstri 4.0 olarak üç önemli bileşen önerilmiştir. Çalışmada Endüstri 4.0 dönüşümüne ait anahtar kelimeler; Endüstri 4.0, akıllı imalat, akıllı üretim, akıllı fabrika, siber fiziksel sistemler, bulut üretim, nesnelerin interneti (IoT); işlemlerle ilgili anahtar kelimeler ise üretim, tam zamanında üretim, bütünsel planlama, kapasite planlama, yalın üretim, kalite ve süreç iyileştirme olarak belirlenmiştir (Kamble, Gunasekaran ve Gawankar, 2018: 408-09).


Şekil 14: Endüstri 4.0 Konusunda Sık Kullanılan Anahtar Kelimeler (Sayı ≥ 2)



Kaynak: Kamble ve diğerleri, 2018: 412.

Seçilen makalelerde sıklık sırası olarak Endüstri 4.0 (%28), nesnelerin interneti (%16), akıllı üretim (%13), siber-fiziksel sistemler (%9) ve diğer anahtar kelimeler RFID, akıllı fabrika ve bulut bilişim olarak gözlenmiştir (Kamble, Gunasekaran ve Gawankar, 2018: 410). Endüstri 4.0 alanında iki veya daha fazla yayın yapan ülkelerin yayın sayıları Şekil 15’ te yer almaktadır.


Şekil 15: Endüstri 4.0 Alanında Ülkelerin Yayın Sayıları (≥ 2 makale)



Kaynak: Kamble ve diğerleri, 2018: 411.

Makale başlıklarındaki sıklıkla kullanılan anahtar kelimeler Şekil 16’ da yer almaktadır.

Şekil 16: Endüstri 4.0 Alanında Makale Başlıklarındaki Anahtar Kelimeler




Kaynak: Kamble ve diğerleri, 2018: 412.

2012-2017 tarih aralığında Endüstri 4.0 dönüşümünü inceleyen yayınlara bakıldığında; Endüstri 4.0 çalışmalarının farklı yönleriyle ilgili kavramsal makalelerin sayısında önemli bir artışın olduğu gözlemlenmektedir. Simulasyonları, deneyleri ve

prototipleri kullanan çalışmalardaki artış anlamlı değildir. Yayınların araştırma türlerine göre dağılım grafiği Şekil 17’ de yer almaktadır. Çalışmada 85 makale beş araştırma kategorisinde değerlendirmeye alınmıştır. Kategorilerin dağılımına bakıldığında, büyük veri, simulasyon, eklemeli üretim, IoT, sanal gerçeklik, vd kullanımını da içeren Endüstri 4.0 teknolojilerine (makalelerin %67’ si) ilginin daha fazla olduğu gözlenmektedir. Bu ilgiyi, Endüstri 4.0 genel teori ve kavramı, üretim ekipman etkileşimi, insan makine arayüzü ve sürdürülebilirlik konuları izlemektedir.


Şekil 17: Endüstri 4.0 Alanında Araştırma Yaklaşımlarının Dağılımı



Kaynak: Kamble ve diğerleri, 2018: 413.

Araştırma kategorilerinin dağılımına bakıldığında, tüm araştırma kategorilerinde araştırmacıların genel ilgisinin arttığı görülmektedir. Araştırmaya göre Endüstri 4.0' ı incelemek için çoğu çalışma (%65) ampirik yaklaşımı benimsemiş ve geri kalan çalışmalar (%35) kavramsal yaklaşımı benimsemiştir.

Şekil 18: Endüstri 4.0 Alanında Araştırma Kategorilerinin Dağılımı 2012-2017



Kaynak: Kamble ve diğerleri, 2018: 413-14.

Ampirik yaklaşım, kavramları, teorileri ve uygulamaları test etmek ve onaylamak için vaka çalışmalarını, simülasyonları, deneyleri, vb. kullanmaktadır. Endüstri 4.0' ın ana teknolojilerine ait 57 bildirinin %33' ü vaka çalışması olarak yayınlanmıştır. Yayınların %8' inde simülasyon ve %5'inde deney kullanılmıştır. Atölye-ekipman etkileşimi konusundaki 37 makalenin yaklaşık %30' unda vaka çalışması yaklaşımı, %13' ünde simülasyon ve %13' ünde deney yaklaşımları kullanılmıştır.

Tablo 3: Endüstri 4.0 Alanlarında Araştırma Düzeyi (2012-2017)

Araştırma Kategorisi	Kavramsal	Vaka Çalışması	Simülasyon	Deney	Araştırma	Prototip	Toplam
Endüstri 4.0 Konsepti ve Teorisi	30	0	0	0	0	0	30
Anahtar (Ana) Teknolojiler	23*	19	7	5	1	2	57
Üretim Alanı-Ekipman Etkileşimi	15*	11	5	5	0	1	37
İnsan-Makine Etkileşimi	7*	6	2	1	3	2	21
Sürdürülebilirlik	6*	6	3	0	1	0	16

Kaynak: Kamble ve diğerleri, 2018 : 414.

İnsan-makine arayüzü (%28) ve sürdürülebilirlik (%37,5) konusundaki çalışmaların çoğu vaka çalışması yaklaşımını kullanmıştır. Elde edilen sonuçlar vaka çalışması yaklaşımının araştırmacılar tarafından teknolojiyi veya arayüz katmanlarını göstermek için kullanılan en popüler yaklaşım olduğunu göstermektedir. Simülasyon, deney ve prototip araştırma yaklaşımlarının kullanımı artmasına rağmen bu artışlar anlamlı değildir (Kamble, Gunasekaran ve Gawankar, 2018: 413-14).

Akıllı üretim, Endüstri 4.0 dönüşümünün merkezinde yer aldığından, üretim planlama ve kontrol Endüstri 4.0 faaliyetlerinde kilit rol oynamalıdır. Önceki araştırmalar genellikle Endüstri 4.0' ın teknolojik yönlerine odaklanırken; Bueno ve arkadaşları üretim planlama ve kontrolün; nesnelerin interneti, siber-fiziksel sistemler, büyük veri ve analitik/yapay zekâ ve eklemeli üretim olarak dijital yeteneklerden nasıl etkilendiği ve bu yeni dönüşümde nasıl çalıştığı konularına odaklanılmıştır. Bu teknolojilerin üretim sistemi performans göstergeleri ve çevresel faktörlerle olan ilişkisi araştırılmıştır. Araştırma 2011-2019 aralığındaki çalışmaları içermektedir. Çalışmada, gerçek zamanlı yetenekler, uyarlanabilirlik ve dinamiklik, görünürlük ve


izlenebilirlik, özerklik, akıllı çizelgeleme ve hizmetin dâhil olduğu 18 akıllı özelliğin listesi sunulmaktadır. Üretim esnekliği, çeviklik ve güvenilirliğin dâhil olduğu 13 performans göstergesi ve ürün, talep ve üretim süreci gibi çevresel faktörler yer almaktadır (Bueno, Godinho Filho ve Frank, 2020: 1).

Kore Hükümeti Endüstri 4.0 dönüşümüne yönelik çeşitli girişimleri faaliyete geçirmiştir. Bilim alanında ana teknolojilerin geliştirilmesine destek sağlanmış; strateji ve politikalar oluşturulmuştur. Kültür alanında içerik endüstrisi beslenmiş ve kültüre ait istikrarlı tedarik sistemleri uygulanmıştır. Ticaret, sanayi ve enerji alanında akıllı fabrika dâhil olmak üzere endüstri altyapısının kurulması kararlaştırılmıştır. İstihdamla ilgili yasa ve politikaların hazırlanması ve insan kaynaklarının geliştirilmesi hedeflenmiştir. Strateji ve finans konusunda finansal planlama ve etkin tepkiler için ilgili tüm kuruluşların koordinasyonu kararlaştırılmıştır. İç işleri ve güvenlik için daha akıllı bir devlet sistemine dönüşülmesi planlanmıştır. Üniversite eğitiminin güçlendirilmesi ve girişimler için insan kaynaklarının geliştirilmesi planlanmıştır. Tarım sektörü için büyük veri analizi, akıllı araçlar ve teknolojilerin geliştirilmesi; etkin ve akıllı ulaşım sistemlerinin artırılması planlanmıştır. Gerekli yasaların hazırlanması ve düzenlenmesine başlanmıştır (Sung, 2018: 44).

Shao ve arkadaşları, iş ve endüstrinin gelecekteki dönüşümü konusunda araştırmaların azlığı nedeniyle; tedarik zincirinin birçok katmanında Endüstri 4.0 teknolojilerinin uygulanabilmesi için yaklaşımlar önermektedir (Shao, Liu, Li, Chaudhry ve Yue, 2020: 1). Moktadir ve arkadaşları tarafından Endüstri 4.0' ın imalat operasyonlarında yaşanan zorlukları konusunda çalışmaların azlığına vurgu yapıp; bu boşluğun giderilmesi için çeşitli zorluklar tanımlanmaktadır. Bangladeş' in deri endüstrisinde, çok kriterli karar verme yöntemi olan “en iyi-en kötü metod” ile değerlendirilmektedir. Çevrenin korunması ve kontrolü için akıllı üretim sistemleri ve temiz teknolojiler; şirketlerin israf ve çevresel zararlı etkilerini en aza indirmesine yardımcı olabilmektedir. Endüstri 4.0' ın Bangladeş deri endüstrisinin tedarik zincirine entegre edilerek; su, toprak ve hava kirliliğinin azaltılması oldukça önemlidir. Çalışmada, teknolojik altyapı eksikliğinin Endüstri 4.0 dönüşümünü engelleyebilecek en önemli zorluk olduğu ve çevresel yan etkilerin en az önem derecesine sahip olan zorluk olduğu saptanmıştır (Moktadir ve diğerleri, 2018: 730-32).

Endüstri 4.0 dönüşümünün çeşitli zorlukları bulunmaktadır. Bu zorluklardan (Gölzer, Cato ve Amberg, 2015: 6) veri güvensizliği konusuna, (K. Zhou, Liu ve Zhou, 2015: 2150–51) yüksek yatırım maliyeti ve strateji eksikliği konusuna, (Waibel, Steenkamp, Moloko ve Oosthuizen, 2017: 736) teknolojik altyapı eksikliği ve (Hecklau, Galeitzke, Flachs ve Kohl, 2016: 2) kalifiye yönetim kadrosu eksikliği konusuna değinmektedir (Moktadir ve diğerleri, 2018: 734). Kamble ve arkadaşları Endüstri 4.0 entegrasyonunun önündeki bariyerleri; istihdam kesintileri, yüksek maliyet, organizasyonel ve süreç değişiklikleri, gelişmiş beceri ihtiyacı, bilgi teknolojileri ve yönetimi eksikliği, IoT faydaları hakkında yetersiz bilgi, standart ve referansların eksikliği, internet kapsama alanı yetersizliği, güvenlik ve gizlilik sorunları, uyumluluk ve mevzuat sorunları, yasal ve sözleşme belirsizliği olarak sıralamaktadır (Kamble, Gunasekaran ve Sharma, 2018: 110). Rafael ve arkadaşları takım tezgâhı üreten kobilerin Endüstri 4.0 dönüşümüne uyum sağlamada yaşayacağı zorluklara değinip; bu işletmeler için olgunluk modeli önermektedir (Rafael, Jaione, Cristina ve Ibon, 2020: 1). Gobbo ve arkadaşları, Endüstri 4.0' ın, proses güvenliği ve çevre koruma konularında çalışma yapan araştırmacıların ve yöneticilerin yeni zorluklar ve fırsatlarla karşılaşacağına vurgu yapmaktadır.

Şekil 19: Çevre Koruma, Süreç Güvenliği ve Endüstri 4.0 Yayınlarının



Kaynak: Gobbo ve diğerleri, 2018: 375.

Çalışmada, Endüstri 4.0 ve çevre koruma alanında temel kavramlar ele alınmıştır. Bu kavramlar arasında gerçekleşebilecek entegrasyonun tanımındaki boşluklara değinilmiştir (Gobbo ve diğerleri, 2018: 372).

1.3. TÜRKİYE KAMU KURUMLARI VE ÖZEL SEKTÖR İŞLETMELERİNDE ENDÜSTRİ 4.0 DÖNÜŞÜMÜ

Kamu ve özel sektör işletmelerinde operasyonlara ait verilerin toplanması, bu veriler kullanılarak çeşitli analizlerin yapılması ve elde edilen bilgiler doğrultusunda ilgili operasyonların yerine getirilmesi işlemleri, gerçek zamanlı yapılmadığında; verilen hizmetlerde ve gerçekleştirilen faaliyetlerde tatmin edici olmayan birçok durumla karşılaşmaktadır. Ülkemizde kurum ve kuruluşlarda gerçekleştirilen faaliyetlerde orta ve uzun vadeli kurumsal hafızanın oluşturulmasına yeterli önem verilmeyerek; operasyonlarda günlük ve plansız davranışlar sergilenebilmektedir. Kamu kurumlarındaki iyileştirme çalışmaları genellikle departman veya iş bazında yapılmaktadır. Mevcut durumda kurum ve kuruluşlarda sağlıklı veri toplama için gereken altyapının geliştirilmeye ihtiyacı bulunmaktadır. Verilerin işlenmesi ve anlamlandırılması için gereken insan yatırımı ve maddi kaynak yatırıma üst düzeyde önem verilmelidir. Yapay zeka, optimizasyon, simulasyon, yalın altı sigma, yazılım, sensör, donanım ve diğer teknik-teknolojilerin gerçek hayat problemlerinin çözümünde kullanımı için gereken altyapı, sürekli iyileştirme hedeflerine verilen önem ve bu alanlardaki teşvikler artırılmalıdır. Bu eksiklikler nedeniyle kamu kurum ve kuruluşlarımız ürettiği büyük hacimli verilerden yeterli düzeyde katma değer ve maliyet avantajı sağlayamamaktadır. Sonuç olarak büyük kısmı kamudan toplanan vergilerle karşılanan devlet harcamalarında; istenmeyen ve fark edilmeyen israflar oluşmaktadır. Devlet harcamalarının yüksek olduğu kamu, enerji, sağlık ve savunma gibi sektörlerde yapılacak iyileştirmeler ve entegre edilebilecek etkin sistemler sayesinde kaynaklarımız daha verimli kullanılacaktır (Sayar ve Güneş, 2015: 562).

Endüstri 4.0 dönüşümüyle kamu ve özel sektörde, kaynakların kullanımındaki israflar, süreç değişkenlikleri ve üretilen ürün veya hizmet kalitesindeki negatif sapmalar azalacaktır. Bu iyileştirmeler sağlanırken; sistemin otonom şekilde gerçek zamanlı müdahalelerde bulunması oldukça önemlidir. Kurumlarda Endüstri 4.0 entegrasyonu sağlandığında; devlet harcamaları, israflar, cari açık ve kamudan toplanan vergiler azalacaktır. Yatırımların ve yeni iş-istihdam olanaklarının önü açılırken; Ar-Ge ye ayrılan kaynaklar ve kamu kurumlarından alınan hizmetlerin kalitesi artacaktır.

1.3.1. Endüstri 4.0 ve Sağlık Sektörü (Sağlık 4.0)

Sağlık sektöründe akıllı süreç uygulamaları, tanı, teşhis ve tedavi süreçlerinde hız ve başarıyı artırarak hayat kurtarma, yaşam kalitesi yükseltme ve sektörün yüksek maliyetlerini azaltma gibi sağladığı faydalardan ötürü devletler açısından oldukça önemlidir. Sağlık sektöründe erken teşhis ve tedavi hayati önem taşımaktadır (Sayar ve Güneş, 2015: 564). Endüstri 4.0 (Sağlık 4.0) dönüşümünün sağlık sektöründe uygulamaları sayesinde teşhis, tedavi ve müdahale süreçlerinde yüksek başarı ve hız yetenekleri elde edilmektedir. Sağlık veri tabanlarının, yapay zeka uygulamalarının ve gömülü algoritmaların kullanıldığı Sağlık 4.0 dönüşümü sayesinde insanların hastalıklara yakalanma risk durumları öngörülüp; hastalığa yakalanmadan ilgili tedbirler alınabilmektedir. Yapay zekâ ve algoritmalar sayesinde sağlık personeli yönlendirilerek; tanı-teşhis-tedavi süreçlerinde olası hatalar azaltılmakta veya önlenabilmektedir. Tedavi ve ilaç kullanım süreci, bireylerin veritabanı bilgileri değerlendirilerek ve bireysel tüm özellikleri dikkate alınarak; bütüncül ve fonksiyonel bakışla, bireye özgü ve optimum şekilde gerçekleştirilecektir. Bu şekilde yanlış ve aşırı ilaç kullanımı önlenip; tedavi sürecinin etkinliği artacaktır. Büyük oranda ithalat yoluyla tedarik edilen ilaçlara ait israfların önüne geçilerek; ülkemizde sağlık sektörünün ilaç bazlı ithalat harcamaları azaltılacaktır. Akıllı cihaz, akıllı telefon ve giyilebilir akıllı cihazlar kullanılarak bireylerin sağlık durumları sağlık kuruluşları tarafından anlık ve gerçek zamanlı olarak izlenebilecektir. Mevcut durumda hastalık risk seviyeleri yükselmeden bireylere erken müdahalelerde bulunulabilecektir. Sağlık 4.0 dönüşümü sayesinde genel olarak insanların yaşam kaliteleri ve yaşam süreleri artarken devlet harcamaları azalacaktır.

1.3.2. Endüstri 4.0 ve Ulaştırma Sektörü (Ulaştırma 4.0)

Endüstri 4.0 dönüşümünün ulaştırma sektöründe uygulanması neticesinde yol durum bilgileri, takip mesafesi, birlikte hareket halindeki araçların birbiriyle paylaştığı veriler, hava ve yol durumlarına ait veriler araçlara gerçek zamanlı şekilde aktarılmaktadır. Yapay zeka, IoT teknolojileri ve çeşitli algoritmalar kullanılarak taşıtların anlık maksimum ve minimum hız seviyeleri belirlenip; dinamik koşullar

altında taşıtların süratleri ve yönlendirmeleri otonom şekilde sistem tarafından yapılabilmektedir. Bu şekilde kazalar büyük oranda azaltılabilecektir. İnsansız hava araçlarının yaygınlaşması ve yapay zeka uygulamalarının gelişmesiyle birlikte tüm süreç tam otonom şekilde kontrol edilip; sürüş esnasında insan hatasının önüne geçilebilecektir. Trafik yoğunluğu ve taşıt beklemleri azaltılırken taşıtların yakıt israfları ve tüketimleri de azalmaktadır. Ülkemiz cari açığında önemli büyüklükte paya sahip olan petrol ithalatı, Ulaştırma 4.0 dönüşümünün katkısıyla azalacaktır. Yapay zeka uygulamaları sayesinde yol, kavşak köprü, trafik lambası ve otopark gibi trafiğin tüm bileşenlerinde sistemin mevcut dinamik durumuna uygun gerçek zamanlı yönlendirmeler otonom şekilde yapılabilecektir. Bir konumdan başka bir konuma ulaşım esnasında kullanılacak taşıt/taşıtlar ve güzergâh alternatifleri süre tahmin verileriyle sunulur; bireylerin yaşam kalitesi yükseltilecektir. Yapay zekâ ve IoT uygulamaları sayesinde tüm ulaşım şebekesinde anlık bekleyen araç sayısı ve yoğunluk tahminleri göz önünde bulundurularak; ambulans ve itfaiye gibi acil durum önceliğine sahip taşıtların ulaşımı kolaylaştırılacaktır.

1.3.3. Endüstri 4.0 ve Kamu Kurumları (Kamu 4.0)

Resmi kurumlarda Endüstri 4.0 dönüşümü gerçekleştiğinde yüz tanıma, göz taraması, parmak izi ve ses tanıma gibi yüksek seviyede güvenliğe sahip kimlik doğrulaması sonrasında; izin verilen veri ve bilgiler izin verilen ilgili kuruma devlet veri tabanı tarafından sağlanacaktır. İşlem, süreç ve operasyonların tamamı yapay zeka ve üst düzey siber güvenliğe sahip devlet sistemi olan Kamu 4.0 platformu üzerinden gerçekleştirilecektir. Resmi evrak ve belge gönderimi, imza, noter vb. tüm işlemler otonom olarak dijital platform üzerinden gerçekleştirilecektir. Kamu kurumlarında işlem yükü azaltılıp bürokratik gecikmelerin önüne geçilecektir. Devlet bütçesinde personel ve belge yükü azaltılacaktır. Devlet-diğer devlet, devlet-vatandaş, vatandaş-vatandaş gibi birbiriyle etkileşimde bulunan tüm gruplar arasındaki vergiler, ödemeler, borçlar, alacaklar, sorumluluklar, cezalar ve sözleşmeler gibi birçok işlem büyük ölçüde otonom şekilde yapılacaktır. Elektrik, su, doğalgaz ve internet kesintileri, temizlik, bakım, ilaçlama, birçok belediye hizmeti, yol yapım çalışmaları ve kurumlar tarafından gerçekleştirilen her türlü bakım-arıza bildirimleri; bu hizmetlerden

etkilenen tüm kiři, kurum ve kuruluşlara, cihazlara ve diğeri otonom sistemlere gerçek zamanlı iletilerek yaşanabilecek mağduriyetler önlenecektir. Kamu 4.0 dönüşümü, sağladığı katma değerler sonucunda; kamu memnuniyetini, insanların yaşam kalitesini ve refah düzeyini artırması yanında devlet harcamalarını büyük oranda azaltacaktır.

1.3.4. Endüstri 4.0 ve Enerji Sektörü (Enerji 4.0)

Enerji sektörü tetikleyici olma özelliğiyle diğeri tüm sektörleri doğrudan etkilemektedir. Enerji sektörünün sürekli büyümesi ve karmaşıklığının artması, sistemin kontrolünü oldukça zorlaştırmaktadır. Enerji sistemlerinin sürekliliğinin, sürdürülebilirliğinin ve güvenliğinin sağlanması ülkeler açısından oldukça önemlidir. Elektrik enerjisi sistemlerinin kesintisiz çalışması ve güvenliği, elektrik dağıtım ağlarında enerji kayıplarının minimizasyonu, elektrik arz-talep dengesinin sağlanması gibi kritik gereksinimler; elektrik üretim ve dağıtım ağlarında gerçekleşen tüm operasyonların ve kontrol süreçlerinin yapay zeka tabanlı otonom yapıya dönüştürülmesini zorunlu hale getirmektedir. Enerji 4.0 entegrasyonu sayesinde enerji sektöründe karşılaşılan birçok operasyonel ve yüksek maliyetli problemler için önemli çözümler sağlanacaktır. Elektrik enerjisi sistemlerinde üretim, iletim, dağıtım, satış, ticaret ve tüketim süreçleri arasında gerçek zamanlı veri paylaşımına dayalı yürütülen operasyonlar; sensör tabanlı haberleşme, yapay zeka, optimizasyon teknikleri ve algoritmalara dayalı otonom karar sistemleri ile gerçekleştirilmelidir. Elektrik enerjisi sistemleri Endüstri 4.0 dönüşümü sayesinde; her türlü dinamik koşulda operasyon kararını kendisi verecektir. Bu şekilde elektrik enerjisi kayıpları ve yük dengesizlikleri otomatik şekilde azaltılacaktır. Yapay zekâ teknolojisi sayesinde enerji arz yetersizliği kaynaklı kesintiler ile iletim ve dağıtım şebekelerinde gerçekleşen iç ve dış faktörler kaynaklı arızalar önceden tahmin edilebilecektir. Gerekli önleyici tedbirler alınabilecek veya oluşacak arızalar erken şekilde giderilebilecektir. İhtiyaç halinde kurulacak olan yeni iletim-dağıtım şebekeleri ve enerji depolama tesisleri; şebeke özellikleri, coğrafi özellikler ve yerleşim yerine ait tüm bilgiler kullanılarak optimum şekilde tasarlanacaktır. Bu sayede oluşabilecek kayıplar ve istenmeyen durumlar önlenebilecektir. Ülkemizde enerji sektöründe Endüstri 4.0 dönüşümü; kamu ve özel sektör için maliyet, cari açık ve enerji sürekliliği bakımından oldukça önemlidir.


İKİNCİ BÖLÜM

ELEKTRİK ENERJİSİ DAĞITIM AĞI, FARKLI SEKTÖRLERDE BAKIM VE ARIZA ÇALIŞMALARI

2.1. ELEKTRİK ENERJİSİ DAĞITIM AĞI

Elektrik enerjisi günümüzde her alanda ihtiyaç duyulan ve hayatımızı kolaylaştıran özelliğinin yanında; aynı zamanda endüstrinin gelişmesi için oldukça önemli bir bileşendir. Elektrik enerjisi genellikle fosil yakıtlardan, nükleer ve diğer yenilenebilir/yenilenebilir olmayan kaynaklardan elde edilmektedir. Güç üretim sistemleri ve enerji dağıtım sistemleri, rastgele nedenler ve etkiler nedeniyle kolayca arızalanabilmektedir. Bu nedenle sistemin güvenilirlik ve kararlılık problemi ile ilgili literatürde birçok çalışma bulunmaktadır. Sistem güvenilirliği genel olarak belirli iç ve dış etkenler altında belirli hedeflere istenilen düzeyde ulaşma olasılığı olarak tanımlanabilmektedir. Güvenilirlik mühendisliği, 1940' tan sonra istatistiksel yöntemlerin gelişmesiyle ilerlemeye başlamıştır. Bu mühendislik alanı savunma sanayinde sıkça kullanılmaya başlanmıştır. 1960' larda Japonya ve ABD gibi birçok ülkede elektriksel hatalar ve diğer sistem dengesizlikleri ortaya çıkmaya başlamıştır. Bu tarihlerden itibaren literatürde güç sistemi güvenilirliğine vurgu yapılmaktadır. Güç sistemi üç ana bölümden oluşmaktadır. Üretim sistemi, iletim sistemi ve dağıtım sistemi birbirine bağlı olarak enterekonnekte sistemi oluşturmaktadır (J. Wang, Zhao, Guo ve Li, 2018: 700).

Şekil 20: Güç Sistemi Etkileşim Şeması



Kaynak: (Froger, Gendreau, Mendoza, Pinson ve Rousseau, 2016: 696).

Üretim sistemi, yenilenebilir ve geleneksel elektrik üretim sistemi olarak iki sınıfa ayrılmaktadır. Yenilenebilir enerji üretim sistemi elektrik üretmek için temiz enerjiyi kullanan sistem olarak tanımlanabilmektedir. Temiz enerji, genellikle güneş enerjisi, rüzgâr enerjisi, biyokütle ve diğer yenilenebilir enerjileri ifade etmektedir. Enerji üretiminde çeşitli fosil yakıtların, kömür, petrol ve diğer konvansiyonel enerjilerin kullanılması ciddi çevre kirlilik sorunlarına neden olmaktadır. Bu nedenle elektrik enerjisi sistemlerinde yenilenebilir enerjinin gelişimi giderek artmaktadır. Üretim istasyonları ve dağıtım sistemi ile bir güç sistemi (ızgara, alan) diğerine iletim hatları vasıtasıyla bağlanmaktadır. Üretim ve iletim sisteminin amacı, her ana yük noktasına yeterli gücü sağlamaktır. İletim sisteminde, elektrik arızası çoğunlukla kısa devre veya diğer ciddi aksaklıklardan kaynaklanmaktadır. Bu nedenle, sistemdeki güvenilirlik ölçütleri temel olarak arıza olasılığı, beklenen azaltılmış yük, beklenen yük azaltma süresidir. Dağıtım sistemi güvenilirliğini değerlendiren endeksler, müşteri ortalama kesinti frekans indeksi (CAIFI), müşteri ortalama kesinti süresi indeksi (CAIDI), sistem ortalama kesinti sıklık indeksi (SAIFI), sistem ortalama kesinti süresi indeksi (SAIDI) olarak kullanılmaktadır. Üretim, iletim ve dağıtım sistemi tüm çalışma durumlarında kesintisiz çalışmalıdır. Bu nedenle, aynı anda üç sistem güvenilirliğini çalışmak, tüm güç sistemi güvenilirliğini iyileştirmek için önemli bir yaklaşımdır (J. Wang ve diğerleri, 2018: 700). Dağıtım sistemi güvenilirliğini değerlendiren endeksler (Balakrishna, Rajagopal ve Swarup, 2017: 158):

$$SAIFI = \frac{\Sigma \text{Kesinti Yaşayan Toplam Müşteri Sayısı}}{\text{Toplam Müşteri Sayısı}}$$

$$SAIDI = \frac{\Sigma \text{Toplam Müşteri Kesinti Süreleri}}{\text{Toplam Müşteri Sayısı}}$$


$$CAIDI = \frac{\Sigma \text{Toplam Müşteri Kesinti Süreleri}}{\text{Kesinti Yaşayan Toplam Müşteri Sayısı}}$$

$$CAIFI = \frac{\Sigma \text{Toplam Kesintiye Uğrayan Müşteri Sayısı}}{\text{Kesinti Yaşayan Toplam Saha Sayısı}}$$

Çoğu ülkede kamu elektrik sistemi, elektrik santrallerine ve diğer güç kaynaklarını elektrik tüketicilerine bağlayan ve aynı zamanda komşu ülkelere de bağlanabilen tek bir ağ (şebeke sistemi) bulunmaktadır. Dağıtım şebeke sistemleri aşağıdaki komponentleri içermektedir (Ward, 2013: 103–04):

- Havai hatlar
- Yeraltı kabloları
- Havai hatların ve yeraltı kablolarının birbirine bağlı olduğu anahtarlama tesislerine sahip alt istasyonlar (şalt sahaları)
- Farklı voltajlarda çalışan ağ parçalarını bağlamak için transformatörler
- Elektriksel koruma ve ölçüm cihazları
- İletişim ve kontrol sistemleri
- Kontrol merkezleri


Şekil 21: Elektrik Enerjisi Dağıtım Ağı



Kaynak: Ortmeyer, 2017.

İletim hatları enerji santrallerini ve dağıtım sistemini birbirine bağlamaktadır. Üretim ve iletim sisteminin temel amacı, şebeke içerisindeki her ana yük noktasına yeterli elektrik enerjisini kesintisiz şekilde sağlamaktır. Kısa devreler veya diğer ciddi kusurlar, genellikle iletim sistemindeki elektriksel arızalara ve bunun sonucunda enerji kesintilerine neden olmaktadır (J. Wang, Zhao, Guo ve Li, 2018: 701). Arıza teşhisinin başarısı, güç kaynaklarının güvenilir ve sağlıklı çalışmasında oldukça önemlidir. Uzman sistemlerin arıza teşhisi konusundaki uygulamaları başarılı sonuçlar vermektedir (Mohamed ve Rao, 1995: 1).

Şekil 22: Geleneksel Güç Şebekesi & Akıllı Şebeke




Kaynak: Ibrahim, Dong ve Yang, 2020: 3.

Akıllı şebeke, yenilenebilir enerjileri kullanan tedarikçilerin enerji üretimini dinamik şekilde tüketicilerin, akıllı fabrikaların veya akıllı evlerin enerji talebiyle eşleştirmektedir. Kısa vadeli enerji depolama işlemini sağlayarak tamponlama yapmaktadır. Akıllı şebekede, enerji tüketicileri ve tedarikçileri aynı olabilmektedir (Stock ve Seliger, 2016: 539). Akıllı Şebeke Endüstri 4.0' da (Smart Grid Industry-SGI 4.0) akıllı şebeke sistemleri, veri toplama, analiz için bilgisayarlarla iletişim kurma ve gerekli işlemler için operatörlere tavsiyelerde bulunma yeteneklerine

sahiptir. SGI 4.0' ın kendini bilişi, kendini optimize edişi ve kişiselleştirmesi; elektrik şebekesinin farklı sistemlerinin bağımsız olarak veya yüksek kaliteli elektrik enerjisi dağıtımı için daha az insan müdahalesiyle çalışmasını sağlamaktadır. SGI 4.0' da sistemler, çalışanlar, müşteriler ve diğer paydaşlar birbirine bağlanacak ve yakın iş birliği içinde olacaktır. Sistemler, çalışanlar ve müşteriler arasında sürekli ve otonom bilgi ve veri alışverişi yoluyla gerçekleşen gerçek zamanlı etkileşim, enerji endüstrisinde güç verimliliğini ve rekabet gücünü büyük ölçüde artırıp; oldukça esnek bir enerji üretim modelini oluşturacaktır (Fischetti, Sartor ve Zanette, 2015: 50). SGI 4.0 geleneksel elektrik üretim yöntemlerini değiştirmekle kalmayıp; içsel karmaşıklık ve dışsal tahmin edilemeyen olaylar açısından gelecekteki gelişmelere rehberlik edecektir. Bununla birlikte, akıllı şebekedeki çok işlevli ve otonom donanımlar büyük hacimlerde veri yığınlarını üretmektedir. Mevcut bilgi alışverişi ortamları ve yaklaşımları, atipik olaylar nedeniyle daha fazla belirsizliğe yol açan sistemlerin içsel karmaşıklığını çarpıcı biçimde fazlalaştıran büyük veri yığınlarını kullanmak için uygun değildir (Benysek, Kazmierkowski, Popczyk ve Strzelecki, 2011: 55–56). Öte yandan, SGI 4.0' daki iletişim gereksinimleri, veri hızları, bant genişliği, gecikme süresi, verimlilik, ölçeklenebilirlik, esneklik ve güvenilirlik kriterleri bakımından artmaktadır. Bu nedenle, güç üretimi ve dağıtım süreci boyunca kaynaktan hedefe gerçek zamanlı ve güvenilir bilgi sağlamak, akıllı şebekede geleneksel olmayan bilgi ve iletişim teknolojisi altyapısını gerektirmektedir (Faheem ve diğerleri, 2018: 5).

Şekil 23: Endüstri 4.0' ın Akıllı Şebeke İçin Temel İletişim ve Servis Mimarisi




Kaynak: Faheem ve diğerleri, 2018: 6.

Faheem ve arkadaşları, Endüstri 4.0 bağlamında uluslararası standartlara ve bilgi teknolojilerine sahip kritik ve akıllı şebeke bileşenleri konusunda kapsamlı bir araştırma yapmıştır. Farklı akıllı şebeke uygulamalarına, yararlarına, özelliklerine ve gereksinimlerine genel bir bakış sunulmuştur. Akıllı şebekelerde kullanılan kablolu ve kablosuz iletişim teknolojilerinin faydaları ve özelliklerine değinilmiştir (Faheem ve diğerleri, 2018: 1). Enerji tüketiminin yoğun olduğu saatlerde, enerji ihtiyacı değişimleri yaşanmış olan altyapıya dayalı olarak güç şebekelerini (Power Grid-PG) zorlamaktadır. Bu durum elektriğin kesilmesine veya güvenilirlikle ilgili kalite sorunlarına neden olmaktadır. Değişen talebi karşılamak amacıyla farklı enerji kaynaklarına ihtiyaç duyulmaktadır. Ortalama elektrik enerjisi talebi, en yüksek seviyede gerçekleşen talepten önemli ölçüde düşük olduğunda bu yaklaşım yetersiz kalmakta ve ekonomik olmamaktadır (Faheem ve diğerleri, 2018: 3). Ev enerji yönetimi, ölçüm altyapısı, sayaç okuma, durumsal farkındalık, talep yönetimi, trafo merkezi otomasyonu, kesinti yönetimi, dağıtım yönetimi, dağıtım üretimi, SCADA, varlık yönetimi, sayaç veri yönetimi, iletim hattı izleme, dağıtılmış enerji kaynakları ve depolama, şebeke için araç, elektrikli araçlar, program ve aygıt yazılımı güncellemesi akıllı şebeke uygulamalarının hizmet kalitesi gereksinimleri arasında bulunmaktadır (Faheem ve diğerleri, 2018: 7).

J. Wang ve arkadaşları yenilenebilir enerji ve gelişmekte olan teknolojileri destekleyerek güç sistemi güvenilirliğini artırmak için yeni bir yaklaşımı hedeflemektedir. Güç sistemleri, üretim, iletim ve dağıtım sistemi olarak üç ana kategoride sınıflandırılmaktadır. Araştırmada, güç sistemi güvenilirliğini araştıran sistem, kurum, araştırmacı ve ortakların kimler olduğu, tartışılan ve popüler konuların neler olduğu ve güç sistemi güvenilirliğinin gelecekteki gelişiminin nasıl olacağı konularına yoğunlaşmıştır. 1990-2015 yılları arasında yapılan araştırmalara bakıldığında 5960 makaleden % 44' ünün üretim sistemi güvenilirliğini, % 34' ünün dağıtım sistemi güvenilirliğini incelediği gözlenmektedir. Web of Science'dan elde edilen son 25 yıla ait ilk 10 üretici ülkeye ait 4525 yayın bulunmaktadır. İlk iki üretici ülke sırasıyla ABD ve Çin' dir (J. Wang, Zhao, Guo ve Li, 2018: 701-02).

Şekil 24: Dağıtım Sistemi Güvenilirliği Alanında Yoğun Çalışma Yapılan



Kaynak: J. Wang, Zhao, Guo ve Li, 2018: 702.

Tablo 4: 1991–2005 ve 2006–2015 Aralıklarında Yapılan Araştırmalar

1991–2005		2006–2015	
Anahtar Kelime	Frekans	Anahtar Kelime	Frekans
Güç Sistemi Güvenilirliği	90	Güç Sistemi Güvenilirliği	343
Dağıtım Sistemi	85	Optimizasyon	253
Optimization	43	Biyoenerji	237
Monte Carlo Simulasyonu	36	Dağıtık Üretim	200
Güç Kalitesi	34	Rüzgar Enerjisi	194

Genetik Algoritma	31	Genetik Algoritma	143
Biyoenerji	22	Yenilenebilir Enerji	123
Maliyet	17	Maliyet	79
Kullanılabilirlik	17	Performans	75
Ağ (Şebeke)	5	Belirsizlik	75

Kaynak: J. Wang, Zhao, Guo ve Li, 2018: 708.

Elektrik endüstrisindeki enerji santrallerinin ve iletim hatlarının güvenilirliği, taleplerin karşılanması için hayati öneme sahiptir. Zamanında bakım, arızaları azaltma ve yüksek maliyetli üretim kesintilerinin önlenmesinde oldukça önemlidir. Enerji tüketimi, ülkelerin gelişimi ve artan dünya nüfusu neticesine giderek artmaktadır. Enerji üretimi bu ihtiyacı sorunsuz karşılamalıdır. Bu nedenle, enerji santrallerinin, rüzgar ve güneş santrallerinin güvenilirliği son derece önemli olup; ekipman bakım yönetimi ekonomi açısından kritiktir. Elektrik güç sistemlerinde ekipman bakım yönetimi; bakım için üretim ünitesinin ne zaman durdurulacağı, ne zaman çalıştırılacağı ve ne kadar kaynağın (insan, makina, ekipman...) atanacağı konularıyla ilgilenmektedir. Kararlar kompleks şartlarda, kaynak kullanılabilirliği, talebin karşılanması ve güvenilirlik eşikleri gibi kısıtlamalar altında ele alınmaktadır. Kararı iyileştirmek için kullanılan yöneylem araştırmasının en önemli katkısı bakım planlaması ve çizelgeleme problemleri için optimizasyon tekniklerinin uygulanmasıdır. Bu problemler, farklı teknisyenler arasındaki atamaları ve problem parametrelerindeki belirsizliği göz önünde bulundurarak, basit teknisyen-ekipman atamalarından karmaşık problemlere kadar uzanmaktadır. Enerji endüstrisi, üretim, iletim ve dağıtım olmak üzere üç ana faaliyeti yürütmektedir. Bakım, düzeltici ve önleyici olmak üzere iki kategoriye ayrılmaktadır. Düzeltici bakım, kesinti sonrasında gerçekleştirilmekte olup; önleyici bakım, arıza olasılığını azaltmak amacıyla önceden belirlenen zaman aralıklarında veya öngörülen kriterlere göre gerçekleştirilmektedir (Froger, Gendreau, Mendoza, Pinson ve Rousseau, 2016: 695-96).

2.2. FARKLI SEKTÖRLERDE BAKIM VE ARIZA ÇALIŞMALARI


Öngörülü bakım sayesinde üretim esnekliği, ürün kalitesi, enerji verimliliği ve gelişmiş ekipman hizmetini sağlamaktadır (Preuveneers ve Ilie-Zudor, 2017: 287), (Kamble ve diğerleri, 2018: 417). Veri bilimi sayesinde, makinelerde, teçhizatlar ve

süreçlerde gerçekleşecek anormal davranışlar ve arızalar etkin bir şekilde tahmin edilebilmektedir. Ekonomik kayıplara ve güvenlik sorunlarına neden olan bu durumlara engel olunmaktadır (Diez-Olivan ve diğerleri, 2019: 92).

Sung çalışmasında endüstriyel AI mimarisinin CNC makinesinin takım tezgâhı miline uygulanmasına yer vermiştir. Takım tezgâh milinin çalışma durumu yapay zeka tabanlı gerçek zamanlı izlenmiş ve performans tahmini için çözümler üretilmiştir. Çalışma, bakım maliyetlerini en aza indirmek; aynı zamanda ürün kalitesini optimize etmek için tasarlanmıştır (Sung, 2018: 41; Lee, Davari, Singh ve Pandhare, 2018: 22).

Durum bazlı bakım (CBM), bozulma ve normal davranıştan sapma bilgilerine dayanan bir bakım planını öngörmeyi amaçlamaktadır. Belirli bir sistemin durumu gözlenirken; bir dizi izleme cihazı ve sensör dikkate alınmaktadır. Sensörleri kullanarak ekipmanın akıllı şekilde izlenmesi, operasyonel hataların fiziksel sinyallerde karakterizasyonunu içeren ilgili verileri elde etmek için önemlidir. Akustik ve ultrasonik sensörler, ivme ölçerler, akım ölçümleri veya ısı çiftler genellikle bu amaç için kullanılmaktadır. Bu verilere ek olarak, ortam koşulları ve sıcaklık, basınç veya nem gibi verilerden, modelleme sürecini zenginleştirmek için oldukça yararlı bilgiler sağlanmaktadır. Bu tür bilgilerden, kritik bir hataya yol açabilecek potansiyel eğilimleri keşfetmek için belirli KPI' ler hesaplanmakta ve analiz edilmektedir. Amaç maksimum güvenilirliğin sağlanması olduğundan; her türlü faydalı verinin eş zamanlı bir araya getirilerek, varlıkların doğru çalışmasını sağlamak için gerekli öngörülerini sağlayacak ve izleme yeteneklerine sahip uygun bir CBM sistemi benimsemektir (Diez-Olivan ve diğerleri, 2019: 98).

Şekil 25: Elektrik Enerjisi Dağıtım Ağı Siber Fiziksel Sistem Mimarisi




Kaynak: Sridhar, Hahn ve Govindarasu, 2011: 211.

Basurko ve Uriondo denizcilikte kullanılan dizel motorların bakım işlemleri ve arıza tahmini için yapay sinir ağı tekniğini kullanırken (Basurko ve Uriondo, 2015: 404); Diez-Olivan ve arkadaşları kısıtlı k-means, bulanık mantık ve lokal aykırı gözlem belirleme (LOF) tekniklerini kullanmaktadır (Diez-Olivan, Pagan, Sanz ve Sierra, 2017: 241). Baqqar elektrik motorlarında dişli kutularına ait durum izleme süreci için genelleştirilmiş regresyon sinir ağı (GRNN), geri yayımlı yapay sinir ağları (BPNN) ve uyarlamalı ağ tabanlı bulanık çıkarım sistemini (ANFIS) kullanmaktadır (Baqqar, 2015: 122-43). Safizadeh ve Latifi rulman yataklarının durum bazlı izleme ve tanı koyma işlemi için temel bileşen analizini (Principal Component Analysis-PCA) kullanmaktadır (Safizadeh ve Latifi, 2014: 1). Mosallam ve arkadaşları akü ve turbofan motorların kalan yararlı yaşamları (RUL tahmini) için kNN ve Discrete Bayesian Filter tekniklerini kullanmıştır (Mosallam, Medjaher ve Zerhouni, 2016: 1037). L. Guo ve arkadaşları yatak ömrü için kalan yararlı yaşamları tahmininde tekrarlayan sinir ağını (RNN) kullanırken (L. Guo, Li, Jia, Lei ve Lin, 2017: 98); Cristaldi ve arkadaşları orta ve yüksek gerilim devre kesicilerin kalan yararlı yaşamlarının tahmininde yapay sinir ağı ve istatistiksel yaklaşımları kullanmıştır (Cristaldi, Leone, Ottoboni, Subbiah ve Turrin, 2016: 1). Seidgar ve arkadaşları üretimde yaşanan aksaklıkların azaltılması için bakım programı ve iş sırası için sinir

ağlarıyla iyileştirilmiş çok amaçlı algoritma kullanmıştır (Seidgar, Zandieh ve Mahdavi, 2017: 16; Diez-Olivan ve diğerleri, 2019: 99).

Beşikçi ve arkadaşları tarafından yapılan çalışmada; gemilerde kullanılacak ve gemi yakıt tüketimini yapay sinir ağı yöntemiyle gerçek zamanlı tahmin edebilecek modele ait karar destek sistemi (Decision Support Systems-DSS) geliştirilmiştir. DSS, karar vericilerin yarı yapısal ve yapısal olmayan problemleri çözmek için dijital verileri, modelleri ve diğer bilgileri kullanmasına yardımcı olabilecek bilgisayar tabanlı bilgi sistemidir. YSA' nın amacı, gemilerin günlük yakıt tüketimine dair bilgi sağlayan operation data-‘noon data’ kullanarak çeşitli işletim koşullarında gemi yakıt tüketimini tahmin etmektir (Bal Beşikçi, Arslan, Turan ve Ölçer, 2016: 393–94).

Şekil 26: Endüstriyel Sektörler ve Tanımlayıcı Öngörü İçin Çözümler



Kaynak: Diez-Olivan ve diğerleri, 2019: 96.

2.3. ELEKTRİK DAĞITIM AĞI ARIZALARINA DAYALI ÇALIŞMALAR

2.3.1. Meteorolojik Faktörlere Dayalı Çalışmalar

Elektrik dağıtım ağlarında meydana gelen arıza ve kesintileri akıllı şebeke ekseninde modellemek zorlu bir görevdir. İklim değişiklikleri ve insan faaliyetleri gibi nedenler, güç sistemlerini çeşitli düzensizliklere maruz bırakabilmektedir. Örneğin, yıldırım veya kesilmemiş ağaçlar iletim hatlarında kısa devre arızalarına neden olabilmekte; kar ve depremler elektrik direklerini ve trafo merkezlerini tahrip

edebilmektedir. Sıcak havalarda klima kullanımı artmaktadır. Önemli spor ve politik olaylar, güç yüklerinin türünü değiştirebilmektedir. Bu faktörler, güç sistemlerinin işletilmesi ve yönetilmesindeki karmaşıklığı arttırmaktadır. İletim hatları arızalarının tespiti ve konumu ile ilgili olarak He ve Zhang, Markov ve grafik teorik modeller aracılığıyla bağımlılığı ve belirsizliğini belirleyebilen merkezi olmayan bir plan önermektedir (He ve Zhang, 2011: 342). Arıza teşhisi, modelleme ve tanıma için akıllı yöntemler, yapay sinir ağları, bulanık mantık, bulanık petri ağları, destek vektör makineleri, karar ağaçları ve veri füzyon teknikleri kullanılmaktadır (De Santis, Rizzi ve Sadeghian, 2018: 267–68).

Enerji altyapılarının zarar görmesi, sosyal sistemler, ekonomiler ve ekolojik sistemler üzerinde ciddi etkilere sebep olabilmektedir. Elektrik hizmet sektöründeki iklim riski yönetimi kritik öneme sahiptir. Elektrik hizmetleri, toplumsal, kültürel ve ekonomik hizmet sağlayan kamu değeridir. İyileştirilmiş iklim riski yönetimi sayesinde önlenen elektrik hizmet aksamalarına bağlı olarak kamu hizmetlerinin iklim değişiklik riskine karşı direnci artacaktır. Elektrik hizmetlerinin, hizmet ettiği insan gruplarıyla benzersiz bir finansal bağımlılığı bulunmaktadır. Büyük bir iklim değişikliğinin etkisi, müşterilerde finansal stres artışlarına yol açabilmektedir. Ayrıca elektrik hizmetleri endüstrisi, iklim değişikliği etkileri nedeniyle çok çeşitli tehditlere maruz kalan karmaşık bir altyapıya sahiptir. Gerlak ve arkadaşlarının elde ettikleri bulgular; iklim değişikliği etkileri, risk değerlendirmesi, paydaş katılımı-sektörler arası işbirliği ve uyum eylemleri olmak üzere dört maddeden oluşmaktadır. Artan sıcaklıklar enerji endüstrisi için iklim risk değerlendirmelerinin temel bileşenidir. Sıcaklık artışları mevsimsel enerji talebini değiştirerek; marjinal çalışma sıcaklıklarına sebep olmaktadır. Bu durum kullanılan üretim ve iletim altyapısının arıza güvenilirliğini azaltmaktadır. Yüksek sıcaklıklar ayrıca yangın riskini de artırmaktadır (Gerlak, Weston, McMahan, Murray ve Mills-Novoa, 2018: 12–13).

Coughlin, literatürde iklim değişikliği ve enerjinin planlaması çalışmalarında kullanılan özel fiziksel etkiler ve nicel analizler arasındaki ilişkinin sistematik şekilde incelenmediğine vurgu yapmıştır. Çalışmada elektrik sisteminin fiziksel hava riskine karşı hassasiyeti ve belirsizlikler açısından bu risklerin zaman içinde nasıl değişebileceğinin tespiti için iklim modelleri konusunda tespitler yer almaktadır (Coughlin ve Goldman, 2008: 9). Larsen ve arkadaşları, hükümet politikaları, akıllı

şebeke teknolojilerinin yayılımı ve şiddetli hava olaylarındaki artışın, ABD ve dünya genelinde elektrik güç sistemlerinin güvenilirliğine dair çalışmaları artırdığını vurgulamıştır. Olumsuz hava koşulları, ekipman arızaları, insan hataları, bitki örtüsü, yaban hayatı ve diğer bilinmeyen faktörlerin enerji kesintilerine neden olduğuna değinilmiştir. ABD Enerji Bakanlığı, olumsuz hava koşullarının güç kesintilerinin en önemli nedeni olduğunu bildirmektedir (Larsen ve diğerleri, 2018: 1256).

Yongxing ve arkadaşları yaptıkları çalışmada çeşitli meteorolojik faktörleri göz önünde bulundurarak; elektrik hattı arıza olasılığını hesaplamıştır. Aktarım hatlarının gerçek zamanlı arıza olasılığının hesaplanması, online risk değerlendirmesinin ve güç sisteminin gerçek zamanlı güvenilirlik hesaplamasının önemli bir parçası konumundadır. Yapılan çalışmada öncelikle çeşitli faktörlerin bulanık üye fonksiyonu incelenmiştir. Belirsiz değerlendirme kuramı, her bir katmanın ağırlık katsayısını belirlemek için bulanık değerlendirme yöntemiyle birleştirilmiştir. Sonrasında kurulan modeli simule etmek için gerçek veriler toplanmış ve model gerçek hava durumu verileri ve güç hattı arıza olasılığı verileriyle doğrulanmıştır. Sonuçlar, önerilen yöntemin böyle bir olayın önlenmesinde etkili olduğunu göstermiştir. Çalışmadaki bulgular ve yöntem şu şekilde sıralanmaktadır. Tel üzerinde biriken buz kütlesi, tasarımda izin verilen eşiğin üzerine çıktıktan sonra, buzlanma kalitesi ve rüzgâr basıncı alanının artmasından dolayı mekanik arıza ve elektrik arızasına neden olabilmektedir. Mekanik hatalar, metal hasarı, tel kırığı, izolatör zincir kırığı veya çatlak, temel çökmesi, kule hasarı, vb. nedenlerle oluşmaktadır. İletim hattı arıza olasılığı ile ilgili güncel araştırmalar ağırlıklı olarak hava durumu ile ilgili güvenilirlik değerlendirmesini, işletme durumunun değerlendirmesini ve hava şartlarına bağlı risk değerlendirmesini içermektedir. Çalışmada meteorolojik faktörlerle birlikte havai iletim hatları için gerçek zamanlı arıza olasılığı değerlendirme yöntemi sunulmaktadır. İletim hattının gerçek zamanlı arıza olasılığı, izolatörlerin, iletkenlerin, paratonerin, kule ve toprak telinin gerçek zamanlı durumu ile yakından ilgilidir. Genellikle iletim hattı izolatörleri, iletkenler, paratoner, kule ve topraklama tellerini izlemek mümkün değildir. Bu nedenle iletim hattı uzun ise hat üzerinde belirli izleme noktalarını seçmek gerekmektedir. Her bir izleme noktasının sonuçları, ilgili kule ve kuleye bağlantılı hattı işaret etmektedir. Çalışmada her bir izleme noktasının gerçek zamanlı arıza verilerinin oranı hesaplanmıştır (en düşük skora sahip

bileşenlerin verileri). Sonrasında her bir izleme noktasının değerlendirme sonuçları birleştirilmiştir. Bir iletim hattının i. çevrim içi izleme noktasının gerçek zamanlı arıza olasılığını hesaplaması şu şekildedir: Geçmiş verilere ve iletim hattının spesifikasyonuna göre her bir online izleme verisinin hesaplama modeli oluşturulmuştur. Uzman görüşleri ve yargı sonuçlarının farkı dikkate alınarak belirsiz rasyonel sayı yöntemi ile her bir endeksin ağırlıkları belirlenmiştir. Sonrasında i. çevrimiçi gözlemin bulanık gerçek zamanlı güvenilirlik olasılığı bulanık hiyerarşi kapsamlı değerlendirme yöntemi ile normalize edilerek iletim hattının gerçek zamanlı arıza olasılık değeri hesaplanmıştır (Yongxing, Yufang ve Hongyu, 2017: 231-02).

Tablo 5: Meteorolojik Olayların Arıza Olasılıkları

Meteorolojik Arıza Olasılığı Verileri	
Faktörler	Arıza Olasılığı
Buzlanma kalınlığı	0,041
Rüzgar	0,0081
Yağmur	0,0037
Kar	0,044
Yıldırım	0
Tayfun	0

Kaynak: Yongxing, Yufang ve Hongyu, 2017: 234.

Yapılan çalışmada iletim hattı arıza olasılığına yol açan temel faktör buzlanmadır. İzolatör sızıntı akımının kabarması ve kulenin dikey yükü de buzlanma nedeniyle oluşmaktadır. Bu nedenle, buzlanma kalınlığı doğrudan iletim hattının hata olasılığı ile ilgilidir (Yongxing, Yufang ve Hongyu, 2017: 235).

Napolitano, bünyesinde bir dizi hat, trafo istasyonları ve aşırı gerilim koruma cihazı içeren bir orta gerilim dağıtım şebekesinin yıldırım performansını değerlendirmek için Monte Carlo tekniğini uygulanmıştır. Hava hattı dağıtım besleyicilerinde yıldırım kaynaklı transformatör arızalarının sıklığı, özellikle yüksek bir keraunik seviyede (gök gürültüsünün sesli olarak algılandığı alanda yıldırım aktivitesini tanımlayan sistem) olan alanlarda endişe oluşturabilmektedir. Bu nedenle, kesinti oranının talep edilen eşiğin altında olması için özel çalışmalar gerekmektedir. Çalışma, Novo Hamburgo (Brezilya) yakınlarında bulunan üç fazlı dağıtım orta gerilim besleyicisinin yıldırım performansının değerlendirilmesine ait yöntemin


geliştirilmesini kapsamaktadır. Kullanılan Monte Carlo tekniği, büyük ağların analizi için hesaplama iş yükünü azaltmak amacıyla tasarlanmış ve uygulanmış sezgisel yöntem içermektedir (Napolitano ve diğerleri, 2016: 60).

Anaya ve Pollitt yaptıkları araştırmada, hava değişkenlerinin Arjantin, Brezilya, Şili ve Peru'daki elektrik dağıtım şirketlerinin verimliliği üzerindeki etkisini incelemiştir. Çalışma 1998-2008 yılları arasında enerji dağıtım pazarının yüzde 90'ından fazlasını oluşturan 82 firma baz alınarak gerçekleştirilmiştir. Hava durumunun üretim fonksiyonuna etkisi ve verimsiz döneme etkisi olarak iki yaklaşım değerlendirilmiştir. Birinin diğeri üzerindeki etkinliği iç içe geçmiş modeller kullanılarak belirlenmiştir. Hava durumu verileri 429 meteoroloji istasyonlarından ve 3423 koordinat olarak NASA' dan toplanmıştır. Elektrik düzenleyicileri, hava durumunun dağıtım şebekelerinin işletme servislerini ne şekilde etkilediğini dikkate almaktadırlar. Olumsuz hava koşulları nedeniyle karşılaşılabilecek maliyet etkisini sağlıklı bir şekilde değerlendirmek için bu koşulların bilinmesi oldukça önemlidir. Dağıtım şirketlerinin, sistemlerinde arıza riskini azaltmak için hava değişkenlerine ait verileri toplaması, analiz etmesi ve şebekeyi hizmet alanının özel durumlarına uyarlaması gerekmektedir. Arızalara zamanında müdahale, dağıtım sistemi güvenilirliğinin iyileştirilmesi için önemlidir. Çalışmada, diğer araştırmalarla uyumlu olarak, hava durumuna ait çevresel değişkenlerin, elektrik dağıtım firmalarının verimliliğinde önemli bir rol oynadığı tespit edilmiştir. Hava koşullarının modellere dahil edilmesiyle, uluslararası karşılaştırmalar yapılırken; elektrik dağıtım yönetmeliğine daha entegre bir yaklaşım getirilmektedir. Elektrik şebeke bileşenleri meteorolojik koşullara karşı oldukça hassastır. Elektrik kesintileri, hava olaylarının en belirgin sonucudur ve en maliyetli olanlarıdır. ABD Enerji Bakanlığı' na göre, çoğu dağıtım kesintileri, yetersiz bakım ve kötü hava koşullarına bağlıdır. Havai hatlar, hava koşulları, yaban hayatı, düşmüş ağaçlar, vb. en güçlü dış etkenlerle yüzleşmektedir. Yıldırım, şiddetli rüzgâr, aşırı sıcaklıklar, kar, buz, fırtınalar ve yağmur, havai hatların normal işlevini etkilemektedir (Anaya ve Pollitt, 2017: 1078).

ABD' de kar ve buz fırtınalarının, şebekelere en çok zarar veren hava olaylarından biri olduğu kabul edilmiştir. Dağıtım sistemlerinde geniş hizmet kesintilerine ağaç devrilme olaylarının neden olduğu gözlenmiştir (Gonen, 2011: 694). Pabla yıldırım ve fırtınalı günlerin, yüksek gerilim ve dağıtım sistemlerinde meydana

gelen tüm hataların yaklaşık üçte birinden sorumlu olduğunu ve bu hataların yaklaşık % 75-80' inin geçici olduğunu belirtmektedir (Pabla, 2012). Aydınlatma hasarları, dağıtım ekipmanına verilen en yüksek maliyetli hasarlardır. Keener 1997 yılında yaptığı çalışmada, elektrik kesintilerinin yaklaşık %90' ının yaz aylarında gerçekleşen yıldırımlardan kaynaklandığını ve yıl boyunca elektrik kesintilerinin gök gürültülü fırtınaya bağlı yıldırım ve rüzgâr hasarı nedeniyle olabileceğini belirtmektedir (Anaya ve Pollitt, 2017: 1079).


Şekil 27: Şebeke Arızaları ve Müşterilere Etkisi



Kaynak: ABD Enerji Bakanlığı (DOE), 2016. Akıllı Şebeke Yatırım Hibe Programı Final Raporu. Anaya ve Pollitt, 2017: 1080.

Hines ve Talukdar ABD' de 1984-2006 yılları arasında yaşanan elektrik kesintisi üzerine yaptıkları çalışmada, kesintilerin %43,6' sının hava olaylarına bağlı olduğunu tespit etmiştir (Hines, Apt ve Talukdar, 2008: 1). Mills 2012 yılında yaptığı çalışmada, ABD Enerji Bakanlığı'ndan 1992–2011 dönemine ait elde ettiği verilerle, arıza sayılarının %66 sının ve arızadan etkilenen müşteri sayılarına göre %78 inin hava durumuna bağlı olduğunu bulmuştur (Mills, 2012: 1). Toplam yağmur, maksimum mutlak sıcaklık, minimum mutlak sıcaklık, nem ve yıldırım oranı olarak toplam beş hava durumu analiz edilmiştir (Anaya ve Pollitt, 2017: 1080-86).

Şekil 28: Elektrik Kesintisi Maliyetleri (2007–2016)



Kaynak: ABD Enerji Bakanlığı CEIDS (2001), BLS (2016). Anaya ve Pollitt, 2017: 1081.


Geniş alanlarda meydana gelen kesintilerinin en önemli nedenleri, hatalar, yanlış davranışlar, çevresel etkiler ve sabotaj sorunları olarak sıralanabilmektedir. Bu faktörlerin ortaya çıkma olasılıklarına ait hesaplama oldukça zordur. Akdeniz ve Bağrıyanık yaptıkları çalışmada, güç sistemi hasar görebilirlik analizi için operasyonel ve operasyonel olmayan indeksleri içeren kapsamlı bir metod önermektedir. Güç sistemlerinin operasyonel performansı, terör saldırıları ve olumsuz hava koşulları için bireysel indeksler tanımlanmıştır. Her iletim sistemine ait toplam güvenlik açığı indeksi elde etmek için bir bulanık çıkarım sistemi kullanılmıştır. Kanada'da 20 yıllık verilere dayanarak ve güç sistemi arıza istatistikleri incelenerek yapılan araştırmaya göre; başarısızlıkların önemli bir kısmı yani kesintilerin yaklaşık %33' ü olumsuz hava koşulları nedeniyle gerçekleşmiştir. Benzer şekilde Türk İletim Sistemindeki hat kesintilerinin büyük kısmı meteoroloji faktörlerine dayanmaktadır. Türkiye'de 2014 ve 2015 olarak 2 yılda gerçekleşen 400 kV'lık hat arızalarının %43' ü ve 154 kV'luk hat arızalarının %48' i meteorolojik faktörler sonucunda meydana gelmiştir (Akdeniz ve Bağrıyanık, 2016: 436-39).

Kumar ve arkadaşları fotovoltaiik (PV) güç üretim öngörüsü için yapay sinir ağları (ANN) ve güç çıkışını tahmininde Uyarlamalı Nöro-Bulanık Çıkarım Sistemi (ANFIS) tabanlı model üzerinde çalışmıştır. Tahmin modeli, geçmiş veriler kullanılarak eğitilmiştir. Modelin sonuçları doğrulanmış ve PV güç üreten istasyonun veri seti dikkate alınarak karşılaştırılmıştır. Yapay zekâ tabanlı yöntemler doğal olarak

esnek ve doğrusal olmayan problemlerin çözümü yeteneğine sahiptir. Önceki herhangi bir modelleme bilgisine ihtiyaç duymamaktadırlar. Çalışma prosedürleri girdi verilerini doğru bir şekilde sınıflandırıp; ilgili çıktı değerleri ile ilişkilendirmektir. Çalışmada küresel yatay ışıınım, küresel dađınık ışıınım, ortam sıcaklığı, yağış, rüzgâr hızı, hava basıncı, güneşlenme süresi, bađıl nem ve yüzey sıcaklığı olarak dokuz çevresel parametre dikkate alınmıştır. Diđer bir ađ, küresel yatay ışıınım, küresel dađınık ışıınım, ortam sıcaklığı ve yüzey sıcaklığı gibi dört girdi göz önünde bulundurularak tasarlanmıştır. Yapay sinir ađında ileri-geri beslemeli yayılım algoritması kullanılmıştır (Kumar ve Kalavathi, 2018: 796–98).

Ward çalışmasında, hava olaylarının Avrupa ve Kuzey Amerika' da bulunan şebeke sistemleri üzerindeki etkilerini incelemektedir. Yüksek gerilim iletim şebekeleri üzerindeki etkilerin, düşük voltaj dağıtım şebekeleri üzerindeki etkilerden farklı olduđu ve genellikle en önemli hava olayının yüksek rüzgâr olduđunu tespit etmiştir. Çalışmada hava olaylarının etkilerini hafifletebilecek iyileştirici tedbirler açıklanmıştır. Şebeke sistemlerindeki arızaların birçođu hava olayları ile ilgili olduđundan; hava durumu modellerinde meydana gelen deđişiklik, şebeke sistemi arızalarının sıklığını deđiştirebilmektedir. Bu durum tüketiciler açısından elektrik arzının güvenilirliğini ve şebeke sisteminin bakım maliyetini etkileyebilmektedir. Güvenilirlik standartları genellikle hava koşullarını göz önünde bulundurmamaktadır. Hava olaylarına ek olarak, ekipman arızası, insan hatası, kasıtlı hasar, depremler, tsunami veya jeomanyetik fırtınalar gibi birçok nedenden dolayı arızalar ortaya çıkabilmektedir. Avrupa ve Kuzey Amerika' da hava olayları, bireysel hataların önemli bir yüzdesi iken; tüketicilere arz kaybını yaşıatan olayların ana nedenidir (Ward, 2013: 103–05).

Şekil 29: Güneybatı İngiltere' de İletim Sistemindeki Arızalar



Kaynak: Ward, 2013: 106.

Velilla ve arkadaşları yaptıkları çalışmada sıcaklık, bağıl nem ve ışınlam verileri ile yapay sinir ağı modelini eğitmiş ve test etmiştir. Bu modeller girdi değişkenlerine göre duyarlılık analizine tabi tutulmuştur. Elektrik enerjisi açısından bakıldığında; daha yüksek bağıl nem, daha yüksek sıcaklıklar ve daha düşük ışınlama koşulları altında organik esnek modül için daha iyi performans elde edilmiştir. Çalışma, fotovoltaik teknolojilerin performanslarının farklı çevresel koşullarda tahmin edilmesine yardımcı olmuştur (Velilla, Valencia ve Jaramillo, 2014: 260).

İletim veya dağıtım hattı üzerindeki ortalama sıcaklığın artması ekipmanın maksimum güç oranını sınırlandırmakta veya azaltmaktadır. Böylece enerji kayıpları artmaktadır. Ağaçlar bir havai hattın altında büyüyorsa ve yakın zamanda kesilmemişse, sıcak günlerde çok sayıda flashover hata riski bulunmaktadır. Şiddetli rüzgârlar, hatlara doğru üflenilen molozlar ve ağaçlar ve yardımcı direklerin ya da iletim kulelerinin bükülmesinin neden olduğu hatalar hatların hasar görmesine yol açabilmektedir. Hines ve arkadaşlarının Kuzey Amerika' daki arz kayıp analizinde elde ettikleri tespitlere göre olayların yaklaşık yarısının ana nedeni rüzgâr, fırtına ve kasırgadır (Hines, Apt ve Talukdar, 2009: 5249). Reed çalışmasında ABD' nin Pasifik Kuzeybatısındaki kış fırtınalarının etkisini incelemiştir. Elde edilen bulgular şunlardır (Reed, 2008: 138):

- Fırtına ve kasırga olayları sonucunda dağıtım şebekeleri, iletim şebekelerinden daha yüksek oranlarda arızaya maruz kalmaktadır. Bu nedenle yaşanan kesintilerin çoğunluğu dağıtım ağlarına verilen zarardan kaynaklanmaktadır. Dağıtım ağlarının arızalarının yarısından fazlasına ağaçlar neden olmaktadır.
- Hasar, en şiddetli rüzgâr hızının karesi ile ilişkilidir.

Şebeke kuleleri, direkler ve trafo yapıları tasarlanırken; tasarımın yaşanabilecek maksimum rüzgâr şiddetine uygun olması ve bu yapıların bakımlarının düzenli şekilde yapılması gerekmektedir. Ağaçların neden olduğu arızalar; havai hatların ormanlık alanlara girmeyecek şekilde yönlendirilmesi, ormanlık alanlardaki havai hatların yeraltı hatlar ile değiştirilmesi, rüzgârda sallanan ağaçlarla temasın önlenmesi için çıplak iletkenlerin yalıtımlı iletkenlerle değiştirilmesi, bu alanlarda orta ve düşük voltajlı devrelerin kullanılması, havai hatlarda direk veya kulelerin korunması gibi tedbirlerle azaltılabilmektedir (Ward, 2013: 106-08).

Kar ve buz birikintilerinden kaynaklanan ağırlıklar, havai hatlarda kule veya direklerin arızalanmasına neden olabilmektedir. Buz tabakaları, havai hat iletkenlerinin kesit alanını arttırmaktadır. Bu durum şiddetli rüzgârlarda çökme riskini arttırmaktadır. Aşırı buz ve kar olayı, kuvvetli yağmurun, kuvvetli rüzgârla birleştiğinde, ağaçlarla veya yapılarla temas halinde donarken, hızla kalın bir buz tabakası oluşturduğunda buz fırtınası oluşmaktadır. Kanada ve Kuzey Doğu ABD’ de Ocak 1998 de yaşanan buz fırtınası nedeniyle dağıtım ağları üzerinde yüzlerce iletim kulesi ve on binlerce tahta direk yok olurken; iki milyondan fazla tüketici elektrik kesintisi yaşamıştır. Almanya’ da, Kasım 2005 tarihinde yaklaşık 70 iletim kulesi kırılıp; yaklaşık 200.000 kişi elektrik kesintisi yaşamıştır (Broström ve Söder, 2007: 1). Buzlanma ve kar yağışının yoğun yaşandığı bölgelerde iletim kuleleri ve hatları beklenen maksimum buz ve rüzgâr yüklemesine dayanıklı şekilde tasarlanmaktadır. Musilek ve arkadaşları havai hatlar üzerindeki buzların birikme oranını tahmini için yöntem geliştirmiştir (Musilek, Arnold ve Lozowski, 2009: 25). Broström and Söder çalışmalarında buz fırtınalarının iletim hatları üzerindeki etkileri için modelleme ve tahmin yöntemleri geliştirmiştir (Broström ve Söder, 2005: 1). Donma koşulları altında, buz ve kar izolatörler üzerinde birikerek kısa devre arızalarına yol açmaktadır. Bu arıza riski uygun bir yalıtkanla azaltılabilmektedir (Ward, 2013: 108).

Havai hatlı iletkenlerin üzerinde veya yakınında düşen yıldırım ile üretilen iyonize gazlar, flashover (parlama) arızalarına neden olabilmektedir. Genel olarak, bu tür hatalar geçicidir. Devrede enerji kesintisi yapıldıktan sonra hatalar giderilmekte ve sonrasında devre hızlı şekilde servise geri yüklenebilmektedir. Bunun yanında yıldırım çarpmasından kaynaklanan voltaj dalgalanması, havai hatlar boyunca hareket edebilmekte ve transformatör sargıları gibi ekipmanlarda hasara neden olabilmektedir. EPRI (2006), araştırmasına göre yıldırım nedeniyle hasarlı veya tahrip olmuş ekipmanın ABD' deki kamu hizmetlerine doğrudan maliyetinin yılda yaklaşık 1 milyar dolar olduğunu tahmin edilmiştir. EPRI (2006) araştırmasına göre ABD' deki iletim hattı kesintilerinin en yaygın nedeninin yıldırım çarpmaları olduğu tespit edilirken; Hines ve arkadaşları arızaların sadece %8' inin ana sebebinin yıldırım kaynaklı olduğunu öne sürmüştür (Hines ve diğerleri, 2009: 5249; Ward, 2013: 108).

Şiddetli yağmurun yaşandığı durumlarda arıza nedenleri daha çok yağmurla bağlantılı olan şiddetli rüzgâr ve yıldırımla ilgilidir. Şiddetli yağış bazı durumlarda izolatörlerde flashover (parlama) hatalarına neden olmaktadır. Şiddetli yağmur nedeniyle yüksek voltajlı izolatörler ile şalt ürünlerine su girebilmektedir. Bu durum iç flashover hatası ve diğer ciddi arızalara yol açabilmektedir. Uzun süreli şiddetli yağmurların diğer zararlı etkileri; sel ve toprak kaymaları olarak kendini gösterebilmektedir. Su baskınları genellikle havai hatlara tehdit oluşturmamaktadır. Havai hatlar için ana tehdit, trafo merkezlerinde yer seviyesinde monte edilen şalt, transformatörler ve kontrol kabinleri gibi ekipmanlardır. Bu ekipmanların su nedeniyle hasar görmesi halinde, tamir edilmesi veya değiştirilmesi uzun zaman alabilmektedir (Ward, 2013: 109).

İletim ve dağıtım sistemleri genellikle soğutma için su kullanmadığından dolayı soğutma sistemleri uzun süreli bir kuraklıktan etkilenmemektedir. Ancak uzun süreli kuraklık, toprağın kurumasına, toprağın ısı iletkenliğinin azalmasına ve yüksek sıcaklıklara bağlı olarak gerilim oranı azalma değerinin artmasına neden olmaktadır. Toprak altının kuruması topraklama sistemlerinde değişiklik yapılmasını gerektiren elektrik iletkenliğini de azaltabilmektedir. Kuraklığın daha önemli bir etkisi, bitki örtüsünün kuruması ve yangın riskini arttırmasıdır. Bitki örtüsünün havai hat iletkenleri ile temasa geçmesi ve flashover nedeniyle tutuşması halinde orman yangınlarına sebep olabilmektedir. Yangınlardan kaynaklanan duman içerisinde

bulunan iyonize hava, bir havai hat üzerinde ark arızalarına neden olabilir. Yangın sırasında, ahşap direkler yanabilmekte; iletkenler ve izolatörler zarar görebilmektedir (Ward, 2013: 109-11). Sıcaklık ve yağış değişikliklerinin hem enerji kullanımı hem de enerji üretimini etkilemesi muhtemeldir. İklim değişikliği veya nehirlerdeki mevsimsel değişimler nedeniyle bazı yerlerde soğutma suyunun kullanılabilirliğinin azalması halinde, hidroelektrik ve/veya termik santraller etkilendiğinden dolayı enerji sektörü de etkilenebilmektedir. Ayrıca yüksek sıcaklık, elektrik hattı verimliliğini olumsuz yönde etkileyebilmektedir (Troccoli, Dubus ve Haupt, 2014: 135).

2.3.2. Şebeke Bileşenlerine Dayalı Çalışmalar

Murugan ve Ramasamy tarafından güç trafosu arızaları analiz edilmiş ve bunların kök nedenleri, Tamil Nadu Transmission Corporation Limited (TANTRANSCO) / Tamil Nadu Üretim ve Dağıtım Şirketi Limited (TANGEDCO) elektrik tesislerinde 2009-2013 yılları arasında meydana gelen 196 arıza ele alınarak incelenmiştir. Hata analizi iki aşamada gerçekleştirilmiştir. İlk aşamada voltaj analizi, coğrafi bölge ve güç trafosu bileşenleri tabanlı arıza analizi istatistiksel yöntemler ile gerçekleştirilmiştir. İkinci aşamada güç trafosu arızalarına neden olan en önemli faktörler, kök neden analizi ile belirlenmiştir. Son olarak, bu arızaların önlenmesi ve güç transformatörlerinin çalışma koşullarının muhafaza edilmesi için etkili bir bakım planlaması önerilmiştir. Çalışma, elektrik tesisatlarında güç trafosunun en iyi koşullarda kullanılması için bakım personeline destek sunmaktadır. Güç transformatörleri, elektrik güç sisteminin en pahalı ve stratejik bileşenlerinden biridir (Metwally, 2011: 36). Güç iletim ve dağıtım sisteminin her aşamasında birbiriyle bağlantı kurarak önemli bir rol oynamaktadırlar. Güç trafoları pratikte, yüksek sıcaklık, acil aşırı yükleme ve dış ortamlarda sürekli çalışma gibi çeşitli durumlarda zorlu çalışma koşulları nedeniyle elektrik sistemindeki yüksek riskli ekipmanlardan biridir. Bu koşullar, güç trafosunun beklenmedik şekilde bozulmasına yol açmaktadır. Güç trafolarının arızalanması, tüm ağın güvenilirliğini doğrudan etkilemektedir. Güç trafolarındaki arızalar, işletim sistemlerinde bozulmaya, neden olup; bu bozulmalar beklenmedik kesintiler ve güç dağıtım sorunları ile sonuçlanmaktadır. Elektrik tesisatlarındaki güç trafosu arızaları yüksek maliyetli olabilmekte ve hasarlı

bileşenlerin yenilenmesi veya değiştirilmesi için uzun zaman gerekebilmektedir. Arıza, sadece uygun maliyet faktörlerini etkilemekle kalmayıp; aynı zamanda müşteri memnuniyetsizliği nedeniyle elektrik tesislerinin imajının düşmesine de sebep olmaktadır (Murugan ve Ramasamy, 2015: 182). Dünya genelinde meydana gelen çok sayıda güç trafosu arızasına ait birçok araştırma bulunmaktadır. Bu araştırmalardan bazıları aşağıda sıralanmaktadır (Murugan ve Ramasamy, 2015: 182-83):

- CIGRÉ çalışma grubu, büyük güç transformatörlerindeki arızaları incelemiş ve arızaların yaklaşık %41' inin yük altındaki kademe değiştiricilere, %19' unun sarımlara, %13' ünün sızıntılara, %12' sinin yüksek gerilim geçit izolatörüne, %12' sinin diğer ve %3' ünün core arızalarına ait olduğunu tespit etmiştir (Bossi ve diğerleri, 1983: 21).
- Minhas ve arkadaşları 1985-1995 yılları arasında Güney Afrika' daki Eskom ağındaki güç trafolarını incelemiştir. Yıldırım, core, kademe değiştirici arızaları, yaşlanma ve kısa devre olarak altı arıza çeşidi belirlenmiştir (Minhas, Reynders ve de Klerk, 1999: 94).
- Jagers ve arkadaşları yüksek gerilim geçit izolatörü, kademe değiştirici ve sargı arızalarının toplam arızaların yaklaşık %79' unu oluşturduğunu; core ile ilgili arızaların katkısının sadece %2 olduğunu tespit etmiştir (Jagers, Khosa, Klerk ve Gaunt, 2007: 1).
- Jongen ve arkadaşları, 110-150 kV arasında değişen gerilime sahip olan transformatörlerde kademe değiştirici ve yüksek gerilim geçit izolatörü arızasının, en önemli arızalar olduğunu belirlemiştir (Jongen, Gulski, Morshuis, Smit ve Janssen, 2007: 1273).
- Abdelfatah ve arkadaşları, 2002-2009 döneminde Mısır Elektrik Şirketi'nde 220 kV güç transformatörleri için bir kesinti veri analizi gerçekleştirmiş ve kesinti nedenlerinin trafo kaynaklı olduğunu bulmuştur. Arıza nedenleri buchholz ve basınç tahliyesi, koruma sistemi hataları, arıza ve hasar, yangın söndürme sistemleri, sıcak noktalar, yağ sızıntısı ve parlama (flash over) olarak sıralanmaktadır. Güç sistemi ile ilgili kesinti kategorisi, yeni gelen (incomer) kesintisi, bara koruma arızaları ve insan faktörleri ile ilgili operasyonel ve bakım hatalarıdır (Abdelfatah, El-Shimy ve Ismail, 2011: 183).

- Suwanasri ve arkadaşları, Tayland'daki trafoların 230/115/22 kV'luk gerilimde arıza istatistiklerini incelemiştir. Nedeni bilinmeyen arızaların %41.3, % 31.7'sinin yüksek gerilim geçit izolatöründen, %17.5'inin kademe değiştiricisinden, %7.9'unun sızıntıdan ve %1.6'sının sarımdan kaynaklı olduğunu tespit etmiştir (Suwanasri, Chaidee ve Adsoongnoen, 2008: 492).
- McElroy, Amerikan kamu kurumunda transformatör sarım rezonansı nedeniyle dört tek fazlı EHV ototransformer arızasını tespit etmiştir. Önceki çalışmalarda sadece istatistiksel analiz yoluyla transformatör bileşeniyle ilgili arızalar tespit edilmiş olup; ilişkili kök nedenler araştırılmamıştır. Çalışmada arıza modunu tanımlamakla kalınmayıp; aynı zamanda arızaların kök nedenleri de araştırılmıştır (McElroy, 1975: 1301).


TANTRANSCO/TANGEDCO' daki en büyük sorun, güç trafolarının sık sık arızalanmasıdır. Yangın, yağ dökülmesi, elektrik sistemi kesintisi ve ekipmanın tamamen hasar görmesi öngörülemeyen onarım veya değiştirme maliyetlerini artırmaktadır (Murugan ve Ramasamy, 2015: 183). 2009–2013 yılları arasında güç trafosu bileşeni tabanlı arızalar sarma, çekirdek, bushing, yük kademe değiştiricisi (OLTC), tank, soğutma sıvısı, izolasyon ve diğerleri şeklinde sıralanmaktadır (Murugan ve Ramasamy, 2015: 185-86):

- Coğrafi bölge tabanlı hata analizi: Bu hatalar çalışma ortamı koşullarından, yaz aylarındaki şebeke yüklenmesinden, yaşlanma faktöründen, yetersiz bakımdan ve bakım personeli eğitiminin eksikliğinden kaynaklanmaktadır. Belirlenen potansiyel arıza türleri ve nedenleri:
 - Katı yalıtım-mekanik hasar: Aşırı yük, aşırı ısınmaya ve yalıtım malzemesinde arızaya neden olmaktadır.
 - Yağın oksitlenmesi-yağın oksidasyonu: Yağın termal ayrışması ve rutubet kaynaklı kirlenme
- Sargı arızaları: Elektrik (yıldırım dalgalanması, anahtarlama dalgası, bağlantı hatası ve aşırı voltaj), mekanik (nakliye hasarı, titreşim, en içteki sargının kasnak burkulmasını içeren elektromekanik kuvvetler, iletken devrilmesi, iletken teleskop, spiral sıkma, kelepçeleme sistemi arızası ve bağlantı uçlarının yer değiştirmesi), termik (transformatöre aşırı yüklenilmesi, soğutma sisteminin bozulması, düşük yağ kalitesi, aşırı ortam sıcaklığı veya aşırı

koşullarda transformatörün çalıştırılması), yalıtım hatası (sargı yalıtım malzemesinin lokal aşırı ısınması, soğutma sistemi arızası ve yalıtım kaplaması hatası).

- Malzemede yüksek gerilim geçit izolatörü hatası, porselen hasarı ve yalıtım hatası.
- Kademe ve yön değiştirici şalter veya kademe arızası, kontrol cihazı ve çalıştırma mekanizması arızası
- Operasyonel hatalar, bakım yetersizliği, operatörler için beceri yetersizliği, transformatörlerin yaşlanması.
- Soğutma sistemi, pompa, fan, radyatör arızası, sıcaklık göstergesi ve kontrol devresi arızaları
- Tank sızıntısı ve içsel basınç nedeniyle kopma

Şekil 30: Güç Trafo Bileşenlerine Ait Arıza İstatistikleri




Kaynak: Murugan ve Ramasamy, 2015: 187.

Akıllı güç trafosu arızalarının ana nedenleri (Murugan ve Ramasamy, 2015: 191):

- Olumsuz çalışma ortamı koşullarında yerleştirilmiş olmaları ve çalışma koşullarına dikkat edilmemesi
- İlgili bölgelerdeki bakım personeli yetersizliği
- Yaşlanma faktörü
- Değişen yük dalgalanmaları nedeniyle izolasyon yağının bozulması

Şekil 31: Güç Trafosu Arızalarına Ait Sebep-Sonuç Diyagramı




Kaynak: Murugan ve Ramasamy, 2015: 187.

Abdulfatah ve arkadaşları güç transformatörleri arızaları ve zorunlu elektrik kesintilerini istatistiksel olarak incelemiştir. Güvenilirliğin artırılması, trafo tasarımı-teknolojisinin iyileştirilmesi, bakım ve durum izleme uygulamalarının iyileştirilmesi için istatistiksel analizler kullanılabilir. Transformatör güvenilirliğinin belirlenebilmesi için çeşitli yöntemlerin, bileşenlerin beklenen arıza oranlarının, güç kesinti sürelerinin ve beklenen onarım sürelerinin bilinmesi gerekmektedir. Çalışmada 2002-2009 yılları arasında, ortalama 1922 trafo için kesinti verileri kullanılmış olup; bu veriler Mısır Elektrik Dağıtım Şirketi'nden (EETC) elde edilmiştir. Kesinti veri analizi iki aşamada gerçekleştirilmiştir. İlk aşamada trafoların arıza ve onarım analizi yapılırken, ikinci aşamada trafo kesintilerinin müşterilere etkisi değerlendirilmiştir. Transformatörlerin güvenilirliği tüm ağın güvenilirliğini doğrudan etkilemektedir. Her elektrik kesintisi için trafonun konumu, tarih, saat, kesintisi süresi, koruma eylemi, trafo bakım (veya onarım) süresi, kesintili MW ve süre verileri elde edilmiştir. Farklı voltajdaki transformatörlerin arıza nedenleri, çalışma koşulları, bakım stratejileri ve çevresel farklılıklardan dolayı değişkenlik göstermektedir. Çeşitli gerilim alt gruplarında transformatörlerin elektrik kesintileri; nedenlerin türüne göre trafo ile

ilgili, elektrik sistemi ile ilgili, çevreye ile ilgili, insan faktörü ile ilgili ve diğer kesintiler olmak üzere beş gruba ayrılmıştır (Abdelfatah, El-Shimy ve Ismail, 2013: 41–42). Trafo ile ilgili arızalar, buchholz ve basınç tahliyesi, aşırı akım koruması, toprak hatası koruması, diferansiyel koruma, arıza ve hasar, yangınla mücadele sistemleri, sıcak noktalar, yağ, hava veya SF6 sızıntısı, flash tükenme; güç sistemiyle ilgili arızalar, gelenlerin kesintisi, bara koruma; insan faktörlü arızalar ve tanımlanmamış diğer arızalar olarak sıralanmaktadır (Abdelfatah, El-Shimy ve Ismail, 2013: 43). Mısır Elektrik Dağıtım işletmesi verilerinden elde edilen kesinti kategorilerinin arıza frekansları ve kesintilerin ortalama onarım süresinin yıllık dağılımı Şekil 32 ve Şekil 33’ te yer almaktadır.


Şekil 32: Kesinti Kategorilerinin Arıza Frekansları



Kaynak: Abdelfatah, El-Shimy ve Ismail, 2013: 44.

Güç transformatörünün plansız kesintisi, elektrik tesislerine milyonlarca dolar maliyete sebep olabilmektedir. Bu nedenle istenmeyen kesintilerin sıklığını ve süresini en aza indirmek oldukça önemlidir. Plansız kesinilerde güç trafosu koruma rölelerine yüksek talepler yüklenmektedir (Abdelfatah, El-Shimy ve Ismail, 2013: 44). Transformatörlerin sürekli olarak izlenmesi ve kontrolü, ömürlerinin yanı sıra stabiliteyi, güvenilirliği ve güvenliği artırmaktadır (Rexhepi, 2017: 422).


Şekil 33: Kesintilerin Ortalama Onarım Süresinin Yıllık Dağılımı



Kaynak: Abdelfatah, El-Shimy ve Ismail, 2013: 46.

Transformatörlerin güvenilirlik değerlendirmesinin ve verimliliğinin dağıtım şebekesinin güvenliği üzerinde büyük etkisi bulunmaktadır. Güç transformatörleri bileşenlerinde arızalar meydana gelmekte ve bu durum tüketicilerin arz ve güvenilirliğini kesintiye uğratmaktadır. Güç transformatörlerinin güvenilirlik değerlendirmesi ile ilgili metodoloji, operasyon durumunun izlenmesi, arızaların türü, zorunlu kesintilerin ve kesinti süresinin izlenmesi aşamalarını içermektedir. Rexhepi'nin çalışması Kosova Enerji İletim Sistemindeki (KOSTT) arıza türü, güvenilirlik ve durum değerlendirmesine ait istatistiksel veri analizini içermektedir. Güç transformatörlerinin güvenlik ve güvenilirliği; iletim limitleri, arıza analizi, voltaj kararlılığı, yük atma, güvenlik kriterleri ve arızaların etkisi faktörlerine bağlıdır (Rexhepi, 2017: 418–19).


Şekil 34: Güç Transformatörlerinin Arıza Sebepleri



Kaynak: (a) KOSTT'teki Güç Trafo Kesintileri Türleri; (b) CIGRE Raporuna Dayalı Hata Verileri. Rexhepi, 2017: 419.

Arıza teşhisinin başarısı, güç kaynaklarının güvenilir ve sağlıklı çalışmasında önemli rol oynamaktadır. Uzman sistemlerin arıza teşhisi üzerine uygulamaları başarılı sonuçlar vermektedir. Ayrıca uygulama süreleri uzun zaman alabilmektedir (Mohamed ve Rao, 1995: 1). Güç sistemi bileşenlerinin güvenilirlik ve kullanılabilirlik değerlendirmesi için diyagramın oluşturulması, geçiş matrisi, markov süreci ve olasılık koşulu gibi birçok yöntem kullanılmaktadır. Kullanılan yöntemler, güç sisteminin sınırı ve tüm bileşenlerin listesi, arıza oranı, onarım oranı, her bileşen için planlı bakım süresi, her bileşen için güvenilirlik modelleri, arıza türü veya normal/hatalı sistem kriterlerini ve sistem güvenilirlik indeksini hesaplayan yöntemleri içerebilmektedir (Martins, 2014: 9–10). Güç transformatörleri için arıza tespiti, transformatörün durumu, ilgili kritik parametrelerin izlenmesi ve transformatörün bir arızanın eşiğinde olup olmadığını sürekli olarak izlemeyi gerektirmektedir. Transformatörlerin önleyici bakımı, önemli işletim verilerini kaydetmeyi gerektirmektedir. Durum değerlendirmesinin temel amacı, varlık yönetimine ait karar verme ve risk azaltımı faaliyetlerini optimize etmenin yanında; varlık ömrü kararları için kriterler oluşturmak ve durum değerlendirmesi için doğru teknikleri saptamaktır (Rexhepi, 2017: 20–21).

Şekil 35: Güç Transformatorü Güvenilirliğinin Değerlendirilmesi



Kaynak: Rexhepi, 2017: 421.


Mekki ve arkadaşları çalışmalarında kısmi gölgeli koşullarda fotovoltaik modül için arıza tespit yöntemini önermiştir. Değişken çalışma koşulları altında çıkış fotovoltaik akımı ve voltajı tahmin etmek için yapay sinir ağı yöntemi kullanılmıştır. Güneş ışıınımı, hücre sıcaklığı, fotovoltaik akım ve voltaj verileri yenilenebilir enerji laboratuvarı REL ve Jijel Üniversitesi' nden elde edilmiştir. Optimal çalışma koşullarını sağlamak ve performans kayıpları faktörü olarak düşünülebilecek hataların tespiti amacıyla; tesisin çalışma durumu sürekli takip edilmiştir. Mevcut birkaç arıza metodu, çalışma durumlarını analiz etmek, anormal kayıpları ve hatalı durumları tespit etmek için belirli zaman aralığında tesisin çevrim dışı verilerini kullanabilmektedir. PV jeneratörlerinin sıcaklık ve seri direnci gibi bazı hatalı parametrelerin tahmini için diğer metodlar karmaşık matematiksel hesaplamaları gerektirebilmektedir. Çalışmada yapay sinir ağları fotovoltaik çalışmalarında başarılı şekilde kullanılmıştır. PV güç tahmini, performans değerlendirmesi, modelleme ve simulasyon gölgeleme koşulları altında maksimum güç noktasının izlenmesi bu çalışmalara örnek olarak gösterilebilmektedir. Fotovoltaik modülün gölgelendirme şartlarında modellenmesi ve izlenmesi için YSA kullanımına dayanan bir ön çalışma yapılmıştır (Mekki, Mellit ve Salhi, 2016: 1-2).

Transformatörler, dağıtım sistemleri için kritik öneme sahip olduklarından; bu bileşenlerin bakım yöntemleri de oldukça önemlidir. Bu yöntemlerden bazıları,

çözünmüş gaz analizi (DGA) tekniği, kısa devre empedansı (SCI) ölçümü, frekans yanıt analizi (FRA) ve güç faktörü testi şeklinde sıralanabilmektedir. Yöntemlerin ana hedefi; yaşlanma sürecinden, baskı durumlarından ve elektriksel arızalardan dolayı azalan ömrü uzatmaktır. Roncero-Clemente ve arkadaşları çalışmalarında bu testlerin uygulanmasını ve girdi-çıktı verilerinin değerlendirilmesini ele almıştır. Sonrasında farklı işlemlerin ve farklı testlerin geri dönüşlerinin otomatikleştirildiği uygulama geliştirilmiştir. Geleneksel bakım operasyon stratejileri temel olarak üç sınıfta listelenebilmektedir (Roncero-Clemente ve Roanes-Lozano, 2018: 153–54):

- Düzeltici bakım: Aksiyon ve onarımlar, ekipmanın bozulmasından hemen sonra gerçekleştirilmektedir.
- Önleyici/planlı/rutin bakım: Önceden ayarlanmış bir süre için bakım işlemleri gerçekleştirilmektedir. Rutin kontroller ve testler yapıp; yaklaşan sorunlar tespit edilebilmekte, azaltılabilmekte veya ortadan kaldırılabilir.
- Tahmine dayalı bakım/duruma dayalı bakım: Ekipmanın durumuna bağlı olarak eylemler ve onarımlar gerçekleştirilmektedir.

Şekil 36: Trafo Arızalarının Nedenleri (1991-2010)




Kaynak: Roncero-Clemente ve Roanes-Lozano, 2018: 154.

Catrinu ve Nordgard' ın çalışmasında elektrik dağıtım sistemi varlık yönetiminde belirsizlik altında risk analizi ve çok kriterli karar desteğinin entegrasyonuna ait konular incelenmektedir. Elektrik dağıtım şebekesinin fiziksel varlıklarının nasıl ele alınacağına karar verilirken; farklı şirket hedeflerinin ve risk

analizlerinin yapılandırılmış bir karar çerçevesine nasıl dahil edileceğine odaklanılmaktadır (Catrinu ve Nordgård, 2011: 663). Trafo varlık yönetimi teknikleri, bulanık mantık, dijital sinyal işleme algoritmaları, örüntü tanıma algoritmaları, temel bileşen analizi ve geri yayılım yapay sinir ağı algoritması gibi tekniklerin kullanılması sayesinde gün geçtikçe gelişmektedir. Trafo varlık yönetimi, geçmiş verilerin kullanılması, durum değerlendirmesi, finansal bilgi, ekonomik risk yönetimi ve nihai karar olan transformatörlerin bakımı, onarımı, yükseltmesi, değiştirilmesi, izlenmesi gibi operasyonları içermektedir (Azmi, Jasni, Azis ve Kadir, 2017: 687–88).

Şekil 37: Trafo Sağlık Endeksi




Kaynak: Azmi, Jasni, Azis ve Kadir, 2017: 689.

Güç tesislerinin arızalardan korunması için, gerçek zamanlı izleme ve hata tahmin araçlarının geliştirilmesine dair birçok araştırma ve uygulama literatürde yer almaktadır. Trappey ve arkadaşlarının çalışmasında güç trafosu bakımı için akıllı mühendislik varlık yönetimi sistemi geliştirmiştir. Sistem, anahtar parametrelerin gerçek zamanlı olarak izlenmesini sağlamak ve değişik çalışma koşulları altında transformatörlerin potansiyel arızalarını tespit etmek için veri madenciliği ve hata tahmin modellerini kullanmaktadır. Tayvan ve Avustralya'ya ait endüstriyel güç trafosu verileri kullanılan çalışmada temel bileşen analizi ve geri yayılım yapay sinir

ağı tahmin modeli kullanılmıştır. Planlı bakım süreleri arasındaki zaman aralığında arıza tespit edilmediğinde zaman bazlı strateji başarısız olabilmektedir. Bu nedenle, ekipman yöneticilerinin transformatör koşullarını yönetmeleri için verimli ve etkili arıza tespit teknikleri ve doğru tahminleri önemlidir. Geri yayımlı yapay sinir ağı, çok sayıda değişken arasındaki ilişkileri ayırt etmeden; trafoların çalışma koşullarını ve karşılık gelen arıza sinyallerini içeren veri setlerini hızlı şekilde öğrenme ve adapte olma avantajını sağlamaktadır (Trappey, Trappey, Ma ve Chang, 2015: 3–4).

Şekil 38: Trafo Arıza Tespiti İçin Geri Yayımlı YSA Mimarisi (BP-ANN)



Kaynak: Trappey, Trappey, Ma ve Chang, 2015: 6.

Akıllı dağıtım şebekelerinin kritik gereksinimlerinden biri kendi kendini iyileştirme mekanizmalarını oluşturmaktır. Dağıtım sistemleri son zamanlarda iletişim, akıllı sayaç-sensörler, otomasyon ve bilgi teknolojisi gibi gelişmiş altyapıların eklenmesiyle çok katmanlı olarak büyümüştür. Dağıtım şebekesinin sayısallaştırılması, alçak gerilim (LV) dağıtımında etkin yük yönetimi ve kontrolü için konut mikro-ızgaraları, elektrikli araç şarjı, talep yanıtı, net ölçüm, talep tarafı yönetimi ve kesinti yönetim sistemi gibi yeni teknolojilerin ve çözümlerin geliştirilmesine yol açmaktadır (Balakrishna ve diğerleri, 2017: 154). Nwobi-Okoye çalışmasında kamu hizmeti şirketlerinin güç dağıtım tesislerinin performans değerlendirmesinde transfer fonksiyonu modellemesinden elde edilen performans katsayısı değerlerinin, regresyon analizinden elde edilen eşdeğer modelden daha doğru ve istatistiksel olarak daha iyi olduğunu tespit etmiştir (Nwobi-Okoye, 2018: 152).

ÜÇÜNCÜ BÖLÜM

YAPAY ZEKÂ, MAKİNE ÖĞRENMESİ, DERİN ÖĞRENME VE HEDEF PROGRAMLAMA

3.1. YAPAY ZEKÂ (ARTIFICIAL INTELLIGENCE)

Yapay zekâ, zekâyı simule edebilen makineleri geliştirmek için uygulanan çok disiplinli teorilerin, tekniklerin, kavramların ve teknolojilerin bütünü olarak tanımlanabilmektedir. Yapay zekâ (AI), makine öğrenimi (ML), görüntü işleme, doğal dil işleme ve robotik gibi birçok alanda araştırma yapılmış ve geliştirilmiş bir bilimdir. Makine öğrenme algoritmalarının başarısı, modeli geliştirenlerin deneyim ve tercihleriyle şekillenmektedir. Bu nedenle, AI' nin endüstriyel uygulamalardaki başarısı, geliştiricinin yeteneklerine bağlıdır. Yapay zekâ, çeşitli operasyonlar ve uygulamalara yönelik öğrenme algoritmalarını geliştirmeye, doğrulamaya ve uygulamaya odaklanmaktadır. Yapay zeka, Endüstri 4.0 entegrasyonunu genişletme sürecinde CPS, IIoT, büyük veri ve bulut bilişim ile entegre edilmektedir. Sonuç olarak endüstri süreçleri esnek, verimli ve sürdürülebilir yetenekler kazanmaktadır (J. Lee ve diğerleri, 2018: 20).


Yapay sinir ağları (YSA) yapay zekâ tekniklerinden biridir. YSA, birçok disiplinde karmaşık sorunların modellenmesi için kullanılan ve son zamanlarda donanım ve yazılımdaki gelişmeler doğrultusunda kullanımı daha kolay olan önemli modelleme araçlarından biri olarak tanımlanabilmektedir. YSA' lar paralel hesaplamalar yapabilen birbirine bağlı uyarlanabilir işlem elemanlarından oluşmaktadır (Hecht-Nielsen, 1990: 3168). YSA tekniği, biyolojik organizmaların karmaşık problemleri çözmek için kullandığı yöntemleri taklit etmektedir. Bu modellerin avantajları, doğrusal olmama, yüksek paralellik, hataya dayanıklılık, öğrenme ve bulanık hesaplama ayrıcalıkları gibi biyolojik sistemlerin özelliklerinden taklit edilmektedir (Basheer ve Hajmeer, 2000: 3). Yapay zekâ (AI) yöntemleri, doğru tahminler yapmak için simulasyonları veya diğer geçmiş verileri kullanarak girdi ve çıktı arasındaki ilişkiyi öğrenmeyi amaçlamaktadır. En yakın komşu tekniği, belirli bir veri noktasının en yakın komşularını tanımlamak için geçmiş verileri kullanmaktadır. Sinir ağları yönteminin uygulamaları AI yöntemlerinininkine benzer şekilde

sınıflandırma ve öngörme esasları ile çalışmaktadır (Wauters ve Vanhoucke, 2017: 1098).

3.2. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORK)

Yapay sinir ağları, farklı disiplinlerde geleneksel istatistiksel modelleme tekniklerine alternatif olarak kullanılmaktadır (Gardner ve Dorling, 1998: 2627). Yapay sinir ağları (YSA/ANN), beynin sinir yapısının çalışma prensibine dayanarak geliştirilmiştir. Bilindiği gibi, beynin öğrenme olayı deneyler yoluyla gerçekleşmektedir. YSA, girdi, gizli ve çıktı katmanları olmak üzere üç bölümden oluşmaktadır. Girdi verilerinin sinir ağına ilk girişleri girdi katmanı üzerinden yapılmaktadır. Bu katmandaki değerler sinir ağına taşınmakta ve nöronlar bilgiyi diğer katmana değer olarak iletmektedir. Gizli katman, girdi ve çıktı katmanları arasında bulunmaktadır. Bu katmanda nöronların derinliği ve sayısı deneysel çalışmalarla yapılmaktadır. Ağıın çıktı değerleri çıktı katmanında oluşturulmaktadır (Shaban ve diğerleri, 2019: 322–23). Yapay sinir ağlarında bilgi, ağırlık şeklinde tanımlanan sayısal değerler olarak temsil edilmektedir. Ağırlıklar, analitik modellerle hesaplanması zor olan fiziksel süreçlerin girdi ve çıktı parametreleri arasındaki ilişkiyi göstermek için kullanılmaktadır (Mekki, Mellit ve Salhi, 2016: 2).

Şekil 39: Yapay Sinir Ağının Genel Mimarisi



Kaynak: Marugán, Márquez, Perez ve Ruiz-Hernández, 2018: 1823.

YSA, nöronlar tarafından oluşturulan ve insan beyninin çalışma prensibine göre hesaplanan bir veya daha fazla katmandan oluşan bir model olarak tanımlanmaktadır. Hesaplama türünün seçilmesiyle, yapay sinir ağı modelinin ileri veya geri yayılım mimarisine sahip olacağına karar verilmektedir. YSA öğrenme sürecinde, sinir ağı bağlantılarının ağırlıkları öğrenme kurallarına göre ayarlanmaktadır. Yapay sinir ağları denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme yöntemine göre tasarlanabilmektedir. Bu öğrenme yöntemlerinden hangisinin kullanılacağına karar verilirken, incelenen problem göz önünde bulundurulmaktadır. YSA' da hiperbolik tanjant, sigmoid, radyal tabanlı fonksiyon ve rectified linear unit (ReLU) gibi aktivasyon fonksiyonları yaygın olarak kullanılmaktadır (Kruse, Borgelt, Braune, Mostaghim ve Steinbrecher, 2016: 47). Çok katmanlı perceptron (MLP), giriş katmanı, bir-çoklu gizli katmanlar ve çıktı katmanlarından oluşmaktadır. Bir katmandaki her nöron, bir sonraki katmandaki tüm düğümlere bağlanmaktadır. MLP, denetimli öğrenme durumlarında geri yayılım yöntemini kullanmaktadır (J. Zhang ve Li, 2020: 2).

Şekil 40: Yapay Sinir Ağlarının Ana Bileşenleri




Kaynak: Anderson ve McNeill, 1992: 2.

Beynin sinir yapısından ilham alınarak geliştirilen yapay sinir ağları, beynin deneyimlerden elde ettiği gibi temel öğrenme olayını gerçekleştirmektedir. Canlılardan ilham alınarak geliştirilen bu yöntem bilgisayarlarda ve bilgisayar endüstrisinde önemli bir konuma ulaşmıştır. YSA geleneksel programlama

yöntemlerini kullanmamaktadır. Bu özelliğiyle geleneksel bilgi işlemden farklıdır. Sorunları çözerken, genellikle paralel ağlar oluşturmakta ve bu ağların eğitimine odaklanmaktadır. YSA davranma, tepki verme, kendi kendini örgütleme, öğrenme, genelleme ve unutma gibi süreçleri içermektedir (Anderson ve McNeill, 1992: 2). Yapay sinir ağları hata tahmini için diğer uygulamalara nazaran kapsamlı bir yaklaşımdır. Yapay sinir ağı tekniği, adapte edilebilirlik, doğrusal olmama ve isteğe bağlı fonksiyon yaklaşım özellikleri nedeniyle; özellikle arıza tahmini için birçok çalışmada tercih edilmektedir. YSA tabanlı modelleme, birbiriyle bağlantılı birçok nöron tarafından çok miktarda girdi ve çıktı arasındaki doğrusal olmayan, karmaşık ve belirsiz ilişkileri göstermek için kullanılmaktadır (Lu ve diğerleri, 2018: 72-73).

Şekil 41: Yapay Nöronun Temel Yapısı



Kaynak: Anderson ve McNeill, 1992: 4.

Şekil 41' de, x_n ağına çeşitli girişler gösterilmektedir. Bu giriş değerlerinin her biri, w_n ile matematiksel olarak gösterilen bağlantı ağırlıkları ile çarpılmaktadır. Sonrasında sonuçlar toplanmakta veya diğer matematiksel hesaplamalara tabi tutulmaktadır. Çıktı değeri, sonuçların elde edilmesi için bir transfer fonksiyonuna tabi tutulduktan sonra üretilmektedir (Anderson ve McNeill, 1992: 5).

Gizli katmanın çıktısını hesaplarırken ω_{ij} bağlantı ağırlığı ve gizli katman ile önceki katman arasındaki b_i sapma değeri kullanılmaktadır:

$$H_j = f \left(\sum_{i=1}^n \omega_{ij} x_i + b_i \right), j = 1, 2, \dots, l$$

Formülde, l gizli katman nöronlarının sayısını ve f gizli katmanın aktivasyon fonksiyonunu temsil etmektedir. Yapay sinir ağının nihai çıktısı aşağıdaki gibi hesaplanmaktadır:

$$O_k = f \left(\sum_{j=1}^n \omega_{kj} H_j + b_j \right), k = 1, 2, \dots, m$$

m ' nin çıktı katmanındaki nöron sayısını temsil ettiği durumda, ω_{ij} bağlantı ağırlığıdır ve b_j çıktı katmanı ile gizli katman arasındaki sapmadır. Ortalama bağıl hata oranı (MRER), SOH tahmin modelinin hata fonksiyonu olarak belirlenmektedir. Ortalama mutlak hata (MAE), RUL tahmin modelinin eğitim sürecinde bir hata fonksiyonu olarak kullanılmıştır. MRER ve MAE formülleri aşağıdaki gibidir:

$$MRER = 1/m \sum_{k=1}^m |(Y_k - O_k)/Y_k|, k = 1, 2, \dots, m$$


$$MAE = 1/m \sum_{k=1}^m |(Y_k - O_k)|, k = 1, 2, \dots, m$$

Formülde m gözlem sayısını belirtmektedir. Y_k gerçek değeri ve O_k YSA' nın tahmini değerini temsil etmektedir. Eğitim süreci için kullanılan geri yayılım algoritmasının formülü aşağıdaki şekildedir:

$$\Delta \omega_{jk} = -\gamma \frac{\partial e_k}{\partial \omega_{jk}}, j = 1, 2, \dots, l; k = 1, 2, \dots, m$$

γ 0-1 aralığında değerler alan bağlantı ağırlığını göstermektedir. Bağlantı ağırlığının ve sapmanın ayarlama derecesini göstermektedir (S. Zhang ve diğerleri, 2019: 7).

Şekil 42: Sinir Ağı Yapılarının Sınıflandırılması



Kaynak: Gardner ve Dorling, 1998: 2628.

Sinir ağları, tahmin, optimizasyon, kümeleme, örüntü sınıflandırma, fonksiyon yaklaşımı, kontrol vb. gibi birçok alanla ilgili problemleri çözmek için kullanılmaktadır (Basheer ve Hajmeer, 2000: 15; Marugán ve diğerleri, 2018: 1823). YSA' larda öğrenme süreci ve test süreci iki önemli aşamadır. Yapay sinir ağındaki eğitim sürecinden sonra, eğitim sürecinin başarısı test verileri ile test edilmektedir. Öğrenmenin başarısı, eğitim modelinin öngörülen değerleri ile elde edilen veriler karşılaştırılarak belirlenmektedir.


3.2.1. Çok Katmanlı Algılayıcı (The Multilayer Perceptron)

Çok katmanlı algılayıcı (MLP), girdi ve çıktı vektörleri arasında doğrusal olmayan bir ağ oluşturan ve birbirine bağlı nöronlardan meydana gelen modeller olarak tanımlanmaktadır. Nöronlar belirli ağırlıklar ve üretilen çıktı değerleri ile birbirine bağlanmaktadır. Sinyaller ve ağırlıklar, aktivasyon fonksiyonu ile değiştirilen nörona olan girişlerin toplamının bir fonksiyonudur. Çok katmanlı algılayıcı doğrusal olmayan fonksiyonlara yakınlamasını sağlayan birçok doğrusal olmayan transfer fonksiyonunun birleştirilmesiyle oluşturulmaktadır. Lojistik fonksiyon kolayca türetilbildiğinden, transfer fonksiyonlarında yaygın olarak kullanılmaktadır. Bir nöronun çıktısı, bağlantı ağırlığı ile belirlenmekte ve bu çıktı, bir sonraki katmanın nöronuna iletilmektedir. Bu yapı ile MLP ileri beslemeli sinir ağı olarak bilinmektedir. MLP yapısı duruma bağlı olarak değişmektedir. Sinir ağlarının (neural network-NN) girdi katmanında hesaplama yapılmamaktadır. Bu katmanın görevi girdi vektörünün

sinir ağına aktarılmasını sağlamaktır. Çok katmanlı algılayıcı bir veya daha fazla gizli katmandan oluşmaktadır. Sadece bir çıktı katmanı bulunmaktadır. MLP, önceki ve sonraki katmandaki her düğüme ve her nörona tam olarak bağlı ağ olarak tanımlanmaktadır (Gardner ve Dorling, 1998: 2627). Girdi katmanı dışındaki her katman, önceki katmandaki çıktıyı kullanarak gerekli eylemleri gerçekleştirmekte ve sonuçları bir sonraki katmana aktarmaktadır (Berecibar ve diğerleri, 2016: 241).

Çok katmanlı algılayıcı, girdi ve ilgili çıktılardan oluşan eğitim veri setini kullanarak öğrenme yeteneği kazanmaktadır. Eğitim sürecinde, çok katmanlı algılayıcıya uygun miktarda eğitim verisi verilmekte ve ağdaki ağırlıklar istenen girdi-çıkı seviyesine ulaşılan kadar ayarlanmaktadır. MLP denetimli öğrenme yöntemi ile eğitilmektedir. Öğrenme işlemi sırasında belirli bir girdi için MLP' nin çıktısı istenen çıktıdan farklı olabilmektedir. Bu hata, gerçek ve beklenen değer arasındaki fark olarak tanımlanmaktadır. Öğrenme sırasında ağdaki bağlantı ağırlıklarının değerlerini belirlemek için hata sinyalinin değeri kullanılarak genel hata azaltılmaktadır. Bir MLP' nin eğitimi, ağ modelleme ilişkisini çözmek için belirli bağlantı ağırlıklarının yeniden belirlendiği denemelerle yapılmaktadır. MLP' u eğitmek için kullanılacak birçok algoritma bulunmaktadır. Geri yayılım algoritması bu yöntemi hata yüzeyinin genel minimum değerini bulmak için kullanılmaktadır (Gardner ve Dorling, 1998: 2627). MLP çok katmanlı ileri beslemeli bir sinir ağıdır. MLP'deki gizli katmanların herbiri birbirine tamamen bağlanmaktadır. Yani her katmandaki her bir düğüm, belirli bir ağırlıkla alt katmanın her düğümüne bağlanmaktadır (Min, Lee ve Yoon, 2017: 855).


Şekil 43: Üç Katmanlı Geri Yayılım Sinir Ağı



Kaynak: W. Sun ve Xu, 2016: 368.

Rumelhalt ve arkadaşları tarafından kullanılan geri yayılım algoritması, MLP'nin eğitimi için en uygun yöntemdir. Sinir ağındaki bağlantı ağırlıkları başlangıçta küçük rastgele değerler olarak belirlenmektedir. İlk hesaplamalardan sonra, backpropagation (geri yayılım) yöntemi hata yüzeyinin yerel gradyanını bulmaktadır. Ağırlıkları en dik yerel eğim yönünde güncellemektedir. Ağırlıkların hata yüzeyinin küresel minimumuna yaklaşacağı beklenmektedir. Çok katmanlı algılayıcının bağımsız test verileri üzerindeki performansı en üst düzeye çıkarıldığında ve ağ hatası en aza indirildiğinde eğitim tamamlanmaktadır (Gardner ve Dorling, 1998: 2627).

Şekil 44: Geri Yayılım (Back Propagation) Algoritması



Kaynak: Gardner ve Dorling, 1998: 2627.

3.2.2. Yapay Sinir Ağlarının Eğitimi

YSA eğitimi beynin öğrenme yöntemine benzemektedir. Beyin deneyimler ve deneyler yoluyla öğrenmektedir. Yapay sinir ağlarında, pekiştirmeli öğrenme (reinforcement learning-RL), gözetimli öğrenme (supervised learning-SL) ve gözetimsiz öğrenme (unsupervised learning-USL) başlıklarında üç öğrenme kuralı bulunmaktadır. SL yönteminde, bir sinir ağının gerçek çıktısı istenen çıktıyla karşılaştırılmaktadır. Rastgele atanan bağlantı ağırlıkları daha sonra ağ tarafından ayarlanmaktadır. Bu şekilde bir sonraki yineleme ile gerçek ve istenen çıktı arasında daha yakın bir eşleşme oluşturulmaktadır. Öğrenme yöntemi çalışırken tüm işlem öğelerinin geçerli hatalarını en aza indirmeye çalışmaktadır. Bu global hata azaltma

kabul edilebilir bir doğruluk değeri elde edilene kadar bağlantı ağırlıklarını sürekli olarak değiştirmektedir. Eğitim veri seti önceki zamanlarda meydana gelen girdi ve çıktı verilerini sinir ağına sağlamaktadır. Her bir girdi seti için karşılık gelen istenen çıktı seti de sağlanmaktadır. Çoğu uygulamada gerçek veriler kullanılmaktadır. İşlem gücü yetersiz olan donanım ile öğrenme süreci uzun sürebilmektedir. Önceden tanımlanmış parametrelerin seviyesine ulaşıldığında sinir ağlarının eğitimi tamamlanmaktadır. Eğitim tamamlandığında mevcut ağırlıklar genellikle dondurulmaktadır. Sinir ağları hesaplamasının başarısı için eğitim veri setinin gerekli tüm bilgileri içerecek şekilde büyük hacimde olması gerekmektedir (Anderson ve McNeill, 1992: 26–27).

Gözetimsiz öğrenme gelecekte büyük ilerlemelerin kaydedileceği önemli bir alandır. Gelecekte bilgisayarların robotik olarak kendi başlarına öğrenmelerini sağlayacaktır. Bu tür ağlar yaygın olarak kullanılmamaktadır. Bu ağlar bağlantı ağırlıklarını güncellemek için herhangi bir dış faktör kullanmamaktadır. Bunun yerine, performanslarını dâhili olarak izlemektedir. Bu ağlar girdi sinyallerindeki eğilimleri veya düzenliliği incelemekte ve bunları ağa uyarlamaktadır. Ağın nasıl çalışacağı hakkında bazı bilgiler bulunmaktadır. Bu bilgiler öğrenme kurallarına ve ağ mimarisine dâhildir. Kümelerin eğitiminde sadece kazanan işlem elemanlarının ağırlıkları öğrenme kuralı ile güncellenmektedir (Anderson ve McNeill, 1992: 7–28). Öğrenme oranı YSA' da ağın öğrenme performansı ile yakından ilişkilidir. Öğrenme oranı hatayı ne kadar önemli olarak değerlendirdiğimizi gösteren değerdir. Öğrenme değerlerinin yüksek oranı göz önüne alındığında, hatalar büyük değişikliklere yol açmaktadır. Yüksek bir öğrenme oranı seçmek ağın öğrenme yeteneğini azaltmaktadır. Küçük öğrenme oranı seçildiğinde de YSA' nın öğrenme süresini uzayabilmektedir. Bu nedenle optimal değer seçilmelidir.

3.3. MAKİNE ÖĞRENMESİ (MACHINE LEARNING)

Makine öğrenme yöntemleri, internet aramaları, web sitesi önerileri, elektronik ticaret ve sosyal ağ filtrelemelerine kadar günlük yaşantımızın birçok yönünü güçlendirmektedir. Makine öğrenim yöntemleri, nesneleri tanımlamak, sesli konuşmayı metne dönüştürmek, yayınları, ürünleri ve haber gündemlerini bireylerin

ilgi alanlarıyla eşleştirerek ilgili arama sonuçlarını seçmek gibi gündelik hayata dair birçok uygulamada kullanılmaktadır. Bu uygulamalar, makina öğrenme yöntemi olan derin öğrenme modellerinden artan şekilde faydalanmaktadır. Yapay zekâda karar verme ve/veya tahmin süreçleri; kümeleme ve sınıflandırma işlemlerinin gözetimsiz ve gözetimli öğrenme yöntemleri sayesinde yapıldığı makine öğrenmesi teknikleri ile gerçekleştirilmektedir (Yann LeCun, Bengio ve Hinton, 2015: 436).

Yapay sinir ağları; karar ağaçları, destek vektör makineleri (SVM) vb. diğer makine öğrenme modelleriyle karşılaştırıldığında kara kutu model olma dezavantajına sahiptir. Bir yapay sinir ağını oluşturmak ve topolojisine karar vermek, çoğu zaman fazlaca araştırma ve deneyi gerektirmektedir. Ortaya çıkan kurallar eğitilmiş ağırlıklar olup; insan tarafından okunabilir kurallar değildir. Bunun yanında sinir ağları, tekrarlayan ve kıvrımlı katmanlarla birlikte, zaman dizileri veya olay günlük kayıtları gibi geçici verileri işlemek ve dâhili durumun korunması konularında uygundur. Yapay sinir ağı modelinde hem eğitim sırasında hem de gerçek tahmin aşamasındayken girdi verileri kullanılmaktadır. Girdi verileri, tespit edilen olay türünün yanı sıra varsa olayla ilişkili diğer verileri içermektedir. ML modelinin çıktısı, modelin bir sonraki adımının ne olacağının bir sınıflandırmasıdır. Çıktı, her işlem adımı için bu işlem adımının bir sonraki aşamadaki olasılığını veren vektördür (Borkowski, Fdhila, Nardelli, Rinderle-Ma ve Schulte, 2019: 224). Makine öğrenmesi, çeşitli sistemlerde arızaların-hataların tespiti ve gelecekteki ihtiyaçların öngörülmesi için önemli bir yapay zekâ tekniğidir. Üretim işletmeleri arıza analizinde ve operasyonlarda daha iyi performans elde edebilmek için makine öğrenmesi uygulamalarını kullanabilmektedir (Moktadir ve diğerleri, 2018: 732).

3.4. DERİN ÖĞRENME (DEEP LEARNING)

Dünya, akıllı şebekeler, nesnelerin interneti, uzun peryotlu dönüşüm ve 5G iletişimi gibi bağlantılı teknolojilerin farklı alanlarında önemli dönüşümler geçirmektedir (Aldweesh, Derhab ve Emam, 2020: 1). Derin öğrenme uygulamaları söz konusu ilerlemelerin önemli bir bilşenidir. Derin öğrenme (Deep Learning-DL) modeli, insan beyninin çalışma işlevini örnek alan hesaplama sistemlerine dayanmaktadır. Derin öğrenme mimarisi bir veya daha fazla gizli katman bulunduran

yapay sinir ağı modeli olup; bir makine öğrenmesi tekniğidir. Derin öğrenme, nesne tanıma, nesne algılama, konuşma dili tanıma, ilaç geliştirme ve gen teknolojisi gibi birçok alana ait teknolojiyi önemli ölçüde geliştirmektedir. Derin öğrenme yönteminde geri yayılım algoritması kullanılarak; katmanların hesaplamalarda kullandığı girdi parametreleri güncellenmekte ve yeni değerlerle yeniden hesaplamalar yapılmaktadır. Bu sayede büyük veri kümelerindeki karmaşık yapılar keşfedilebilmektedir. Görüntü, video, konuşma ve sesin işlenmesinde derin evrimsel ağlar önemli katkılar sunarken; metin ve konuşma gibi sıralı verilere ait analizler tekrarlayan ağlar ile verimli bir şekilde gerçekleştirilmektedir (Yann LeCun ve diğerleri, 2015: 436). Derin öğrenme, problem çözme ve hayati fonksiyonları devam ettirme süreçlerinde insan beyninin gözlem, analiz, öğrenme ve karar verme yeteneklerinden esinlenmektedir. Derin öğrenme, büyük veri setlerinden gözetimli veya gözetimsiz şekilde özellik çıkarma, dönüştürme ve sınıflandırma işlemlerini yapabilen bir makine öğrenmesi yöntemidir. Geleneksel makine öğrenme algoritmaları doğrusal yapıda olup; derin öğrenme algoritmaları için, üzerinde çalışılan alanın karmaşıklığına göre doğrusal olmayan modeller de tasarlanabilmektedir (Süzen ve Kayaalp, 2018: 7).

Derin mimariler, basit makine öğrenimi tekniklerinden farklı olarak; insan müdahalesi olmadan farklı işleme katmanlarındaki farklı soyutlama düzeylerine sahip öğrenme yeteneğine sahiptirler. Bu şekilde derin sinir ağları ham girdi ve çıktı arasındaki karmaşık korelasyonları ve haritalamayı otomatik şekilde bulabilmektedir (Deng ve Yu, 2014: 199). Derin öğrenme uçtan uca problem çözmeyi desteklerken; basit makine öğrenme algoritmaları bir problemi birkaç parçaya bölmekte, her birini ayrı ayrı çözmekte ve daha sonra sonuçları elde etmek için bu sonuçları tekrar birleştirmektedir (Aldweesh, Derhab ve Emam, 2020: 6). Derin öğrenme, yapay zekâ topluluğunun uzun yıllar üzerinde emek harcadığı problemlerin çözümünde büyük katkılar sağlamıştır. Derin öğrenme tekniğinin büyük hacimli veri yığınlarındaki karmaşık yapıları keşfetmede yüksek derecede önemli olduğu ortaya çıkmıştır. Bu nedenle bilim, iş dünyası ve devletlerin birçok alanı için uygulanması oldukça önemlidir. DNA mutasyonlarının hastalık üzerine etkisi (Xiong ve diğerleri, 2015: 1), doğal dil anlama (Collobert ve diğerleri, 2011: 1), konuşma tanıma (Sainath, Mohamed, Kingsbury ve Ramabhadran, 2013: 1), görüntü tanıma (Krizhevsky, Sutskever ve Hinton, 2012: 1), sınıflandırma, duygu analizi, soru cevaplama ve dil


çevirisi için derin öğrenme teknikleri kullanılmaktadır (Yann LeCun ve diğerleri, 2015: 436).

Derin öğrenme tekniğinde, verilere ait birden çok özellik seviyesi veya temsilin öğrenilmesiyle oluşan bir model bulunmaktadır. Bu teknikte üst düzeyin alt düzey özelliklerden türetilerek oluşturulduğu bir temsil hiyerarşisi bulunmaktadır (Bengio, 2009: 1). Derin öğrenme mimarisi, tamamı (veya çoğu) öğrenme odaklı ve birçoğu doğrusal olmayan girdi-çıkı eşleşmelerini hesaplayan çok katmanlı basit modül yığınlarından meydana gelmektedir. Yığınlardaki her modül seçiciliğini ve değişmezliğini artırmak için girdi ağırlıklarını dönüştürmektedir. Çok katmanlı modül yığınlarının ağırlıklarına göre amaç fonksiyonun gradyanının hesaplanmasında kullanılan geri yayılım algoritması, türev zincir kuralının pratik uygulamasıdır. Genel uygulama, bir modülün girdisine göre hedefin türevinin (veya gradyanının), modülün çıktısına (veya sonraki modülün girdisine) göre eğimden geriye doğru çalışarak hesaplanması şeklindedir. Bu şekilde ağırlıklar yeniden güncellenmektedir. Derin öğrenmenin birçok uygulaması, sabit boyutlu bir girdiyi sabit boyutlu bir çıktıyla eşleştirmeyi öğrenen ileri beslemeli sinir ağı yapılarını kullanmaktadır. Bir katmandan diğerine geçmek için, bir birim önceki katmandan girdilerinin ağırlıklı toplamını hesaplamakta ve sonucu doğrusal olmayan bir fonksiyondan geçirmektedir. Çok katmanlı sinir ağının gizli katmanları, ağırlıkların girdilerini hedef çıktıları tahmin etmeyi kolaylaştıracak şekilde düzenlemeyi öğrenmektedir (Bengio ve diğerleri, 2001: 1137).

Yapay sinir ağları alanında yapılan çalışmalarda problemlerin boyutuna bağlı olarak sinir ağına ait gizli katman (hidden layer) ve düğüm sayılarının fazlalaşmasıyla hesaplama yükü oldukça artmıştır. Söz konusu hesaplama yüküne karşın bilgisayarların donanım ve yazılım imkânlarının yetersizliğinden dolayı bu çalışmalar yakın zamana yaygın şekilde kullanılamamaktaydı. Günümüzde özellikle donanım ve yazılım sektörlerindeki imkânların artması ile bu tekniğin kullanım alanları günden güne fazlalaşmaktadır (Schmidhuber, 2015: 103). Derin öğrenme, öğrenme sürecini temsil eden çok sayıda nöron katmanından oluşan gelişmiş bir makine öğrenimi tekniğidir. Derin öğrenme büyük ölçekli verilerle işlem yaparak farklı alanlarda birçok başarı göstermektedir (Aldweesh ve diğerleri, 2020: 1). Derin öğrenme mimarileri, farklı katmanlardan oluşan çok katmanlı sinir ağları olarak inşa edilmektedir. Bu yapı girdi, çıktı ve bu katmanları bağlayan bir veya birden fazla gizli katmandan

oluşmaktadır. Tipik bir sinir ağında, katmanlar verileri matematiksel olarak dönüştüren nöronlar aracılığıyla birbirine bağlanmaktadır. Toplam girdiyi, yani girdilerinin ağırlıklı ortalamasını hesaplamakta, sapma verisi eklemekte ve nöronun çıktısını üretmek için sigmoid, rectifier (doğrultucu) veya hiperbolik tanjant gibi doğrusal olmayan bir aktivasyon fonksiyonu uygulamaktadır (Yann LeCun ve diğerleri, 2015: 439; Boulemtafes, Derhab ve Challal, 2020: 24).

Şekil 45: Temel Elementler Yapılı Nöron




Kaynak: Bal Beşikçi, Arslan, Turan ve Ölçer, 2016: 396.

Genel sinir ağı (Neural Network-NN), her biri bir dizi gerçek değerli aktivasyon üreten birbirine bağlı işlemcilerden oluşan nöronlardan oluşmaktadır. Girdi nöronları çevre faktörlerini algılayan sensörlerle aktifleşirken; diğer nöronlar kendisinin bağlı olduğu ve önce gelen aktif haldeki nöronların ağırlıklı bağlantıları yoluyla aktifleşmektedir. Probleme ve nöronların bağlantı şekline bağlı olarak bu tür davranışlar; genellikle doğrusal olmayan şekilde her aşamada ağı toplam aktivasyonunu dönüştürdüğü hesaplama aşamalarının uzun nedensel zincirlerini gerektirebilmektedir. Derin öğrenme sözü geçen birçok aşamada doğru şekilde değerler atamayla ilgilenmektedir. Gözetimli öğrenmede, girdi ile doğru değeri bir gözetmen tarafından verilen çıktı arasındaki eşleşme öğrenilmektedir. Gözetimsiz öğrenmede böyle bir gözetmen bulunmamaktadır. Girdi verisi üzerindeki düzenin keşfi olarak neyin sık neyin seyrek gerçekleştiğinin görülmesi amaçlanmaktadır (Alpaydın, 2018: 8). Gözetimli öğrenmede (Supervised learning-SL), eğitim verisi

kullanılmaktadır. Sonuçları bilinen veri kümesinden yararlanılarak veri kümesi içerisinde etiket bilgisi bulunmayan verilerin sonuçları tahmin edilmektedir. Gözetimli sinir ağı eğitiminin amacı, toplam hatayı en aza indiren olaylara ait ağırlıkları bulmaktır (Schmidhuber, 2015: 86-88). Gözetimsiz öğrenme yöntemi, Kanada İleri Araştırma Enstitüsü'nde (CIFAR) çalışan araştırmacılar tarafından 2006 yılında tanıtılmıştır. Böylece ileri beslemeli derin ağlar alanındaki araştırmalara yeniden başlanmıştır (Geoffrey E. Hinton, 2005: 1765; Ranzato, Poultney, Chopra ve LeCun, 2007: 1137). Geri yayılım yöntemi sayesinde derin model katmanlarındaki ağırlıklar yeniden güncellenerek; daha başarılı değerlerin alınmasına çalışılmaktadır (G. E. Hinton ve Salakhutdinov, 2006: 504).

Şekil 46: Derin Öğrenme ve Diğer Öğrenme Algoritmaları




Kaynak: Ng, 2015: 30.

Derin ağlar, etiketlenmemiş bir veri setinden otomatik öğrenme için gözetimsiz öğrenmeyi uygulayan üretken mimariler, tahmin için kalıpları ayırt etmek amacıyla gözetimli öğrenmeyi uygulayan ayırt edici mimariler ve hem üretken hem de ayırt edici modelleri içeren hibrit mimariler olarak üç ana kategoriye ayrılmaktadır (Deng, 2014: 3-4; Aldweesh ve diğerleri, 2020: 1-2). Derin öğrenme, çok katmanlı ağları kullanan gelişmiş bir makine öğrenimi tekniğidir. Katmanlar, öğrenme süreçlerinin matematiksel hesaplamasını temsil eden nöronlar aracılığıyla bağlanmaktadır (Goodfellow, Bengio ve Courville, 2016: 5). Derin öğrenme, görüntü ve video tanıma, ses işleme, doğal dil işleme, otonom sistemler ve robotik gibi farklı alanlarda üstün başarılar göstermektedir (Hatcher ve Yu, 2018: 24411).

3.4.1. Derin Öğrenme Tekniğinin Ortaya Çıkışı

Derin öğrenme yönteminin başlangıcı, McCulloch ve Pitts' in; insan beyninin çalışma sürecinin taklidi için matematiğe ve sinir mantığı algoritmalarına dayalı sinir ağlarına ait hesaplama modeli oluşturmaya dayanmaktadır (McCulloch ve Pitts, 1943: 115–32). Bu çalışmadan sonra Rosenblatt tarafından 1958 yılında iki katmanlı yapay sinir ağına, gözetimli desen tanıma için algılayıcı (perceptron) oluşturulmuştur (Rosenblatt, 1958: 392–401). 1966 yılında gözetimli çok katmanlı algılayıcılar (MLP) ve katmanlar arası geçişte en küçük kareler yöntemi kullanılmıştır (Ivakhnenko ve Lapa, 1965: 5). 1979 yılında omurgalı canlıların sinir sistemlerinden esinlenilerek gözetimsiz öğrenme yöntemiyle bir sinir ağı geliştirilmiştir (Fukushima, 1980: 193). Bu zamandan sonra derin ağların çoklu katmanlarında hataların geri yayılımı öğrenmesinin eksikliği hissedilmektedir. Derin sinir ağındaki geri yayılım algoritmasının ilk başarılı uygulaması LeCun ve arkadaşları tarafından geliştirilmiştir (Y. LeCun ve diğerleri, 1989: 541). 1992 yılında karışık görüntülerden üç boyutlu nesne tanıma işlemini gerçekleştirilmiştir (Weng, Coher ve Herniou, 1992: 1). 1995 yılında birbirine benzeyen verilerden oluşan iki grubun sınıflandırılması amacıyla destek vektör makinası (SVM) geliştirilmiştir (Cortes ve Vapnik, 1995: 284–85). 1997 yılında uzun kısa süreli hafıza (LSTM) modeli ile tekrarlayan bir sinir ağı önerilmiştir (Schmidhuber ve Hochreiter, 1997: 1735). 2006 yılında yapılan çalışmada ileri beslemeli sinir ağının, bir katmanı her iterasyonda ne şekilde eğitilebildiği gösterilmiştir (G. E. Hinton ve Salakhutdinov, 2006: 504). Bu çalışmadan sonra derin öğrenmeye olan ilgi artmıştır. Yapay zekâ teknolojisi 1940' lı yıllarda başlamıştır, 1980' in ilk yıllarında yerini alt dalı olan makine öğrenmesi tekniklerine bırakmıştır. Makine öğrenmesi tekniklerinin eksiklikleri derin öğrenme yöntemi ile giderilmiştir (Süzen ve Kayaalp, 2018: 7–10).

Şekil 47: Derin Öğrenme Süreci



Derin Öğrenme tekniği 2000 yılında Igor Aizenberg ve arkadaşları tarafından tanıtılmış olup; Hinton tarafından, çok katmanlı ileri beslemeli bir sinir ağının her iterasyonda bir katmanını gözetimsiz kısıtlanmış Boltzmann makinesi kullanarak nasıl eğitebildiği gösterilmiştir. Sonrasında gözetimli bir geri yayılım yöntemi ile hassas ayarlamaların yapabileceği gösterilmiştir (Geoffrey E. Hinton, 2007: 428). Hinton ve arkadaşları sonrasında (Geoffrey E. Hinton, Srivastava, Krizhevsky, Sutskever ve Salakhutdinov, 2012: 1) sinir ağlarında ezberleme durumunu (overfitting) azaltarak öğrenme sürecini daha sağlıklı şekilde gerçekleştirebilmek için “dropout” adı verilen normalleştirme tekniğini kullanmıştır. Bu gelişmelerden sonra Google, Facebook ve Microsoft gibi firmalar derin öğrenme alanına yatırım yapmaya başlamıştır (Şeker, Diri ve Balık, 2017: 49–50).


3.4.2. Derin Öğrenme Yapıları

3.4.2.1. Evrişimsel Sinir Ağları (Convolutional Neural Networks)

Görsel korteksin nörobiyolojik modeli evrişimsel sinir ağları (CNN) modeline ilham vermiştir. Evrişimsel sinir ağlarında, giriş için küçük filtreler kullanılmaktadır. Daha sonra yüksek seviye özellikler çıkarılana kadar alt örneklendirmeler yapılmaktadır. Son alt örnekleme katmanından sonra, nihai sınıflandırmayı elde etmek için birkaç tam bağlı katman kullanılmaktadır (Ravi ve diğerleri, 2017: 4). CNN'ler, büyük boyutlu girdi verilerini çıktı katmanındaki bir grup sınıfta sınıflandırmak için

doğrusal olmayan eşlemelerle birden çok katmanı eğitmektedir. Bir CNN, evrişimli katmanlar ve havuzlama katmanlarından oluşmaktadır. Bunu isteğe bağlı tam bağlı katmanlar izlemektedir. Evrişimli katmanlar, girdi verilerinin daha küçük boyutlu dilimlerini temsil eden filtreleri kapsamaktadır. Filtreler, özellik haritaları oluşturmak için tüm girdide dolaşmaktadır. Havuzlama katmanı daha sonra özellik örneklerinin boyutluluğunu azaltan alt örnekleme yapmak için özellik haritaları üzerinde çalışmaktadır (Patterson ve Gibson, 2017: 128; Aldweesh ve diğerleri, 2020: 5). Evrişimsel katmanlar, geleneksel mimarilerde verinin yeniden yapılandırılmasından kaçınarak doğrudan çok boyutlu girdiler almaktadır. Bu nedenle, CNN'ler görüntüler ve konuşma sinyalleri gibi çok boyutlu verilere iyi bir şekilde uyum sağlamaktadır. Ayrıca, bir CNN, karmaşıklığı azaltan ve öğrenme sürecini hızlandıran diğer derin ağlarla karşılaştırıldığında aynı ağ derinliğine sahip daha az parametre gerektirmektedir (Krizhevsky ve diğerleri, 2012: 1097; Aldweesh ve diğerleri, 2020: 5).

Şekil 48: Evrişimsel Sinir Ağı Katmanları



Kaynak: Amidi ve Amidi, 2018: 1.

İnsan görme sistemini taklit eden CNN kullanılarak; nesne algılama, tanıma, ve sınıflandırma işlemleri etkin şekilde gerçekleştirilmektedir (H. Lee, Grosse, Ranganath ve Ng, 2009: 609; F. J. Huang ve LeCun, 2006: 284). CNN birçok evrişim, örnekleme ve ileri besleme katmanlarından oluşmaktadır (Hu, Huang, Wei, Zhang ve Li, 2015: 2). CNN’ de gizli katman sayısı yüksek tutularak; görüntülerdeki farklı özellikler keşfedilmektedir. Böylece görüntülerde yer alan nesne türleri (insan, hayvan, bitki, araç, bitki vd) ayırt edebilmektedir (Süzen ve Kayaalp, 2018: 12–13). Evrişimsel sinir ağlarında filtreler yardımı ile görüntü dizisinin sol üst tarafından başlanarak, filtrelerde yer alan değerler ile görüntülerde yer alan değerler soldan sağa ve yukarıdan aşağı doğru çarpılıp tek bir sonuç elde edilmektedir. İlk katmandan bir sayı dizisi olan özellik haritası elde edilmektedir. Daha sonra nesnelerin tanımlanması için görüntüye sayısal değerler içeren bir dizi olan eğrilik filtresi uygulanmaktadır. Eğrilik filtresi sağdan sola ve yukarıdan aşağıya olarak piksel bazlı hareket ettirilmektedir. Elde edilen değerler sayesinde görüntülerde yer alan nesneler tanımlanmaya başlamaktadır. Üçgen ve diğer filtreler eğrilik filtresi yerine uygulanabilmektedir. CNN modelinin öğrenme sürecinde; etiketlenmiş çok sayıda resim derin sinir ağına verilmekte ve görüntüler sinir ağına öğretilmektedir. CNN’ de test veri seti kullanılarak; oluşturulan derin öğrenme modelinin öğrenme başarısı test edilmektedir. Bu ağlar nesne tanıma, ses, metin, video ve görüntü işleme, resim başlıklandırma (CNN+RNN) ve hastalık teşhisi gibi birçok çalışmada oldukça başarılı şekilde uygulanmaktadır (Süzen ve Kayaalp, 2018: 13-15).

Evrişimsel sinir ağları bir veya daha fazla evrişimsel katman, ortaklama katmanı ve tam bağlı katmandan oluşan çok katmanlı algılayıcı ağların (MLP) bir türüdür. Evrişimsel sinir ağlarının ilk çalışması 1988 yılında Yann LeCun tarafından yapılan LeNet isimli mimaridir (Le Cun ve diğerleri, 1989: 41–45). LeNet mimarisinde; alt katmanlar, ardışık şekilde konumlanmış evrişim ve maksimum havuzlama katmanlarından meydana gelmektedir. Üst katmanlar da tamamen bağlı çok katmanlı algılayıcılardan (MLP) meydana gelmektedir. CNN, doğal dil işleme, biyomedikal, ses ve görüntü işleme gibi birçok alanda uygulanabilmektedir. Özellikle görüntü işlemede en iyi sonuçlar elde edilmiştir. 2015 yılında geliştirilen AtomNet, ilaç keşfi için geliştirilen ilk derin sinir ağıdır (Wallach, Dzamba ve Heifets, 2015: 1). Google şirketine ait DeepMind tarafından CNN tabanlı geliştirilen AlphaGo derin sinir

ağı modeli, profesyonel oyuncuyu yenebilen ilk programdır (C.-S. Lee ve diğerleri, 2016: 67; Şeker ve diğerleri, 2017: 50).


3.4.2.2. Tekrarlayan Sinir Ağları (Recurrent Neural Network)

Tekrarlayan sinir ağları (Recurrent Neural Network-RNN), 1982 yılında Hopfield tarafından tanıtılan dinamik ileri beslemeli bir sinir ağıdır. Zamana göre sıralı verileri öğrenme yeteneği ile ayırt edilmektedir. Geleneksel ileri beslemeli sinir ağlarında, her birimin çıktısı, aynı birimin girdisi ve önceki çıktısı arasında herhangi bir bağımlılık olmaksızın akım girişine bağlanmaktadır. Konuşma tanıma gibi ardışık verilere veya sensör verisi gibi bazı uygulamalar zaman serisi verilerine dayanmaktadır. Burada her bir örnek, önceki örneklerin analizine bağlıdır. Bu nedenle, geleneksel ileri beslemeli sinir ağı bu tür uygulamalar için uygun olmamaktadır. RNN'ler, verileri zaman serisi olarak modelleyerek bu sorunu ele almaktadır. RNN' deki her gizli birimin çıktısı, geçerli zaman aralığı girdisine ve bir önceki zaman adımının çıktısına dayanmaktadır. Her gizli katmanın, katman çıktısı, bir sonraki zaman adımıyla ilişkilendirilecek aynı katmana geçiren bir geri besleme döngüsünü barındırmaktadır (Lipton, Berkowitz ve Elkan, 2015: 10–11; Aldweesh ve diğerleri, 2020: 4–5).

RNN, bileşenleri arasındaki bağlantıların yönlendirilerek döngü oluşturduğu YSA olarak tanımlanmaktadır. Oluşturulan döngüyle, dinamik ve zamansal davranış gösterilmesini sağlayan bir ağ iç durumu oluşturulmaktadır. Tekrarlayan sinir ağları; ileri beslemeli ağlardan farklı olarak, kendi girdi hafızalarını, girdilere ait rastgele dizileri işlemek için kullanabilmektedirler (Mikolov, Karafiát, Burget, Jan ve Khudanpur, 2010: 1045). RNN' deki temel amaç sıralı bilgileri kullanmaktır. İlk basit tekrarlayan ağ mimarisi Elman tarafından 1990 yılında tasarlanmıştır (Elman, 1990: 184). Görüntülere ait verilerde tüm girdi ve çıktıların birbirinden bağımsız olduğu kabul edilmektedir. Ancak doğal dil işleme gibi zaman değişkeni olan alanlar için bu kabul geçerli olmamaktadır. Tekrarlayan sinir ağı mimarisinin yinelenen (recurrent) olarak adlandırılması, bir dizinin her ögesi için aynı görevi önceki çıktılara bağlı olarak yerine getirmesinden kaynaklanmaktadır (Şeker ve diğerleri, 2017: 50–51). Konuşma ve dil gibi birbirini izleyen girdileri içeren problemlerin çözümünde RNN' leri

kullanmak genellikle daha iyi sonuçların alınmasını sağlamaktadır. RNN' ler bir girdi dizisinin her seferinde bir ögesini işlemekte ve gizli birimlerinde dizinin tüm geçmiş öğelerinin geçmişi hakkında örtülü bilgiler içeren bir durum vektörünü tutmaktadır (Yann LeCun ve diğerleri, 2015: 441).

Şekil 49: Tekrarlayan Sinir Ağı (RNN)



Kaynak: Huaizhi Wang, Lei, Zhang, Zhou ve Peng, 2019: 4.

RNN sıralı bilgileri kullanarak; gizli katmana ait çıktıyı tekrar aynı katmana girdi olarak gönderebilen bir derin öğrenme yöntemidir. Tekrarlayan sinir ağı algoritmasının döngü oluşturabilmesi ve ardışık gerçekleşen olayların birbiriyle anlamlandırılabilmesi özelliklerinden dolayı günümüzde birçok çalışmada tercih edilmektedir. Tekrarlayan sinir ağlarının, tekli giriş-tekli çıkış, tekli giriş-çoklu çıkış, çoklu giriş-tekli çıkış, çoklu sıralı giriş-çoklu sıralı çıkış, çoklu senkronize giriş-çoklu senkronize çıkış olarak 5 farklı yapısı bulunmaktadır (Süzen ve Kayaalp, 2018: 16–17). RNN sıralı bilgilerle çalışacak şekilde tasarlanmıştır. RNN, çıktının konuşma, metin veya DNA dizileri analizi gibi önceki hesaplamalara bağlı olduğu durumlar için önemli bir sinir ağıdır. Önceki bilgileri saklamak için belleği olan RNN' de, yeni verilerin çıktısı, akım ve son geçmiş girdilerden faydalanılarak elde edilmektedir. Önemli olaylar arasında bilinmeyen boyutlarda uzun süreli gecikmeler olduğunda, RNN'nin türü olan uzun kısa süreli hafıza (LSTM) tekniği kullanılmaktadır (Min ve diğerleri, 2017: 853; Boulemtafes ve diğerleri, 2020: 25).

3.4.2.3. Uzun Kısa Süreli Hafıza Ağları (Long Short Term Memory)


Uzun süreli alışkanlıklar ve bağımlılıklar günlük hayatta büyük problemlere yol açmaktadır. Bu durumun önüne geçebilmek için, uzun süreli davranışları öğrenebilen ve tekrarlayan sinir ağı çeşidi olan Uzun Kısa Süreli Hafıza (LSTM) ağları 1997 yılında Schmidhuber ve Hochreiter tarafından geliştirilmiştir (Schmidhuber ve Hochreiter, 1997: 1735). Uzun kısa süreli hafıza ağlarının yapısı, girdi, unutma ve çıktı olarak üç kapı, blok girişi, sabit hata döngüsü, çıktı aktivasyon fonksiyonu ve gözetleme (peephole) bağlantılarından oluşmaktadır. Blok çıktısı tekrar bloğun girdisi ile tüm kapılarına bağlanmaktadır. Unutma kapısı ve gözetleme bağlantıları ilk geliştirilen yapıda bulunmamaktadır. Uzun kısa süreli hafıza ağlarında, modelin durumunu sıfırlaması amacıyla unutma kapısı; öğrenme ve kesin zamanlamaları kolaylaştırmak için gözetleme bağlantıları eklenmiştir. Bu ağlardan, metin işleme ve konuşma konularında çok başarılı sonuçlar alınmaktadır (Şeker ve diğerleri, 2017: 51). RNN ile tahmin edilen bir olayda belli bir süre içerisinde başka olaylar da gerçekleştiği takdirde RNN bu olayın tahminini sağlıklı bir şekilde yapamamaktaydı. Bu duruma uygun çözüm bulunabilmesi amacıyla RNN modeli geliştirilerek LSTM modeli literatüre kazandırılmıştır (Schmidhuber ve Hochreiter, 1997: 1735; Süzen ve Kayaalp, 2018: 19).

3.4.2.4. Kısıtlı Boltzman Makineleri (Restricted Boltzmann Machines)

Kısıtlı Boltzmann Makineleri (RBM) ilk olarak 1986'da Harmony Theory ismiyle literatürde yerini almıştır (Smolensky, 1986: 213–20). Bu araştırmadan uzun zaman sonra hızlı bir öğrenme algoritması olarak tekrar çalışılmıştır (G. E. Hinton ve Salakhutdinov, 2006: 504–06). Kısıtlı boltzmann makineleri girdi seti üzerindeki olasılık dağılımını öğrenebilen bir yapay sinir ağıdır. Aralarında simetrik bağlantı bulunan gizli ve görünür iki parçalı ağdan oluşmaktadır. Kısıtlamasız boltzmann makinelerinin gizli birimleri arasında bağlantı bulunurken; RBM içindeki düğümlerde kendi aralarında bağlantı bulunmamaktadır. Bu sayede RBM genel olarak mevcut olanlardan daha etkili eğitim algoritmalarının oluşmasına yardımcı olmaktadır. Kısıtlı boltzmann makineleri, sınıflandırma, kümeleme, özellik öğrenimi, boyut indirgeme ve

işbirlikçi filtreleme gibi farklı problemler için kullanılan derin öğrenme algoritmasıdır (Şeker ve diğerleri, 2017: 52; Süzen ve Kayaalp, 2018: 24).

Şekil 50: Kısıtlı Boltzman Makinesi (Restricted Boltzmann Machines-RBM)




Kaynak: H. Z. Wang, Wang, Li, Peng ve Liu, 2016: 82.

3.4.2.5. Derin İnanç Ağları (Deep Belief Network)

Derin inanç ağları (DBN), kısıtlı boltzmann makinelerinin yığını olarak tanımlanmaktadır. Kısıtlı boltzmann makinelerinin her katmanı önceki ve sonraki katmanlarla birbirine bağlıdır. Katmanlarda yer alan düğümler kendi aralarında yatay iletişim halindedir. RBM modelinde softmax katmanı son katman olarak bulunmaktadır. Derin inanç ağlarının, gözetimsiz öğrenme veya sınıflandırma teknikleri için kümeleme yetenekleri bulunmaktadır. Derin inanç ağları görüntü tanıma ve üretme alanlarında kullanılmaktadır (Şeker ve diğerleri, 2017: 52). Derin inanç ağları ilk olarak Hinton tarafından geliştirilmiştir. Kısıtlı boltzmann makinelerinden (RBM) oluşan, farklı katmanlar arasında çift yönlü ve simetrik bağlantıları olan üretken bir modeldir. RBM makinesi, stokastik bir sinir ağı görevini üstlenmektedir. Şekil 50' de yer alan, v ve h olarak görünür ve gizli katmanların belirtildiği bir Boolean görünür nöron katmanı ve bir çift ikili gizli ünite katmanlarından oluşmaktadır. İlgili önyargıları a ve b temsil etmektedir. Bir RBM' nin temel amacı, konfigürasyonu istenen özellikler gösterebilmesi için girdi veri alanı üzerindeki bir olasılık dağılımını öğrenmektir (H. Z. Wang ve diğerleri, 2016: 89), (H. Wang ve diğerleri, 2019: 3–4).

Şekil 51: Derin İnanç Ağları (Deep Belief Network-DBN)



Kaynak: H. Z. Wang ve diğerleri, 2016: 82.

3.4.2.6. Derin Oto-Kodlayıcılar (Deep Autoencoders)

Otomatik kodlayıcı, aynı sayıda girdi ve çıktı düğümüne sahip olan ve bir sınıf etiketi atamak yerine girdi vektörünü yeniden oluşturmak için tasarlanmış bir sinir ağıdır. Çalışmalarda büyük boyutlu girdi verileri altında, tek bir gizli katmana sahip bir otomatik kodlayıcı tüm verileri temsil etmek için yeterli olmayabilmektedir. Bu sorunla başa çıkmak için, birçok oto kodlayıcıyı üst üste istifleyerek bir DAE mimarisi oluşturulmakta ve genellikle derin inanç ağları (DBN) ile önceden sorgulanmaktadır. Doğrusal olmayan bir özellik çıkarma yöntemi olarak kabul edilen DAE, genellikle boyut azaltımı ve etkili kodlama öğrenimi için kullanılmaktadır (Deng, 2014: 5).

Oto-kodlayıcılar bir veri kümesine ait boyut indirgemesi için temsil (kodlama) işlemini öğrenmektedir. Girdi verisinin sıkıştırılmış modundan veriye ait özellikleri öğrenen bir ileri beslemeli sinir ağı mimarisidir. Otokodlayıcılar, girdi verilerinde şifreleme ve şifre çözmeden sonra çıktı olarak tekrar aynı girdiyi görene kadar ağırlıkları defalarca güncellemektedir. Hedefe ulaşıldığında gizli katmandaki düğüm sayısı ile girdi verisi temsil edilebilmektedir. Birden fazla otokodlayıcı katmanı bulunduran sinir ağlarına derin oto-kodlayıcı denilmektedir (Şeker ve diğerleri, 2017: 52). Derin oto kodlayıcılar, birden fazla katmandan oluşan ve girdileri çıktı olarak üreten derin öğrenme algoritmasıdır (Baldi, 2012: 37–38). Liou ve arkadaşları edebi eserlerdeki kelimeler için Elman ağına çalışan geliştirilmiş bir eğitim yöntemi ile bir otomatik kodlayıcıyı incelemiştir (Liou, Cheng, Liou ve Liou, 2014: 84). Çalışmada, verilen girdiye en çok benzeyen çıktıyı üreten ve veriye ait önemli bilgileri içeren

fonksiyonun bulunması amaçlanmaktadır. Bu modelde girdi ve çıktı katmanlarında bulunan nöron sayıları birbirine eşittir. Bu durum bazı sistemler için verinin ezberlenmesine ve istenmeyen sonuçlar elde edilmesine neden olabilmektedir. Ezberleme probleminin önlenmesi amacıyla; gürültü giderici oto-kodlayıcı modelinde, girdi verilerine çeşitli gürültüler eklenerek, çıktı katmanında gürültüsüz girdi değerleri üretilmektedir. Bu şekilde eğitim veri setinde bulunmayan farklı örüntülere sahip verilerde öğrenebilmektedir. Derin oto-kodlayıcıların amacı, büyük boyutlara sahip özellik vektörünü; minimum kayıpla küçük boyutlu vektöre dönüştürmektir. Bu model sınıflama işlemi yapamamaktadır. Derin oto kodlayıcılar, görüntü ve ses işleme operasyonlarında boyut azaltma ve gürültü giderme işlemleri için kullanılmaktadır. Veri sıkıştırma ve öznitelik çıkarma işlemlerinde bu sebeple sıklıkla kullanılmaktadır (Süzen ve Kayaalp, 2018: 25-28).

3.4.3. Literatürde Derin Öğrenme ve Yapay Sinir Ağı Çalışmaları

Bilgi tabanlı sistem, üretim sisteminin planlama ve tasarım aşamasında karar vermeyi desteklerken; makine öğrenimi (ML) tabanlı yaklaşımlar, üretim süreçlerini optimize etmek için büyük bir potansiyele sahiptirler. Bu bağlamda, süreç kontrolü, kalite yönetimi ve öngörülü bakım üç ana uygulamayı temsil etmektedir. Makine öğreniminin proses kontrolünde uygulanmasıyla; değişen koşullara daha iyi adapte olunması ve hata oranlarının düşürülürken çıktı kalitesinin artırılması beklenmektedir. Kalite yönetiminde, ML tabanlı modeller, ürün kalitesini izlemek veya tahmin etmek için kullanılabilir. Böylece rastgele örnekleri kontrol etmek gibi kalite önlemlerinin alınmasına gerek kalmamaktadır. Proses kontrolünün aksine, kalite yönetimi nihai ürüne odaklanacaktır. Tahminsel bakım konusunda da ML algoritmaları makinelerin ve/veya ekipmanların durumunu tahmin edebilmekte ve bakım veya takım değişiklikleri için en uygun zamanı saptayabilmektedir (Mayr ve diğerleri, 2018: 43). Veri bilimi sayesinde, makinelerde, teçhizatlar ve süreçlerde ekonomik kayıplara ve güvenlik sorunlarına neden olan anormal davranışlar ve arızalar etkin şekilde tahmin edilebilir; bu durumlara engel olunabilmektedir. Diez Olivan ve arkadaşları çalışmalarında, endüstriyel araştırmalar için veri füzyonu ve makine öğrenimindeki son gelişmeler hakkında kapsamlı bir araştırma sunmaktadır.

Araştırma eğilimlerinin, fırsat alanlarının ve keşfedilmemiş zorlukların belirlenmesine vurgu yapılmaktadır (Diez-Olivan ve diğerleri, 2019: 92). Boulemtafes ve arkadaşları üst düzeyde gizlilik koruma görevleri ve temel düzeydeki teknolojik kavramları temel olarak güncel teknolojiler hakkında özel önyargıları kategorize etmektedir. Yöntem olarak derin öğrenme tekniklerini ve çok katmanlı sınıflandırmayı önermektedir (Boulemtafes ve diğerleri, 2020: 21).

Slomp ve Klingenberg, delme işlemleri için kuvvet-yer değiştirme grafiğinden kaliteyi belirten özellikleri elde etmek için yapay sinir ağı kullanan bir kontrol sistemini önermektedir (Slomp ve Klingenberg, 2004: 556). Rahman ve arkadaşları çalışmalarında metal damgalama işlemlerinde oluşan hataların tanımlanmasını incelemektedir. Denetimli öğrenme modellerinde yapay sinir ağı, üretim sürecindeki istatistiksel özellikleri girdi verileri olarak kullanarak bir kalıp tanıyıcı görevi görmektedir. Yapay sinir ağı proses kontrolü, kalite yönetimi ve öngörülü bakım için kullanılabilir (Rahman, Masood ve Rahman, 2016: 1–2; Mayr ve diğerleri, 2018: 45). Qu ve arkadaşları şanzıman arızalarının tespiti için titreşim sensörleri ve akustik emisyonlar arasındaki karşılaştırmada (Qu ve diğerleri, 2014: 1372–73); Zhou ve arkadaşları da hata seviyesini tanıma ve hata kaynağını belirleme işleminde hiyerarşik derin sinir ağına dayanan model önermiştir (F. Zhou, Gao ve Wen, 2017: 1). Borkowski ve arkadaşları makine öğrenme tekniklerini kullanarak; iş süreçlerinde olay tabanlı hata tahmini yapmıştır (Borkowski ve diğerleri, 2019: 220). Kraus ve arkadaşları işletme analitiği için derin öğrenme tekniğini operasyonel bakış açısıyla incelemektedir. Çalışmalarında iş analitiği araştırmacılarının ve uygulayıcıların derin sinir ağları kullanmaları gerektiğine dair öneriler sunulmaktadır. Bunun yanında mevcut kullanım durumları, gereksinimler ve faydaların gözden geçirilmesi için tavsiyelerde bulunmaktadır. Gerçek hayat verileriyle farklı vaka çalışmalarında yöneylem araştırmasına olan katma değer incelenmiş; hesaplamalı deneylerin, hazır mimarilerin çoğu zaman yetersiz olduğu ve derin gömülü ağ önerilerek özelleştirilmiş mimarilerin değeri vurgulanmıştır (Kraus, Feuerriegel ve Oztekin, 2020: 628).


El Achi ve arkadaşları lenfoma tanısına ait model oluşturmak üzere evrişimli sinir ağı (CNN) algoritmasını kullanmıştır. Çalışmada görüntü-görüntü tahmini için % 95 ve set-by-set tahmini için % 100 başarı elde edilmiştir (Achi ve diğerleri, 2019: 153). Wang ve Guo çalışmalarında yüz tanıma problemi için derin öğrenme

tekniklerini kıyaslamaktadır. Derin öğrenme uygulamaları olarak UC Berkeley'den Caffe (Jia ve diğerleri, 2014: 675), Google'dan TensorFlow (Abadi ve diğerleri, 2016: 265) ve Facebook'tan PyTorch (Paszke ve diğerleri, 2019: 1) gibi birçok platform bulunmaktadır. Derin sinir ağlarını eğitmek karmaşık bir süreç olup; eğitim sürecini ve değerlendirme performansını etkileyebilecek birçok faktör bulunmaktadır (Q. Wang ve Guo, 2019: 1). Kim ve arkadaşları finansal risk yönetimindeki kararları desteklemek için derin öğrenme yöntemini incelemektedir. Çalışmada, perakende yatırımcıların spread-ticaret piyasasındaki davranışlarını ve gelecekteki işlemlerden kâr sağlayıp sağlamadıklarını tahmin etmek için yakın zamanda geliştirilen derin öğrenme yöntemleri uygulanmaktadır (A. Kim ve diğerleri, 2020: 220). Yang ve arkadaşları, akıllı şebeke güvenilirliğini artırmak amacıyla gelecekteki talep belirsizliklerinin belirlenmesine için bir derin topluluk öğrenme (deep ensemble learning) modelini önermektedir (Y. Yang, Hong ve Li, 2019: 1). Li ve arkadaşları, güç kaynağı ile talep arasında çok yönlü etkileşimlerin yanı sıra siber ve fiziksel unsurlar arasında sıkı bir bağlantı içeren aktif dağıtım ağlarının güç kayıplarını yönetmek için derin öğrenme yöntemlerinden yararlanarak üç aşamalı karar verme çerçevesi önermiştir (D. Li, Tan, Yu ve Li, 2021: 1).

Boullé ve arkadaşları kesikli ve sürekli dinamik sistemler tarafından üretilen tek değişkenli zaman serilerini kaotik veya kaotik olmayan davranışlarına göre sınıflandırmak için standart derin sinir ağlarını kullanmıştır. Gerçek hayat problemlerinden bazıları için farklı sinir ağları eğitilerek sınıflandırma işlemleri gerçekleştirilmiştir (Boullé, Dallas, Nakatsukasa ve Samaddar, 2020: 3). Çeşitli cihazlardan ve iletişim protokollerinden aktarılan verilerin büyük oranda artması, gelişmiş saldırı tespit sistemlerinin (intrusion detection systems-IDS) geliştirilmesine ait önemi arttırmaktadır. Üstün avantajları sayesinde izinsiz gerçekleşen giriş tespitleri için derin öğrenme tekniği birçok araştırmada kullanılmaktadır. Aldweesh ve arkadaşlarının çalışmasında, önceki derin öğrenme modeli odaklı siber güvenlik çalışmaları gözden geçirilmiş ve karşılaştırılmıştır. Mevcut son teknoloji derin öğrenme tabanlı IDS' leri girdi verileri, algılama, dağıtım ve değerlendirme stratejileri de dâhil olmak üzere farklı yönlelere göre sınıflandıran yeni bir çalışma sunulmaktadır. Saldırı tespitinde derin öğrenmenin rolü, izinsiz giriş tespit veri setlerinin etkisi ve önerilen yaklaşımların etkinliği araştırılmıştır (Aldweesh ve diğerleri, 2020: 1).

Muhammed ve Shaikh çalışmalarında kablosuz sistem ağı hata bulma tekniklerini sınıflandırmıştır (Muhammed ve Shaikh, 2017: 271). Kullanılan teknikler diğer şebeke sistemlerinde gerçekleşen hataların analizinde de kullanılabilir.

Şekil 52: Kablosuz Sistem Ağı (WSN) Hata Bulma Teknikleri




Kaynak: Muhammed ve Shaikh, 2017: 271.

Mayr ve arkadaşları yapay zekâ (AI) teknolojilerinin birçok endüstriyel sektörde kullanılmasına rağmen, önemi giderek artan elektrikli araçların üretimi için bu teknolojilere ait çalışmaların istenilen seviyede olmadığını vurgulamaktadır (Mayr ve diğerleri, 2018: 43). Zhang ve arkadaşları sabit akım deşarjı altında pillerin sağlığını ve kalan yararlı ömürlerini tahmin etmek için YSA ve kısmi artan kapasite yöntemlerini kullanmıştır. Önerilen yöntemlerle yüksek güvenilirlik ve doğruluk tahminleri yapılmıştır (S. Zhang ve diğerleri, 2019: 1). Marugán ve arkadaşları rüzgâr

enerjisi sistemlerinde kullanılan YSA' ların kapsamlı şekilde incelemesini sunmaktadır. Araştırmacılar uygulamalar için en çok kullanılan yöntemleri belirlemekte ve YSA' ların birçok durumda geleneksel yöntemlere alternatif olabileceğini göstermektedir. Çalışmada yapılan literatür taramasına göre, yapay sinir ağının rüzgar türbinlerine uygulanmasındaki temel zorluklar ve teknolojik yetersizlikler açıklanmaktadır (Marugán ve diğerleri, 2018: 1822). İyi tasarlanmış durum tabanlı bakım yönetimi (condition based management-CBM), gereksiz bakım faaliyetlerini önleyerek maliyetleri azaltmakta olup; sisteminin çalışmama süresi ve beklenmedik arızaları en aza indirmektedir. Lu ve arkadaşları duruma bağlı olan bileşenler arasında ekonomik bağımlılığın bulunduğu açık deniz rüzgâr türbinleri için rekabetçi bir CBM yaklaşımını önermektedir. Çalışmada, yaşam yüzdesini tahmin etmek için durum bilgisi kullanılarak yapay sinir ağı geliştirilmiştir. Bileşenin tahmin edilen arıza-zaman dağılımından türetilen koşullu hata olasılık değeri, rüzgâr türbinlerinin arızasını temsil etmek için hesaplanmıştır (Lu ve diğerleri, 2018: 69).

Şekil 53: Deniz Rüzgâr Türbini Bileşen Ömrünün Tahmini İçin YSA Modeli




Kaynak: Lu ve diğerleri, 2018: 72.

Yapay sinir ağı, bileşenlerin yaşı, durum izleme verileri ve bileşenlerin yaşam yüzdesi arasındaki ilişkiyi modellemek için kullanılmıştır. Rüzgâr türbinlerinin titreşim ve sıcaklık verileri YSA modelinin oluşturulması için ölçüm olarak seçilmiştir. İleri besleme ağı modeli, bir giriş katmanı, bir çıktı katmanı ve iki gizli katmandan oluşan dört katmanlı yapıya sahiptir. Yapay sinir ağı eğitimi, test sürecinde

en iyi eğitime karşılık gelen en küçük eğitim hatasını arama sürecidir. Eğitim hatası ağırlık ve önyargılara bağlı olarak minimuma indirilerek gerçek ve tahmini yaşam yüzdesi arasındaki fark gösterilmektedir (Lu ve diğerleri, 2018: 72-73).

Şekil 54: Öngörülü Arıza Tahmininde Kullanılan Yapay Sinir Ağı Modeli



Kaynak: Lu ve diğerleri, 2018: 73.

Mousavian ve arkadaşları elektrik sistemi iletim verileri ile ilişkili siber saldırılara karşı riskleri araştırarak sinir ağı tabanlı bir koruma yöntemini önermektedir. Önerilen model, güç akışı hesaplamalarının çıktısını izleyebilmekte ve veri anormalliklerini gerçek zamanlı olarak tespit edebilmektedir. Çalışmada siber saldırıların verdiği büyük hasar ve kayıplar nedeniyle; güç şebekesine yapılabilecek fiziksel saldırılar kadar tehlikeli olabileceği belirtilmektedir (Mousavian, Valenzuela ve Wang, 2013: 285). Silva ve arkadaşları elektrik güç dağıtım sistemindeki yüksek empedans arızalarını tahmin etmek için gerçek verilere dayalı bir artımlı öğrenme algoritması kullanmıştır. Arızaları tespit etmek ve sınıflandırmak için önerilen sistemin etkinliği çok katmanlı yapay sinir ağı, olasılıklı yapay sinir ağı ve destek vektör makinesi (SVM) yöntemleri ile karşılaştırılmaktadır. Çalışmanın sonuçları önerilen sistemin değişiklikler için uygun olduğunu belirtmektedir (Silva ve diğerleri, 2018: 474). Günümüzde tüm sektörlerde elektrik enerjisi sistemleri konusunda önemli ilerlemeler kaydedilmektedir. Yenilenebilir enerji kaynakları, artan etkileri, müşteri sayısını ve uygun yeşil enerji politikaları elektrik sisteminin gelişimini tetiklemektedir. Bu gelişmeler ışığında Saviozzi ve arkadaşları dağıtım yönetim sistemlerinin

gerektirdiği yük tahmini ve yük modelleme süreçlerinin işlevselliğini arttırmak için YSA kullanmaktadır (Saviozzi, Massucco ve Silvestro, 2019: 230).


Dozić ve diğerleri AB' nin mevcut enerji politikasına dayanarak 2050 yılına kadar CO₂ emisyonlarını tahmin etmek için yapay sinir ağı modeli geliştirmiştir. Çalışma ile YSA, CO₂ emisyonlarının davranışını tahmin etmede etkili olmuştur. Ayrıca CO₂ emisyonlarının planlı şekilde azaltılmasını sağlamak için göstergenin değerini 2050 yılına kadar değiştirerek, ekonomik ve enerji stratejisinin zamanında iyileştirilmesini sağlamaktadır (Dozić ve Urošević, 2019: 448). Khwaja ve arkadaşları kısa süreli elektrik yükü tahminini iyileştirmek için ANN tabanlı topluluk makine öğrenmesi yöntemini kullanmıştır. Önerilen yöntem yapay sinir ağını eğitmek için hem güçlendirmeyi hem de torbalama tekniğini birleştirmektedir. Çalışmada bir grup çoklu YSA modeli paralel olarak eğitilmiştir. Son tahmini yükü elde etmek için bu modellerin tahmini yüklerinin ortalaması alınmıştır (Khwaja, Anpalagan, Naeem ve Venkatesh, 2020: 1). Rüzgâr hızı tahmini ile ilgili ilk araştırmalar genellikle sayısal ve fiziksel matematiksel modeller kullanılarak yapılmıştır (Carta, Ramirez ve Velazquez, 2009: 933). Lawan ve arkadaşları Sibu' da rüzgâr enerjisi potansiyelini araştırmak için topografik makine öğrenimi kullanarak bir rüzgâr durumu tahmin modelini önermektedir. Kara temelli yapay sinir ağına geliştirildiği çalışmada, modelin uygulandığı alanlarda rüzgar hızı değerlerinin başarılı bir şekilde tahmin edilebileceği tespit edilmiştir (Lawan, Abidin ve Masri, 2019: 21). Gardner ve Dorling atmosfer bilimlerinde bir çeşit yapay sinir ağı olan çok katmanlı perceptronun son uygulamaları için genel bir tartışma sunmaktadır (Gardner ve Dorling, 1998: 2627).

Shen ve arkadaşları, kısmi bir şarj sırasında voltaj, akım ve şarj kapasitesi ölçümlerine dayalı olarak pil hücre seviyesine ait kapasite tahmini için derin evrimsel sinir ağını (DCNN) kullanmıştır. Model, şarj sırasındaki ölçümleri kullanarak pil kapasitesini doğru şekilde tahmin etmeyi sağlayan yerel bağlantı ve paylaşılan ağırlıkları içermektedir (Shen, Sadoughi, Chen, Hong ve Hu, 2019: 1). DCNN, hücrenin kapasitesi ile yüke bağlı girdi değişkenleri arasındaki ilişkiyi öğrenmek için kullanılmıştır. DCNN regresyon modeli, çevrimdışı olarak eğitildikten sonra, bir hücrenin bilinmeyen kapasitesini, kısmi şarj döngüsü sırasında voltaj ve akım ölçümleri örneğinden çevrimiçi olarak çıkarmak için kullanılmıştır. Son olarak evrimsel katman sayısının ve girdi büyüklüğünün DCNN' nin doğruluğu üzerindeki

etkisi deneysel olarak araştırılmıştır. Evrişimsel katmanların sayısı değiştirilerek ve kapasite tahmininin doğruluğundaki değişiklikler gözlemlenerek daha derin sinir ağlarının daha sık sinir ağlarına göre performansları ölçülmüştür (Shen ve diğerleri, 2019: 3). Fotovoltaik (PV) güç üretimi için doğru tahmin, nihai tüketiciler için yüksek kaliteli elektrik enerjisi sağlamak ve güç sisteminin güvenilirliğini artırmak için önemlidir. Li ve arkadaşları enerji sektöründeki başarılı sonuçları nedeniyle, dalgacık paket ayrıştırma (WPD) ve uzun kısa süreli hafıza (LSTM) ağlarını birleştiren; beş dakikalık aralıklarla bir saatlik ileri PV güç tahmini için hibrit bir derin öğrenme modelini önermektedir. Tahmin sonuçlarının doğruluğunu artırmak için bazı temel meteorolojik faktörler girdi değişkenleri olarak kullanılmıştır (P. Li, Zhou, Lu ve Yang, 2020: 1–7). Zhang ve arkadaşları çalışmalarında bulut bilişim ve derin öğrenme tekniklerini kullanarak akıllı güç dağıtım hizmeti mimarisini tasarlamıştır (W. Zhang ve diğerleri, 2018: 239).

Yenilenebilir enerjinin tahmin doğruluğunu geliştirmek için fiziksel modeller, istatistiksel yöntemler, yapay zeka teknikleri dahil olmak üzere çeşitli yöntemler geliştirilmiştir. Bu yöntemler arasında makine öğrenimi türü olan verilerdeki doğal doğrusal olmayan özellikleri ve yüksek seviyeli değişmez yapıları keşfeden derin öğrenme konusunda literatürde çok sayıda çalışma bulunmaktadır (H. Wang ve diğerleri, 2019: 1). Derin öğrenme yöntemi örüntü tanıma, görüntü işleme, arıza tespiti, sınıflandırma ve tahmin problemlerinde yaygın olarak kullanılmaktadır (Helbing ve Ritter, 2018: 189). Literatürde yenilenebilir enerji tahmini için derin evrişimli sinir ağı ve derin tekrarlayan sinir ağı teknikleri sıklıkla kullanılmaktadır (H. Wang ve diğerleri, 2019: 2–3).

Şekil 55: Yenilenebilir Enerji Tahmini için Genel Çerçeve



Kaynak: H. Wang ve diğerleri, 2019: 5.

Wu ve Wang araştırmalarında mikro şebekelerdeki dağıtılmış enerjinin yönetimini optimal bir kontrol problemi olarak ele almaktadır. Çalışmada sistem kontrol teorisi kullanılarak; mikro şebekelerde dağıtılmış enerjinin gerçek zamanlı yönetimine ait model önerilmektedir. Bu model için derin öğrenme uyarlamalı dinamik programlama üzerinde durulmaktadır (Wu ve Wang, 2018: 1169). Žarković ve Stojković' in yaptığı çalışmada; yüksek gerilim SF6 devre kesicilerinin sağlık değerlendirmesi için ileri yapay zekâ yöntemleri sunulmaktadır. Makale, yüksek voltajlı SF6 devre kesicilere ait en önemli göstergelerin izlenmesi ve arıza teşhisine genel bir bakış sunmaktadır. Çalışmada yeni sağlık değerlendirmesi için yapay zekâ tarafından kullanılabilecek gösterge limit değerlerini belirlemeye odaklanılmaktadır. Devre kesicilerin bakımında karar verecek bulanık uzman sistemler oluşturulmuştur. Yüksek gerilim devre kesicileri benzer durum ve arıza olasılığı olan gruplara ayırmak ve sınıflandırmak için k-ortalama küme yöntemi ve küme ağacı aracılığıyla denetimsiz makine öğrenmesi teknikleri uygulanmıştır. Gözetimli makine öğrenmesi olan yapay sinir ağı, test edilmiş devre kesicilerin kalan ömrünü ve hızlandırılmış yaşlanmasını tahmin için oluşturulmuştur (Žarković ve Stojković, 2019: 1).

Guo ve arkadaşları derin öğrenme yöntemine dayalı olarak bina enerji tasarrufu için yeni bir arıza teşhis yaklaşımı önermekte ve klima arızası teşhis alanındaki uygulama potansiyelini araştırmaktadır. Parametre optimizasyonu seçim stratejisi ile optimize edilmiş modelin arıza teşhisi doğruluk oranı % 97.7 olarak gerçekleşmiştir. Veri özelliklerinin yeniden yapılandırılması için denetimsiz kısıtlı Boltzmann makine

katmanının arıza teşhis performansının iyileştirilebileceği vurgulanmıştır (Y. Guo ve diğerleri, 2018: 732). Konstantakopoulos ve arkadaşları akıllı bina sakinleri arasında enerji tasarruflu davranışlarını teşvik etmek için tasarlanmış bir sosyal oyun deneyinin yüksek boyutlu verilerini kullanmıştır. Araştırmacılar çalışmalarında öngörü performansını iyileştirmek için, çift yönlü tekrarlayan sinir ağları ile derin öğrenme yöntemini kullanarak uçtan uca eğitimden yararlanmıştır (Konstantakopoulos ve diğerleri, 2019: 810). Rüzgâr türbini çalışma durumunun erken arıza tespiti yöntemleri kullanılarak sürekli izlenmesi türbin güvenilirliğini artırmakta ve tehlikeli bir aşamaya gelmeden bakım maliyetlerini düşürebilmektedir. Zhao ve arkadaşları çalışmalarında rüzgâr türbini bileşenlerinin anormallik tespiti ve hata analizini elde etmek için derin öğrenme yöntemini önermektedir. Çoklu kısıtlı Boltzmann makineleri (RBM) kullanan bir derin oto kodlayıcı (DAE) ağ modeli oluşturulmuştur. Rüzgâr türbinlerinden önceden toplanan normal SCADA verileri kullanılmıştır. Elde edilen sonuçlarla arıza bileşenlerinin erken uyarısı yanında arızalı bir bileşenin fiziksel yeri saptanabilmektedir (Zhao, Liu, Hu ve Yan, 2018: 825). Zhang ve arkadaşlarının çalışmasında, akıllı elektrik kutusunda izlenen verilerin buluta aktarıldığı ve açık kaynak kodlu yazılım paketleri kullanılarak bilgi işlem altyapısının oluşturulduğu bulut tabanlı akıllı güç dağıtım hizmeti mimarisi sunulmaktadır. Çalışmada elde edilen gerçek zamanlı elektrik bilgi kontrolü, güç tüketimi izleme ve anahtarların uzaktan kontrolü verileri bir derin öğrenme tekniği olan uzun kısa süreli hafıza (LSTM) kullanılarak analiz edilmiştir. Analiz sonucunda hem klasik SVR tabanlı yaklaşımdan hem de en yeni XGBoost yaklaşımından daha iyi tahmin doğruluğuna ulaşılmıştır (W. Zhang ve diğerleri, 2018: 239).

Geleneksel olarak, makine öğrenme temelli bina enerji tahminleri, tek öğrenme algoritması kullanılarak ve model geliştirme süreci boyunca tek parçalı bir model kullanılarak gerçekleştirilmektedir. Bu geleneksel yaklaşım aynı zamanda tek tahmin yaklaşımı olarak bilinip; yaklaşımının en büyük dezavantajlarından biri her öğrenme algoritmasında yaşanan kararsızlık durumudur. Bina enerji tahmini için çoklu doğrusal regresyon (MLR), yapay sinir ağları (YSA), karar ağacı ve destek vektör regresyon (SVR) gibi çeşitli makine öğrenme algoritmaları kullanılmaktadır. YSA ve karar ağacı gibi öğrenen algoritmalar, girdi verilerinde yapılacak küçük değişiklikler ile çıktı değerlerinde önemli farklılıklar oluşturabilecek kararsız öğrencilerdir. Bu kararsızlık

gerçek zamanlı, saha içi uygulamalarda bu algoritmaların uygulanmasını engelleyebilmektedir. Çünkü bazı enerji verimliliği ölçümleri, tahminlerin güvenilirliğine bağlıdır. Kararsızlık kısıtının üstesinden gelmek ve tahmin doğruluğunu arttırmak için ensemble (topluluk) öğrenme kavramı, sınıflandırma ve regresyon problemleri için uygulanmaya başlanmıştır. Topluluk tahmin modeli, çıktıları bir tahmin için birleştirilen, sinir ağları ve karar ağaçları gibi tek tek eğitilmiş temel modellerden oluşmaktadır. Çeşitli veri kümeleri ve tahminleri birleştirerek uygun öngörü performansı nedeniyle, topluluk tahmin yaklaşımı, özellikle veri sınıflandırma, arıza teşhisi ve sistem yük tahminleri gibi pek çok alanda araştırmalarda yer almaktadır. Wang ve arkadaşları kararsızlığı hafifletmek ve tahmin doğruluğunu arttırmak için meteoroloji sistemlerinden, bina seviyesindeki doluluk ve sayaçlardan elde edilen veriler kullanılarak grup öğrenme tekniğini (Ensemble Bagging Trees-EBT) kullanmıştır (Z. Wang, Wang ve Srinivasan, 2018: 110-11).

Mumtaz ve Qayyum çalışmalarında beyindeki sinir hücreleri tarafından uyanıklık ve uyku halinde üretilen elektriksel faaliyetleri derin öğrenme yöntemi ile incelemiştir. Bu yöntem sayesinde depresif-sağlıklı tanılarını belirleyen modeller geliştirilmiştir. Çalışmalarında tek boyutlu evrişimli sinir ağı ve LSTM teknikleri kullanılmıştır (Mumtaz ve Qayyum, 2019: 1). Yıldırım ve arkadaşları, uyku evrelerinin sınıflandırılması için uçtan uca eksiksiz bir mimariye sahip 19 katmanlı tek yönlü CNN (1D-CNN) modelini önermektedir. Model, farklı uyku sınıflarında yüksek tanıma performansı ile çalışmaktadır (Yıldırım, Baloglu ve Acharya, 2019: 18). Erdenebayar ve arkadaşları uyku apnesi (SA) olaylarını bir elektrokardiyogram (EKG) sinyalinden otomatik olarak tespit etmek ve en uygun yöntemi bulmak amacıyla derin öğrenme yaklaşımlarını kullanmıştır. SA olaylarının otomatik tespiti için altı derin öğrenme yaklaşımı tasarlanmış ve uygulanmıştır. Tasarlanan derin öğrenme modelleri analiz edilmiş ve performansları karşılaştırılmıştır. Çalışmada 86 SA hastasından toplanan veri seti kullanılmıştır. Eğitim seti için hastaların 69' undan elde edilen veriler, test seti için ise diğer 17 hastanın verileri kullanılmıştır. En iyi performans gösteren modelin doğruluğu %99 olarak gerçekleşmiştir (Erdenebayar, Kim, Park, Joo ve Lee, 2019: 1).

3.5. HEDEF PROGRAMLAMA (GOAL PROGRAMMING)

Karar verme, günlük hayatta süreç ve operasyonların tamamının gerçekleştirilebilmesi için her an ihtiyaç duyulan oldukça önemli bir faaliyettir. Kısıtlı kaynaklar ve sahip olunan bilgilerin yetersizliği nedeniyle bazı durumlarda karar verme süreci zorlayıcı olabilmektedir. Karar verme, karar vericinin tercihlerine bağlı olarak; mevcut alternatifler arasından en iyiyi seçme olarak tanımlanabilmektedir. İşletmeler faaliyetlerini sürdürürken daha gerçekçi kararlar vermek amacıyla; kârın maksimizasyonu ve maliyetlerin minimizasyonu haricinde eş zamanlı olarak farklı hedefleri de göz önünde bulundurmak durumundadır. Bu şekilde verilen kararlar, işletmelerin, değişen şartlara uyum ve çeşitli beklentileri eş zamanlı karşılama yeteneklerini geliştirmektedir.

Hedef programlama farklı hedeflerin eş zamanlı olarak gerçekleştirilmesi amacıyla geliştirilen önemli bir yöneylem araştırması tekniğidir. Bu teknikte hedefler gerçekleştirilirken istenmeyen sapma değişkenlerine ait fonksiyon minimum yapılmaya çalışılmaktadır (Caballero, Ruiz, Uría ve Romero, 2006: 139). Hedef programlamada tüm hedeflerin aynı anda gerçekleştirilmesi mümkün olmayabilmektedir. Bu nedenle hedeflerin en iyi şekilde doyurulduğu çözüm elde edilmeye çalışılmaktadır. Hedefler önem derecelerine göre ağırlıklandırılıp; önemi yüksek olan hedefler önem sırasına göre gerçekleştirilmeye çalışılmaktadır. Hedef programlamanın ilk temeli 1955 yılında Charnes, Cooper ve Ferguson tarafından atılmış olup; bu yöntem Charnes ve Cooper'ın 1961 yılındaki çalışmasında açıkça tanımlanmıştır. Sonrasında Ignizio, Lee, Tamiz, Romero ve arkadaşları tarafından bu yöntem geliştirilmiştir (Türkoğlu, 2017: 31). Ignizio tarafından tamsayı ve doğrusal olmayan hedef programlama modelleri ile dualite konularında çalışmalar yapılmıştır (Ignizio, 1978: 1109; Ignizio, 1983: 277; Ignizio, 1985: 507). Günümüze kadar hedef programlama alanında; doğrusal, doğrusal olmayan, tamsayı programlama konularında çalışmalar yapılmıştır. Bulanık hedef programlama modelleri sayesinde hedef programlama modelinde bulunan kesin parametrelerin belirsiz bilgileri gösterilmiştir (Öztürk, 2012: 258–61).

Hedef programlama amaç fonksiyonunun yapısına bağlı olarak; tek hedefli programlama, eşit ağırlıklı çok hedefli programlama, ağırlıklı çok hedefli

programlama, öncelikli çok hedefli programlama ve ağırlıklı öncelikli çok hedefli programlama olarak sınıflandırılmaktadır (Öztürk, 2012: 256). Bu sınıflandırmalara göre genel hedef programlama modelinin yapısı aşağıdaki şekildedir (Öztürk, 2012: 285):

Amaç fonksiyonu

$$\text{Min } Z = \sum_{k=1}^k \sum_{i=1}^m P_k (a_{ik}^+ * d_i^+ + a_{ik}^- * d_i^-)$$

Kısıtlar

$$\sum_{j=1}^n t_{ij} x_j - d_i^+ + d_i^- = b_i \quad (i = 1, 2, \dots, l), (j = 1, 2, \dots, l)$$

$$x_j > 0, \quad d_i^+ > 0, \quad d_i^- > 0$$

P_k : k' inci hedefin önceliği

a_{ik}^+, a_{ik}^- : k' inci önceliğe sahip i' inci hedefe ait sapma değişkeninin ağırlığı

d_i^+, d_i^- : i' inci hedefe ait pozitif ve negatif sapma değişkenleri

t_{ij} : i' inci hedef ve x_j ile ilişkili teknoloji katsayısı

b_i : i' inci hedef düzeyini göstermektedir.

Hedef programlama yöntemi, birden çok amacın eş zamanlı gerçekleştirilerek kararların verildiği birçok sektörde yaygın şekilde kullanılmaktadır. (Javid, Khalili-Damghani, Makui ve Abdi, 2020: 1) ve (Leung ve Chan, 2009: 1053) üretim ve işgücü planlama süreçlerinde, (Gharehgozli, Tavakkoli-Moghaddam ve Zaerpour, 2009: 853; Pang ve Wu, 2014: 192; Güler, 2013: 4906; Moghaddam, 2013: 704) çizelgeleme süreçlerinde, (Mokhtari ve Hasani, 2017: 230; Giri, Maiti ve Maiti, 2014: 160; Abdelaziz, Masri ve Alaya, 2017: 383; Ghoseiri ve Ghannadpour, 2010: 1096) ulaşım ve araç rotalama süreçlerinde, (Aouni, Colapinto ve La Torre, 2014: 536) portföy yönetimi sürecinde, (R. Jia, Liu ve Bai, 2020: 1; Torres-Ruiz ve Ravindran, 2019: 211) tedarikçi yönetiminde, (Jana, Sharma ve Chakraborty, 2016: 134) tarım sektöründe, (Hocine, Zhuang, Kouaissah ve Li, 2020: 642; San Cristóbal, 2012: 4461) enerji alanında yapılan çalışmalardan bazılarıdır.

DÖRDÜNCÜ BÖLÜM

DERİN ÖĞRENME VE HEDEF PROGRAMLAMA YÖNTEMLERİ İLE ÇEŞME ELEKTRİK DAĞITIM AĞININ GERÇEK ZAMANLI ÖNGÖRÜ SİSTEMİNİN OLUŞTURULMASI

Bu çalışmada yapay zeka tekniği olan derin öğrenme modeli ve optimizasyon yöntemi olan hedef programlama modeli hibrit şekilde kullanılmıştır. Derin öğrenme yöntemi, diğer yöntemlerle kıyaslandığında üstün özellikleri nedeniyle diğer sektörlerde olduğu gibi enerji sektöründe de kullanım alanı giderek artan bir tekniktir. Enerji sektöründe gerçekleştirilen önceki çalışmalarda, enerji talep tahmini, batarya ömrü, batarya şarj süresi, rüzgâr santralleri, kullanım ömrü ve elektronik eşya arızaları gibi problemlerin çözümünde kullanılmıştır. Elektrik enerjisi dağıtım ağlarının çalışma durumu ile ilgili önceki yapay zeka çalışmaları genellikle ağın bir bileşeni için lokal olarak modellenmiştir. Elektrik tüketim miktarının ve meteorolojik faktörlerin; elektrik dağıtım şebekelerinin çalışma durumu (sağlıklı/arızalı) üzerindeki etkisini derin öğrenme ve hedef programlama yöntemlerini hibrit kullanarak inceleyen çalışmaya rastlanmamıştır. Bu bölümde İzmir-Çeşme ilçesinin elektrik dağıtım şebekesi ile ilgili vaka çalışması sunulmaktadır. Çalışmada kullanılan veriler Çeşme ilçesine hizmet veren GDZ Elektrik Dağıtım A.Ş., Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) ve Türkiye Devlet Meteoroloji Genel Müdürlüğü'nden 01 Ocak 2017-31 Mart 2019 tarih aralığı için saatlik olarak alınmıştır. Bu kurumlardan elde edilen veriler eşleştirilip oluşturulan veri seti kullanılarak elektrik dağıtım ağının planlanmamış elektrik kesintileri ve sağlıklı çalışma koşulları için derin öğrenme modelleri geliştirilmiştir. Enerji tüketimi ve meteorolojik olay tahminlerine ait gerçek zamanlı veriler, eğitilen derin modeller tarafından kullanılarak, dağıtım şebeke sisteminin gelecekteki çalışma durumlarına ait saatlik tahminler elde edilmektedir.

Çalışmada, elektrik dağıtım ağlarının sistem durumuna etki eden tüm iç faktörlere (enerji tüketim miktarı, trafo özellikleri, kapasite, ekipman özellikleri, markalar, yaş, önceki bakım zamanları, iletim kablosu uzunlukları, kapasiteler..vd) ve dış faktörlere (meteorolojik faktörler, şebeke elemanlarının bulunduğu konumlara ait rakım ve şebeke harici diğer faktörler) ait saatlik dinamik verilerin modele dahil edilmesi hedeflenmiştir. Ancak faktörlerden bir kısmına ait geçmiş dijital veriler,

teknolojik altyapı kısıtlardan dolayı işletmeler tarafından kayıt altına alınamadığından; bu faktörler model dışı bırakılmıştır. Bu durum modellere ait sonuçlardaki başarı düzeyinin istenilen seviyeden düşük olmasına neden olmuştur. Dinamik gerçekleşen enerji tüketimi ve meteorolojik koşullar altında Çeşme ilçesinde kurulu olan elektrik dağıtım ağı incelenmiştir. Gerçek zamanlı olarak, dağıtım ağının arızalı/sağlıklı sistem çalışma durumuna ait tahminlerin oluşturulması, sistem arıza olasılıklarının azaltılması ve güvenlik seviyesinin artırılması hedeflenmektedir. Dağıtım ağının geçmişe ait saatlik arızalı/sağlıklı durum verileri yanında enerji tüketimi ve meteorolojiye ait geçmiş, gerçek zamanlı ve geleceğe ait saatlik tahmin verileri kullanılmıştır. Saatlik verilerden oluşan veri seti ile gerçek zamanlı derin öğrenme modelleri kurulmuştur. Kısıtları ve hedefleri dinamik şekilde güncellenen hedef programlama modelleri kurulmuş ve bu modeller kurgulanan algoritma yardımıyla, derin öğrenme modelleri havuzu ile ilişkilendirilmiştir. Böylece kamu yararı ve dağıtım işletmesi yönünden hedefleri gerçekleştiren derin öğrenme modelinin seçileceği hibrit sistem önerilmiştir.

Çalışma gerçekleştirilirken, GDZ Elektrik Dağıtım A.Ş., TEİAŞ ve Meteoroloji Genel Müdürlüğü bünyesinde kurulu olan Endüstri 4.0 bileşenlerine ait altyapının sağladığı olanaklardan faydalanılmıştır. Nesnelerin interneti teknolojisi sayesinde Çeşme ilçesinde kurulu dağıtım şebekesinin mevcut durumu gerçek zamanlı izlenebilmektedir. Yani t anında enerji iletiminin sorunsuz olduğu ve kesintinin yaşandığı bölgeler konum bazlı anlık izlenebilmektedir. Enerji arzı ve tüketimi dengede tutulabilmektedir. Bulut bilişim sayesinde hem şebeke durumu hem de enerji arz ve talep verileri, ilgili kurumların anlık izleyebileceği şekilde buluta kaydedilip çeşitli raporlamalar alınabilmektedir. Büyük veri sayesinde sürekli akış halinde olan ve sürekli artan veri setleri kaydedilmektedir. Dağıtım işletmesinin büyük veri konusunda şebekeye ait çeşitli verileri standart ve kullanılabilir şekilde kaydetmesinde birtakım eksiklikler bulunmaktadır. İşletme bu durumu iyileştirmek için faaliyetlerine devam etmektedir. Ayrıca büyük verilerden yapay zekâ algoritmaları ve çeşitli veri madenciliği uygulamaları kullanılarak anlamlı bilgi üretme konusunda da eksiklikler bulunmaktadır. Dağıtım işletmesi siber güvenlik konusunda hassasiyet göstermekte olup; T.C. Enerji ve Tabii Kaynaklar Bakanlığı, TEİAŞ, enerji üretim işletmeleri ve enerji perakende işletmesi gibi sürekli bağlantıda olma


zorunluluğu bulunan işletmeler haricinde kapalı ve güvenli bir ağ üzerinden süreçlerini yürütmektedir. Siber güvenlik konusunda da sürekli iyileştirme çalışmaları devam etmektedir. Yatay ve dikey sistem entegrasyonu sayesinde değer zinciri boyunca hem kurum içi operasyonlarda hem de T.C. Enerji ve Tabii Kaynaklar Bakanlığı, TEİAŞ, üretici ve tüketici kanalları arasında gerçek zamanlı iletişim ve bilgi paylaşımı etkin şekilde yürütülmektedir. Böylece talep ve arz seviyesindeki hızlı değişiklikler göz önünde bulundurularak dinamik bir operasyon sistemi oluşturulmaktadır. Dağıtım işletmesinde yapay zekâ teknikleri konusunda mevcut durumda bir çalışma yapılmamıştır. Bu çalışma ile Türkiye genelinde elektrik dağıtım ağlarında gelecekte yapılacak yapay zekâ uygulamalarına örnek teşkil etmesi hedeflenerek; bir yapay zekâ tekniği olan derin öğrenme yöntemi ve hedef programlama algoritması hibrit şekilde kullanılmıştır.

Simulasyon uygulamaları, elektrik dağıtım şebekesinin genişletilmesi veya değişikliği süreçlerinde lokal bazda gerçekleştirilmektedir. Hizmet işletmesi olmanın getirdiği durum nedeniyle mevcut durumda operasyonlarda otonom robotlar kullanılmamaktadır. Operasyonlar insan gücüyle gerçekleştirilmektedir. Robot ve drone teknolojilerinin gelişmesi sayesinde dağıtım ağının montajı, şebeke komponentlerinin değiştirilmesi, arızaların giderilmesi, bakım işlemlerinin yapılması gibi şebekede insan gücü ile yapılan birçok işlem robotlara devredilecektir. Böylece insan hayatı için tehlikeli birçok operasyon robotlarla otonom şekilde gerçekleştirilecektir. Ayrıca Endüstri 4.0 ile tam entegrasyon süreci başarıldığında arıza ve ihtiyaçlar otonom belirlenip operasyonlar otonom şekilde gerçekleştirilecektir. Eklemeli üretim teknolojisinin ilerlemesiyle şebeke komponentleri, dağıtım ağlarının bulunduğu konumun coğrafi şartları gözetilerek, daha uygun tasarımlarla üretilecektir. Şebekelere ait montaj, demontaj, arıza tespit, bakım ve onarım gibi süreçlerde artırılmış gerçeklik uygulamalarının kullanımı operasyonların etkinliğini arttıracaktır.

İlk çağda Cysus adıyla bilinen Çeşme, Anadolu' nun batı kıyısında MÖ 1000 yıllarında kurulduğu tahmin edilen 12 İyonya kentinden biri olan Erythrai (Eritre)' nin ildir iskelesiydi. Çeşme, Türkiye' nin batısında üç tarafı denizlerle çevrili kendi adını taşıyan yarımadanın üzerinde konumlanmaktadır. Doğuda Urla İlçesi, güneyde ve

batıda Ege Denizi, kuzeyde Karaburun İlçesi ile çevrili olup; İzmir' e 80 km ve Sakız Adası' na da 8 mil uzaklıktadır. Kıyı sahil şeridi uzunluğu 133 km' dir.


Şekil 56: Çeşme İlçesi' nin Konumu



Kaynak: Google Maps, Çeşme, 2020.

Akdeniz ikliminin etkisi altında olup; turizm sezonlarında nüfus yoğun ve hızlı şekilde artmaktadır. Arazi genellikle taşlık ve kayalık tepelerden ve az miktarda düzlüklerden meydana gelen küçük ovacıklardan oluşmaktadır. Arazi yapısı genellikle meyillidir. Orman yoğunluğu azdır. Toprak yapısı çakıllı, kumlu, kireçli, bazı bölgelerde de tınlı ve kalkerli satıh fakirdir. İlçenin yüzölçümü 260 km² olup rakımı 5 metredir. Gerek iç ve gerekse dış turizm yönünden Türkiye' nin sayılı plajlarına sahiptir. Nüfusu 44363 olup turizm sezonlarında nüfus 1 milyonu aşmaktadır (Çeşme Kaymakamlığı, 2020).

Şekil 57: İzmir Elektrik Dağıtım Ağı Gerçek Zamanlı Görüntüleme Sistemi



Kaynak: GDZ Elektrik Dağıtım AŞ, TEİAŞ, 2020.


İzmir elektrik dağıtım ağı çalışma durumunun gerçek zamanlı görüntüleme sistemi Şekil 57’ de yer almaktadır. Dağıtım işletmesi mevcut durumda bu sistemden faydalanarak operasyonlarını yönetmektedir.

4.1. KULLANILAN VERİLER

Çalışmada kullanılan veriler ilçeye hizmet veren GDZ Elektrik Dağıtım A.Ş., Türkiye Elektrik İletim A.Ş (TEİAŞ) ve Türkiye Devlet Meteoroloji Genel Müdürlüğü’nden 01 Ocak 2017-31 Mart 2019 tarih aralığı (27 Ay) için saatlik (19681 saat) ham veri olarak elde edilmiştir. Elektrik dağıtım işletmesi İzmir-Manisa il ve ilçelerinde 10000’ den fazla trafonun bulunduğu dağıtım ağı altyapısına sahiptir. Çeşme’ de kurulu olan dağıtım altyapısı 400’ den fazla trafodan oluşmaktadır. İşletme, hizmet verdiği elektrik dağıtım ağını, coğrafi bilgi sistemi tabanlı (CBS) elektrik dağıtım bilgi sistemi yazılım altyapısı ile gerçek zamanlı takip etmektedir. CBS sayesinde veriler gerçek zamanlı toplanmaktadır. Sisteme tanımlanmış olan fiderlerin, trafo ve hatların (alçak gerilim-AG ve orta gerilim-OG) beslediği bölgeler harita üzerinde topoloji kurularak izlenebilmektedir. Elektrik tüketimlerinin, abone dağılımlarının, fidere ait

trafoların ve arızaların raporları gerçek zamanlı alınabilmektedir. Otomatik sayaç okuma sistemi ile enerji tüketimi gerçek zamanlı izlenebilmektedir.

Şekil 58: Çeşme Elektrik Dağıtım Ağı Gerçek Zamanlı Görüntüleme Sistemi



Kaynak: GDZ Elektrik Dağıtım AŞ, TEİAŞ, 2020.

Anlık görüntülenebilen sistem durumuna göre sarı renk kesintileri, mavi renk ihbarları, kırmızı renk ihbar ve bilinmeyen durumları, yeşil renk ise giderilen arızaları temsil etmektedir. Araştırmada 2017, 2018 ve 2019 (Mart ayı dahil) yıllarına ait saatlik veriler kullanılmıştır. 27 Aya ait zaman diliminde toplamda 7085 adet plansız ve istenmeyen elektrik kesintisi meydana gelmiştir. Elektrik kesintileri bölgedeki ekonomik ve sosyal hayatı olumsuz etkilemektedir. Turizm sektöründe de olumsuz durumların yaşanmasına sebep olup; kesinti sırasında jeneratör kullanımı nedeniyle konaklama ve hizmet maliyetlerini arttırmaktadır. Çalışmada kullanılmak üzere GDZ Elektrik Dağıtım A.Ş., TEİAŞ ve Meteoroloji Genel Müdürlüğü’nden elde edilen 27 aya ait saatlik veriler (19681 saat) Tablo 6’da yer almaktadır.

Tablo 6: Çalışmada Kullanılan Saatlik Veriler

Tarih ve Saat	Ortalama Rüzgâr Hızı (m/sn)
Dağıtım Ağı Çalışma Durumu (Arıza Yok/Var)	Rüzgâr Hızı (m/sn)
Elektrik Enejisi Tüketim Miktarı (kWh)	Rüzgâr Yönü (°)
Aktüel Basınç (hPa)	Sıcaklık (°C)
Buhar Basıncı (hPa)	Yağış Miktarı (mm=kg/m ²)

İşba Sıcaklığı (°C)	Enerji Kesinti Süresi (sa)
Max Aktüel Basınç (hPa)	Etkilenen Kullanıcı Sayısı İmar İçi (OG)
Max Nisbi Nem (%)	Etkilenen Kullanıcı Sayısı İmar İçi (AG)
Max Rüzgâr Yönü (°)	Etkilenen Kullanıcı Sayısı İmar Dışı (OG)
Max Rüzgâr Hızı (m/sn)	Etkilenen Kullanıcı Sayısı İmar Dışı (AG)
Max Sıcaklık (°C)	Toplam Etkilenme Süresi İmar İçi (OG)
Min Aktüel Basınç (hPa)	Toplam Etkilenme Süresi İmar İçi (AG)
Min Nisbi Nem (%)	Toplam Etkilenme Süresi İmar Dışı (OG)
Min Sıcaklık (°C)	Toplam Etkilenme Süresi İmar Dışı (AG)
Nisbi Nem (%)	

Tablo 6’ da yer alan veri setleri, otomatik sayaç okuma sistemi (OSOS), elektrik dağıtım bilgi sistemi (EDABİS), ve meteorolojik veri bilgi sunum ve satış merkezinden (MEVBİS) elde edilmiştir. Şekil 59’ da örnek ölçüm istasyonu olarak; İzmir otomatik meteoroloji ölçüm istasyonunun görseli yer almaktadır.

Şekil 59: İzmir Otomatik Meteoroloji Gözlem İstasyonu



Kaynak: Meteoroloji 2. Bölge Müdürlüğü-İzmir. Kişisel Arşiv, 2020.

Farklı kaynaklardan toplanan veriler, tarih ve saat birleşiminden oluşan etiket kullanılarak eşleştirilmiştir. Çalışmanın sağlıklı sonuçlar vermesi açısından oluşturulan veri havuzunda bulunan bozuk, eksik ve gereksiz verilerin yer aldığı kısımlar çıkarılmıştır. Gerekli düzenlemelerden sonra dağıtım ağı çalışma durumu (0:sağlıklı çalışma-1:arıza), elektrik tüketimi ve meteorolojik faktörlere ait veriler derin öğrenme modelleri için 15734 saatlik veri setine dönüştürülmüştür. Son hali verilen veri setinde her etikete ait (tarih ve saat bilgisinden oluşturulan) dağıtım ağının

çalışma durumu (sağlıklı/arızalı), enerji tüketim miktarı ve meteorolojik faktörlere ait değerler bulunmaktadır. Tüm faktörlerin bulunduğu veri seti Tablo 7’ de yer almaktadır.

Tablo 7: Veri Setinin Bir Bölümü

Tarih & Saat	Gün	Arıza Yok:0/Var:1	Tüketim	Aktuel Basınc (hPa)	Buhar Basıncı (hPa)	İsba Sıcaklığı (°C)	Max Aktuel Basınc (hPa)	Max Nisbi Nem (%)	Max Rüzgar Yonu (°)	Max Rüzgar Hızı (m/sn)	Max Sıcaklık (°C)	Min Aktuel Basınc (hPa)	Min Nisbi Nem (%)	Min Sıcaklık (°C)	Nisbi Nem (%)	Ort Rüzgar Hızı (m/sn)	Rüzgar Hızı (m/sn)	Rüzgar Yonu (°)	Sıcaklık (°C)	Yağış Miktarı (mm=kg/m ²)
1-1-2017 3	7	0	43544	1023	5.1	15.8	1023	84	47	4.2	1.3	1022.9	77	0.6	77	2.2	2.2	78	1	0
1-1-2017 10	7	1	42451	1022.5	5	20.7	1022.8	55	35	2.7	11.7	1022.2	41	7.4	43	1.9	1.9	36	8.9	0
1-1-2017 13	7	1	45874	1021.6	5.2	15.8	1021.7	65	358	2.6	8.6	1021.5	53	6.6	53	1.3	1.3	1	6.8	0
1-1-2017 14	7	1	43915	1021.4	6.1	15.8	1021.5	68	31	3	8.5	1021.4	62	5.7	62	1.5	1.5	26	6	0
1-1-2017 15	7	0	41534	1021.5	5.5	15.8	1021.7	75	108	2.4	5.8	1021.4	67	3.8	68	1.7	1.7	99	4.4	0
1-1-2017 16	7	0	39828	1021.8	5.4	15.8	1022	88	104	1.9	3.8	1021.7	76	1.3	71	1.2	1.2	233	2.9	0
1-1-2017 17	7	0	39217	1022	5.4	15.8	1022	91	273	0.7	1.3	1021.8	89	0.1	87	0.5	0.5	328	0.2	0
1-1-2017 18	7	1	41100	1021.8	5.6	15.8	1021.9	92	72	1.9	0.6	1021.7	90	0	90	0.7	0.7	59	0.5	0
.....																				
.....																				
.....																				
31-3-2019 17	7	1	22807	1007.3	7.2	2.5	1007.9	54	24	8.7	12.1	1007.4	51	11.2	52	4.6	4.6	40	12.1	0
31-3-2019 18	7	0	24120	1007.8	6.8	1.7	1008.2	59	50	8.1	11.7	1007.7	52	11.1	51	4.6	4.6	50	11.5	0
31-3-2019 19	7	1	26811	1008.1	7.6	2.1	1008.4	59	54	8	11.7	1008	53	10.5	58	4.4	4.4	10	11.5	0
31-3-2019 20	7	0	29321	1008.1	7	2.4	1008.4	60	37	11.2	11.2	1008.1	57	10.3	57	3.3	3.3	66	10.7	0
31-3-2019 21	7	0	28227	1008.4	7.4	2.8	1008.6	63	61	7.5	10.7	1008.2	60	9.8	60	4.2	4.2	24	10.5	0
31-3-2019 22	7	1	27355	1008.4	7.7	2.9	1008.5	64	47	6.3	10.4	1008.2	63	9.3	63	4.9	4.9	46	10.4	0
31-3-2019 23	7	1	26460	1008.2	7.3	3	1008.3	68	79	3.9	9.4	1008.1	64	9	64	2.5	2.5	65	9.2	0
Toplam 15734 Saatlik Veri Seti																				

4.2. ELEKTRİK ENERJİSİ DAĞITIM AĞI VE METEOROLOJİK FAKTÖRLERE AİT ANALİZLER (ÇEŞME)

Bu bölümde Çeşme ilçesinde yaşanan 27 aya ait elektrik dağıtım ağının çalışma durumu, enerji tüketimi ve meteorolojik faktörleri kapsayan saatlik veriler kullanılarak analizler gerçekleştirilmiştir. Yapılan bu analizler neticesinde şebeke çalışma durumu ve çalışma durumuna etki eden faktörlerin davranışları incelenmeye çalışılmaktadır. Bu bölüm meteorolojik faktörlere ait analizler ve enerji dağıtım ağına ait analizler olarak iki başlık altında incelenmektedir.

4.2.1. Meteorolojik Faktörlere Ait Analizler

Bu bölümde Çeşme ilçesinde Ocak 2017-Mart 2019 tarihleri arasında gerçekleşen meteorolojik olaylara ait temel analizler yer almaktadır.


Analizde 19595 saati kapsayan ilk veri seti kullanılmaktadır.

Tablo 8: Meteorolojik Faktörlere Ait Tanımlayıcı İstatistikler

		Aktuel Basıncı (hPa)	Buhar Basıncı (hPa)	Isba Sıcaklığı (°C)	Nisbi Nem (%)	Rüzgar Hızı (m/sn)	Rüzgar Yonu (°)	Sıcaklık (°C)	Yağış Miktarı (mm=kg/m ²)
N	Valid	19595	19320	16661	19544	19361	19356	19607	18733
	Missing	86	361	3020	137	320	325	74	948
Mean		1012.98	14.22	13.31	71.07	2.39	172.15	17.39	0.08
Std. Err of Mean		0.04	0.04	0.05	0.12	0.01	0.88	0.05	0.00
Median		1012.60	13.40	14.30	70.00	2.10	176.00	17.20	0.00
Mode		1011.20	12.30	19.70	100.00	0.50	360.00	16.50	0.00
Std. Deviation		5.82	5.44	6.07	16.15	1.55	121.75	7.31	0.63
Variance		33.86	29.62	36.87	260.98	2.39	14823.91	53.45	0.40
Minimum		994.20	3.00	-8.60	22.00	0.00	0.00	-2.30	0.00
Maximum		1031.40	28.90	23.70	100.00	11.70	360.00	37.20	31.10


Aktüel basınç atmosfer basıncı olarak adlandırılabilen olup; genel olarak atmosferi oluşturan gazların cisimler üzerine uyguladığı kuvvet olarak tanımlanabilmektedir. Çeşme’ de Ocak 2017-Mart 2019 tarih aralığında gerçekleşen saatlik aktüel basınca ait ortalamanın 1012.98 hPa, standart sapmanın 5.82, min 994.20 hPa ve maks 1031.40 hPa değerlerini aldığı gözlenmektedir. Saatlik aktüel basınç grafiği Şekil 60’ ta yer almaktadır.

Şekil 60: Aktüel Basınç Dağılımı



İlçede özellikle mevsimlere göre değişkenlik gösteren aktüel basıncın minimum ve maksimum değerleri arasındaki makas açıklığı, diğer aylara nazaran Aralık, Ocak, Şubat ve Mart aylarında daha fazla gerçekleşmektedir. Bu durum Şekil 61’ de yer alan aylara göre aktüel basınç değer aralıkları grafiğinde detaylı şekilde gösterilmektedir.


Şekil 61: Aylara Göre Aktüel Basınç Değer Aralıkları



İşba sıcaklığı yüzeye yakın havanın yoğunlaşarak nesneler üzerinde su damlalarına dönüştüğü nokta olarak tanımlanmaktadır. Çiğ noktası olarak ta adlandırılmaktadır. Çeşme’ de Ocak 2017-Mart 2019 tarih aralığında gerçekleşen işba


sıcaklığına ait ortalamanın 13.31, standart sapmanın 6.07, min -8.60 ve maks 23.70 değerlerini aldığı gözlenmektedir. Saatlik işba sıcaklığı grafiği Şekil 62’ te yer almaktadır.

Şekil 62: İşba Sıcaklığı Dağılımı




İlçede mevsimlere göre değişkenlik gösteren işba sıcaklığının minimum ve maksimum değerleri arasındaki makas açıklığı, diğer aylara nazaran Ekim, Kasım, Aralık, Ocak, Şubat ve Mart aylarında daha fazladır. Ayrıca bu aylarda çığ noktasının sıfırın altında değerler alabildiği gözlenmektedir. İlgili gözlemler Şekil 63’ te aylara göre işba sıcaklığı değer aralıkları grafiğinde detaylı şekilde yer almaktadır.

Şekil 63: İşba Sıcaklığı Değer Aralıkları



Nisbi nem belirli hacimde nem miktarının, sözkonusu hacmi doymuş hale getirecek nem miktarına olan oranı şeklinde tanımlanabilmektedir. Havadaki su buharı kısmi basıncının, aynı sıcaklıkta bulunan suya ait denge buhar basıncına olan oranıdır. Nisbi nem genel tanımla havanın belirli sıcaklıkta taşıyabileceği nem miktarının mevcut durumda yüzde kaçını taşıdığını belirtmektedir.

Şekil 64: Değer Aralıklarına Göre Nisbi Nem Frekansları




Çeşme' de Ocak 2017-Mart 2019 tarih aralığında gerçekleşen nisbi neme ait ortalamanın 71.07, standart sapmanın 16.15, minimum 22 ve maksimum 100

değerlerini aldığı gözlenmektedir. Şekil 64’ de 4 ‘er birimlik değer aralıklarına Çeşme’de yaşanan nisbi nem değerlerinin frekansları gösterilmektedir.


İlçenin rüzgâr hızı verilerine bakıldığında 27 aylık veri setine ait ortalamanın 2.39 m/sn, standart sapmanın 1.55 m/sn, minimum 0 m/sn ve maksimum 11.70 m/sn olduğu tespit edilmektedir. Rüzgâr hızının değer aralıklarına ait frekans grafiği Şekil 65’ te yer almaktadır. Grafiğe göre ilçede 0-5 m/sn arasındaki rüzgâr hızı değerleri yoğun şekilde yaşanmaktadır.

Şekil 65: Değer Aralıklarına Göre Rüzgâr Hızı Frekansları




Rüzgar yönü verilerine bakıldığında rüzgar yönünün genellikle 0°-50°, 165°-185° ve 335°-360° aralıklarında yaşandığı gözlenmektedir. Rüzgar yönüne ait yoğunluğun en fazla olduğu açı değerleri 345°-360°, 0°-10°, 175°-185° aralıklarındadır. Rüzgâr yönüne ait yoğunluk grafiği Şekil 66’ da yer almaktadır.

Şekil 66: Rüzgâr Yönü Yoğunluğu




Çeşme’ de Ocak 2017-Mart 2019 tarih aralığında gerçekleşen sıcaklık verilerine bakıldığında ortalamanın 17.39, standart sapmanın 7.31, minimum -2.30 ve maksimum 37.20 değerlerini aldığı gözlenmektedir. Değer aralıklarına göre saatlik sıcaklıkların frekanslarına ait grafik Şekil 67’ te yer almaktadır. İlçede yaşanan sıcaklıklar genellikle 7 C° ile 29 C° aralığında gerçekleşmektedir.

Şekil 67: Değer Aralıklarına Göre Sıcaklık Frekansları



Yağış miktarına bakıldığında 27 aylık süreçte ilçede ortalaması 0.08 kg/m^2 , standart sapması 0.63 kg/m^2 , minimum 0 ve maksimum 31.10 kg/m^2 değerlerinde olan yağış olayları yaşanmıştır. Yağış miktarına ait grafik Şekil 68’ de yer almaktadır.

Şekil 68: Yağış Miktarı



4.2.2. Elektrik Enerjisi Dağıtım Ağına Ait Analizler

Elektrik dağıtım işletmesi, Çeşme’ de kurulu olan dağıtım altyapısında 400’ den fazla trafonun bulunduğu şebekenin operasyonlarını yürütmektedir. İşletme, sahip olduğu elektrik dağıtım ağını coğrafi bilgi sistemi tabanlı (CBS) elektrik dağıtım bilgi sistemi yazılım altyapısı ile gerçek zamanlı takip etmektedir.


Tablo 9: Arıza Sayısı, Toplam Kesinti Süresi ve Ortalama Kesinti Süresi (Ay)

	Arıza Sayısı			Kesinti Süresi (saat)			Arıza Başına Ortalama Kesinti Süresi (saat)		
Aylar	2017	2018	2019	2017	2018	2019	2017	2018	2019
Ocak	326	257	322	745	740	741	2.29	2.88	2.30
Şubat	179	196	288	669	672	671	3.74	3.43	2.33
Mart	182	195	284	744	744	740	4.09	3.82	2.61
Nisan	136	132	0	720	700	0	5.29	5.30	0.00
Mayıs	189	111	0	744	743	0	3.94	6.69	0.00
Haziran	155	149	0	720	720	0	4.65	4.83	0.00
Temmuz	314	151	0	743	744	0	2.37	4.93	0.00

Ağustos	200	102	0	744	734	0	3.72	7.20	0.00
Eylül	137	99	0	718	713	0	5.24	7.20	0.00
Ekim	152	103	0	735	743	0	4.84	7.21	0.00
Kasım	163	121	0	720	708	0	4.42	5.85	0.00
Aralık	190	199	0	744	744	0	3.92	3.74	0.00
Toplam	2323	1815	894	8746	8705	2152			

Ocak 2017-Mart 2019 tarih aralığında saatlik verilerin analizi sonucu Çeşme’ de aylara göre gerçekleşen arıza sayıları, aylara göre kesinti süreleri ve aylara göre arıza başına gerçekleşen kesinti süreleri Tablo 9’ da yer almaktadır.


Şekil 69: Aylara Göre Arıza Başına Ortalama Kesinti Süresi



Şekil 69’ da gösterilerin aylara göre arıza başına kesinti süreleri grafiğinde; üzerinde çalışılan veri seti en son 31 Mart 2019 tarihini kapsadığından dolayı, 2019 yılının Nisan ayından itibaren ortalama kesinti süresi değerleri sıfır olarak belirtilmiştir. Grafikte yer alan yılların ilk 3 ayları karşılaştırıldığında 2019 yılında gerçekleşen arızaların daha kısa sürede giderildiği gözlenmektedir. Bu durum işletmenin arıza giderme operasyonlarına ait performansın artışı diye yorumlanabilmektedir.


Şekil 70: Yıl Bazında Aylara Göre Arıza Sayıları

Yıl Bazında Aylara Göre Arıza Sayıları (Ocak 2017-Mart 2019)



Şekil 70’ te aylara göre arıza sayısı grafiği yer almaktadır. Grafiğe göre 2018 yılında gerçekleşen arızaların 2017 yılına nazaran daha az olduğu tespit edilmektedir. 2019 yılının ilk üç ayında gerçekleşen arıza sayısı 2017 ve 2018 yıllarının ilk üç aylarında gerçekleşenden fazladır.

Şekil 71: Haftanın Günlerine Ait Enerji Tüketimi-Arıza Sayısı




Şekil 71’ de haftanın günlerine ait enerji tüketimi ile bu günlerde yaşanan arıza sayıları karşılaştırılmaktadır. İlçede hafta sonlarında enerji tüketimlerinde artış gözlenmektedir. Bu duruma ilçenin tatil bölgesi olmasından kaynaklı olarak nüfusunun artması sebep olmaktadır.

Tablo 10: Haftanın Günleri Bazında Arıza Yüzdesi


	2017	2018	2019	Toplam	Gün Bazında Arıza Yüzdesi
Pazartesi	340	285	105	730	14.51%
Salı	314	237	129	680	13.51%
Çarsamba	348	271	119	738	14.67%
Perşembe	338	261	147	746	14.83%
Cuma	322	243	127	692	13.75%
Cumartesi	331	255	144	730	14.51%
Pazar	330	263	123	716	14.23%
Genel Toplam	2323	1815	894	5032	

Tablo 10’ da yer alan analize göre gün bazında gerçekleşen arıza sayılarının toplam arıza sayısı içindeki payları incelendiğinde haftanın günlerinde gerçekleşen arıza oranlarının birbirine yakın olduğu gözlenmektedir. Tabloda 2019 yılına ait Nisan ayından itibaren veriler dahil edilmemiştir.

Şekil 72: Yıl Bazında Haftanın Günlerinde Meydana Gelen Arıza Sayıları



Şekil 73: Toplam Arıza Sayısının Haftanın Günlerine Olan Dağılımı



Çalışmada kullanılan veri seti incelendiğinde; haftanın günleri bazında arıza yüzdelerinde çok yüksek bir farkın olmadığı gözlenmektedir (Şekil 73). Ancak hem veri setinin büyüklüğü hem de her kesintide birçok hanenin elektriksiz kaldığı düşünüldüğünde; bu değişkenliğin de büyük kayıplara karşılık geldiği görülmektedir. Şekil 71 incelendiğinde bu değişkenliğin sebebinin farklı günlerde tüketilen enerji miktarının farkından da bağımsız olduğu tespit edilmektedir. Bu nedenle haftanın günlerinin de faktör olarak modele yansıtılmasına ihtiyaç duyulmaktadır.


Tablo 11: Yıllara Göre Kesintiden Etkilenen Kullanıcı Sayısı

Aylar	OG-İmarİci-2017	AG-İmarİci-2017	OG-İmarDisi-2017	AG-İmarDisi-2017	OG-İmarİci-2018	AG-İmarİci-2018	OG-İmarDisi-2018	AG-İmarDisi-2018	OG-İmarİci-2019	AG-İmarİci-2019	OG-İmarDisi-2019	AG-İmarDisi-2019	OG-İmarİci-Toplam	AG-İmarİci-Toplam	OG-İmarDisi-Toplam	AG-İmarDisi-Toplam
Ocak	147	85010	0	44	325	60085	0	0	193	100429	12	8616	665	245524	12	8660
Subat	52	37802	0	0	1184	94309	0	175	95	53449	5	1476	1331	185560	5	1651
Mart	0	29448	0	336	448	62744	0	210	141	55660	37	3757	589	147852	37	4303
Nisan	0	6186	0	0	24	21871	0	525	0	0	0	0	24	28057	0	525
Mayıs	94	59610	0	0	16	37794	0	525	0	0	0	0	110	97404	0	525
Haziran	103	25044	0	168	22	32054	0	0	0	0	0	0	125	57098	0	168
Temmuz	314	19380	26	3592	52	50815	0	162	0	0	0	0	366	70195	26	3754
Agustos	10	80509	0	67	68	26667	20	2542	0	0	0	0	78	107176	20	2609
Eylul	26	31935	0	0	179	49414	31	6934	0	0	0	0	205	81349	31	6934
Ekim	64	41515	0	34	500	146334	79	3372	0	0	0	0	564	187849	79	3406

Kasım	151	0	0	0	83	28758	9	1298	0	0	0	0	234	28758	9	1298
Aralık	464	38860	0	0	91	39304	2	4676	0	0	0	0	555	78164	2	4676
Genel Toplam	1425	455299	26	4241	2992	650149	141	20419	429	209538	54	13849	4846	1314985	221	38508


Kullanılan veri seti ile yapılan analizde, diğer yıllara göre 2018 yılında kesintilerden daha fazla kullanıcının etkilendiği tespit edilmiştir. Şekil 74’ te yer alan grafik incelendiğinde orta gerilim imar içi alanlarda, özellikle sonbahar ve kış aylarında etkilenen kullanıcı sayısının bariz şekilde arttığı gözlenmektedir.

Şekil 74: Etkilenen Kullanıcı Sayısı (Orta Gerilim-İmar İçi)




Şekil 75’ te alçak gerilim imar içi alanlar için aylara göre etkilenen kullanıcı sayısı grafiği sunulmaktadır. Grafiğe göre kış aylarından bahar aylarına geçişte etkilenen kullanıcı sayısında azalma, ilkbahar aylarından yaz aylarına geçişte ise etkilenen kullanıcı sayısında tekrar artma davranışı tespit edilmektedir. Bu artış, turizm bölgesi olmanın vermiş olduğu yaz aylarında yaşanan ani nüfus yoğunlukları sebebiyle olabilmektedir.

Şekil 75: Etkilenen Kullanıcı Sayısı (Alçak Gerilim-İmar İçi)




Şekil 76’ da orta gerilim imar dışı alanlar için etkilenen kullanıcı sayısı grafiği yer almaktadır. Orta gerilim imar dışı alanlarda kullanıcı sayısı imar içi alanlara göre daha azdır. Bu bakımdan meydana gelen arızalarda etkilenen kullanıcı sayısı imariçi alanlara göre sayıca daha az olarak gerçekleşmektedir. Bu alanlarda kış aylarında etkilenen kullanıcı sayısı fazladır. Kış aylarından bahar aylarına geçişte etkilenen kullanıcı sayısında azalma, ilkbahar aylarından yaz aylarına geçişte ise etkilenen kullanıcı sayısında tekrar artma davranışı görülmektedir.

Şekil 76: Etkilenen Kullanıcı Sayısı (Orta Gerilim-İmar Dışı)




Şekil 77’ de alçak gerilim imar dışı alanlar için etkilenen kullanıcı sayısı grafiği yer almaktadır. Alçak gerilim imar dışı alanlarda kullanıcı sayısı orta gerilim imar dışı alanlara göre daha fazladır. Bu nedenle meydana gelen arızalarda etkilenen kullanıcı sayısı orta gerilim alanlara göre sayıca daha fazla gerçekleşmektedir. Bu alanlarda da kış aylarında etkilenen kullanıcı sayısı fazladır. Kış aylarından bahar aylarına geçişte etkilenen kullanıcı sayısında azalma, ilkbahar aylarından yaz aylarına geçişte ise etkilenen kullanıcı sayısında tekrar artma davranışı görülmektedir.

Şekil 77: Etkilenen Kullanıcı Sayısı (Alçak Gerilim-İmar Dışı)



Şekil 78’ de Ocak 2017 ve Mart 2019 tarih aralığında alçak gerilim ve orta gerilim gruplarının tüm imar içi ve imar dışı alanlarında etkilenen kullanıcı sayıları için genel analiz sunulmaktadır. Çeşme’ de abone sayısı bakımından yaşanan kesintilerden en fazla etkilenen kullanıcı sayısı alçak gerilim imar içi alanlarda bulunmaktadır. Analizin kapsadığı tarih aralığında en düşük etkilenen kullanıcı sayısının olduğu ay olan Nisan ayında 28057 abone etkilenmiş olup; yaşanan arızalarda kamunun aldığı hizmetten gördüğü zararın boyutları oldukça fazladır. Grafiğe göre yılın her ayında kamunun gördüğü zarar yüksek boyutlarda olup; özellikle Ocak, Şubat, Mart ve Ekim aylarında diğer aylara nazaran etkilenen kullanıcı sayısında ciddi oranda artma gözlenmektedir.

Şekil 78: Etkilenen Kullanıcı Sayısı (Genel)




Elektrik kesintilerinde, kesintiye yaşayan bölgede etkilenen abone sayısı ve söz konusu kesintiye ait süre verileri kullanılarak; bölgenin arıza başına maruz kaldığı toplam etkilenme süresi hesaplanabilmektedir. EK 2’ de yıl ve ay kırılımları dikkate alınarak Çeşme ilçesinde alçak gerilim ve yüksek gerilime ait imar içi ve imar dışı alanlarla toplam etkilenme süreleri yer almaktadır. Ocak 17-Mart 19 tarih aralığında orta gerilime (OG) ait imar içi alanlarda elektrik kesintileri nedeniyle gerçekleşen toplam etkilenme süresi Şekil 79’ da yer almaktadır. Toplam etkilenme süresi

$$\text{Toplam Etkilenme Süresi (OG İmar İçi)} = \text{Kesinti Süresi} * \text{Etkilenen Kullanıcı Sayısı (OG İmar İçi)}$$

formülüyle hesaplanmaktadır. Grafiğe göre orta gerilim imar içi alanlarda tüm aylar için etkilenme süresi fazladır. Şubat 2018 ayı için etkilenme süresi diğer aylara göre oldukça fazla gerçekleşmiştir.

Şekil 79: Toplam Etkilenme Süresi (Orta Gerilim-İmar İçi)




Alçak gerilime (AG) ait imar içi alanlarda elektrik kesintileri nedeniyle gerçekleşen toplam etkilenme süresi Şekil 80’ de yer almaktadır.

$$\text{Toplam Etkilenme Süresi (AG İmar İçi)} = \text{Kesinti Süresi} * \text{Etkilenen Kullanıcı Sayısı (AG İmar İçi)}$$

formülüyle hesaplanmaktadır. Grafiğe göre alçak gerilim imar içi alanlarda tüm aylar için etkilenme süresi fazladır. Şubat 2017, Ekim 2017 ve Şubat 2018 aylarında yaşanan toplam etkilenme süreleri diğer aylara göre oldukça fazladır.

Şekil 80: Toplam Etkilenme Süresi (Alçak Gerilim-İmar İçi)




Orta gerilim imar dışı alanların toplam etkilenme süresi grafiği Şekil 81’ de yer almaktadır. OG imar dışı alanlarda abone sayısının az olmasından dolayı yaşanan kesintilerde etkilenme süreleri düşük gerçekleşmiştir. Toplam etkilenme süresi

$$\text{Toplam Etkilenme Süresi (OG İmar Dışı)} = \text{Kesinti Süresi} * \text{Etkilenen Kullanıcı Sayısı (OG İmar Dışı)}$$

formülüyle hesaplanmaktadır. 2017 yılının Temmuz ayında 42 saatlik etkilenme süresi gerçekleşmiştir. 2018 yılının Ağustos ayında 24, Eylül ayında 76, Ekim ayında 168, Kasım ayında 22 ve Aralık ayında 2 saatlik etkilenme süresi gerçekleşmiştir. 2019 yılının ilk üç ayında sırasıyla 22, 7 ve 205 saatlik etkilenme süreleri gerçekleşirken; veri setinde bu yılın diğer aylarına ait verilerin bulunmaması nedeniyle kalan aylar için toplam etkilenme süresi grafikte sıfır değeriyle ifade edilmiştir.

Şekil 81: Toplam Etkilenme Süresi (Orta Gerilim-İmar Dışı)




Alçak gerilim imar dışı alanların toplam etkilenme süresi grafiği Şekil 82’ de yer almaktadır. 2017 yılında Ağustos ayında, 2018 yılında Şubat ve Eylül aylarında ve 2019 yılında ise Ocak ve Mart aylarında toplam etkilenme süreleri ilgili yıllara ait diğer aylara göre daha yüksek seyretmiştir. 2019 yılının Nisan ayından itibaren diğer aylar veri setine dahil olmadığından sıfır değerini almıştır. Toplam etkilenme süresi:

*Toplam Etkilenme Süresi (AG İmar Dışı) = Kesinti Süresi * Etkilenen Kullanıcı Sayısı (AG İmar Dışı)*


formülüyle hesaplanmaktadır.

Şekil 82: Toplam Etkilenme Süresi (Alçak Gerilim-İmar Dışı)



Çeşme’ de 27 aylık veri seti baz alınarak oluşturulan orta/alçak gerilimin imar içi ve imar dışı alanlarında meydana gelen toplam etkilenme süreleri Şekil 83’ te genel toplam olarak yer almaktadır. Nüfus yoğunluğu nedeniyle abone sayısının fazla olduğu alçak gerilim imar içi alanlarda meydana gelen kesintilerde diğer alanlara göre etkilenme süreleri oldukça fazladır. Grafikteki değerler milyon saat cinsinden olduğundan sütun olarak küçük görünen kısımlarda da etkilenme süreleri oldukça fazladır. Alçak gerilim imar dışı alanlarda da AG imar içi alanlar gibi olmasa da toplam etkilenme süreleri yüksek seviyede gerçekleşmiştir. Kesinti süresi ve etkilenen kullanıcı sayısının fazlalığından dolayı yaşanan etkilenme sürelerinin fazlalığı nedeniyle kamunun aldığı hizmet kalitesi olumsuz etkilenmektedir. Abonelerin uzun süre elektrik enerjisi ihtiyacı karşılanamamaktadır.

Şekil 83: Etkilenme Süresi Genel Durum



Tablo 12’ de Çeşme’ de OG-AG imar içi ve imar dışı alanlarda aylara göre gerçekleşen kesinti sayıları ve kesintilerin giderilme süreleri yer almaktadır.


Tablo 12: Kesinti Sayısı ve Süresi

Aylar	Toplam Arıza Sayısı	Toplam Kesinti Süresi (Saat)	Ortalama Kesinti Süresi (Saat)	AGEtkKullSayImarIci	AGEtkSuresiImarIci (Saat)	AGEtkKullSayImarDisi	AGEtkSuresiImarDisi (Saat)	OGEkKullSayImarIci	OGEkSuresiImarIci (Saat)	OGEkKullSayImarDisi	OGEkSuresiImarDisi (Saat)	Toplam Etkilenen Kullanıcı Sayısı	Toplam Etkilenme Süresi (Saat)
Ocak	906	3075	3.39	245524	682405	8660	20424	665	1452	12	22	254860	704302
Şubat	664	2086	3.14	185560	21888256	1651	39859	1331	155366	5	7	188547	22083488
Mart	662	1975	2.98	147852	374368	4303	16679	589	1243	37	205	152781	392495
Nisan	270	845	3.13	28057	1192197	525	2041	24	62	0	0	28606	1194300
Mayıs	300	945	3.15	97404	356619	525	922	110	348	0	0	98038	357888
Haziran	304	926	3.05	57098	164161	168	249	125	237	0	0	57391	164648
Temmuz	465	1341	2.88	70195	118337	3754	10398	366	467	26	42	74341	129244
Ağustos	302	729	2.42	107176	43874	2609	51472	78	348	20	24	109883	95718
Eylül	237	676	2.85	81349	93674	6934	25359	205	386	31	76	88519	119494
Ekim	255	641	2.51	187849	6496811	3406	11371	564	10091	79	168	191898	6518441
Kasım	284	777	2.73	28758	375409	1298	3279	234	541	9	22	30299	379252
Aralık	389	1058	2.72	78164	173704	4676	5693	555	791	2	2	83397	180190

Genel Toplam	5038	15075	2.99	1314986	31959815	38508	187746	4846	171332	221	568	1358561	32319461
--------------	------	-------	------	---------	----------	-------	--------	------	--------	-----	-----	---------	----------


Aylara göre arıza sayısı ve arızada geçen sürelerin gösterildiği grafikte (Şekil 84) kış mevsimi ve turizm sezonu olan yaz mevsiminde arıza sayılarının yüksek olduğu tespit edilmektedir. Kış mevsiminde arıza sayılarının ve sürelerinin yüksekliği özellikle dikkat çekmektedir. Grafik incelendiğinde genel durumda arıza sayıları ile toplam kesinti süreleri arasında bir ilişkinin olduğu göze çarpmaktadır. Bazı durumlarda arızanın türüne göre bu ilişkinin derecesi değişebilmektedir. Kış aylarında yüksek olan arıza sayısı ve kesinti süresi ilkbahar aylarında azalmakta; turizm sezonu olan yaz mevsimi ve sonbahar dönemlerinde tekrar yükselmektedir.

Şekil 84: Arıza Sayısı ve Kesinti Süresi




Şekil 85’ te yer alan aylara göre arıza başına gerçekleşen ortalama kesinti süresi grafiğine göre diğer mevsimlerle kıyaslandığında kış aylarında gerçekleşen arızaların giderilme sürelerinin daha fazla zaman aldığı gözlenmektedir. Buradaki nedenin hem gerçekleşen arızanın türünden hem de arızayı gidercek olan ekibin olumsuz hava şartlarından dolayı çalışma koşullarının zorluğundan kaynaklandığı düşünülmektedir. Birkaç dakikadan daha fazla süren kesintiler uzun kesinti olarak tanımlanırken; arıza başına kesinti süresi ortalamarının saat cinsinden 2.42-3.39 aralığında olduğu tespit edilmiştir. Uzun kesinti süreleri, kamunun aldığı hizmeti ve ekonomik hayatı olumsuz etkilemekte olup; yerleşim bölgelerinde görünmeyen birçok maliyete de sebep olmaktadır.

Şekil 85: Arıza Başına Ortalama Kesinti Süresi



Şekil 86’ da ortalama kesinti süresi, toplam arıza sayısı ve toplam kesinti sürelerinin birbiriyle olan ilişkisini gösteren grafik yer almaktadır. Toplam kesinti süresi, ortalama kesinti süresi ile toplam arıza sayısının çarpımıyla elde edilmektedir.

Şekil 86: Ortalama Kesinti Süresi, Arıza Sayısı ve Kesinti Süresi İlişkisi



4.3. DERİN ÖĞRENME MODELLERİ

Bu çalışmada, Çeşme’ de kurulu olan elektrik dağıtım ağının saatlik çalışma durumu (arıza/sağlıklı çalışma), saatlik elektrik enerjisi tüketimi ve meteorolojik faktörlere ait saatlik veriler kullanılarak derin öğrenme modelleri eğitilmiştir. Derin öğrenme modellerinde kullanılan veriler Çeşme ilçesine dağıtım hizmeti veren GDZ Elektrik Dağıtım A.Ş., Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) ve Türkiye Devlet Meteoroloji Genel Müdürlüğü'nden 01 Ocak 2017-31 Mart 2019 tarih aralığı (27 Ay) için saatlik (19681 saat) ham veri olarak elde edilmiştir. Veri setleri, ilgili işletmelerin gerçek zamanlı veri toplama cihaz ve sensörleri tarafından ilgili kurumun veritabanlarına kaydedilen verilerden oluşturulmuştur. Farklı kaynaklardan toplanan veriler, tarih ve saat birleşiminden oluşan etiket kullanılarak eşleştirilmiş ve birleştirilmiştir. Oluşturulan veri setinde bulunan bozuk, eksik ve gereksiz verilerin yer aldığı kısımlar çıkarılmıştır. Gerekli düzenlemelerden sonra elektrik dağıtım ağı çalışma durumu (0:sağlıklı çalışma ve 1:arızalı durum), elektrik tüketimi ve meteorolojik faktörlere ait veriler derin öğrenme modelleri için 15734 saatlik veri setine dönüştürülmüştür. Veri setinde tarih ve saat bilgisinden oluşturulan her etikete dağıtım ağının çalışma durumu (sağlıklı/arızalı), enerji tüketim miktarı ve meteorolojik faktörlere ait değerler tanımlanmıştır.

Yapay sinir ağlarında olduğu gibi derin öğrenme modellerinde de modelin girdi faktörleri arasındaki güçlü ilişkiler ezberleme (overfitting) hatasının yaşanmasına ve modelin güvenilir sonuçlar verememesine neden olmaktadır. Bu nedenle derin öğrenme modelleri oluşturulmadan önce dağıtım ağının çalışma durumuna etki eden ve derin modellerin girdisini oluşturan enerji tüketim miktarı ile meteorolojik olaylara ait faktörler arasında korelasyon analizi gerçekleştirilmiştir. Korelasyon analizinde ilişkileri araştırılan faktörler Tablo 13’te detaylı şekilde yer almaktadır. Tablo 13’te yer alan mavi tondaki renkler faktörler arasında pozitif yöndeki ilişkiyi, kırmızı tondaki renkler ise negatif yöndeki ilişkiyi temsil etmektedir. Renk tonlarının koyulaşması, iki faktör arasındaki ilişkinin kuvvetinin arttığını göstermektedir. Korelasyon analizine ait sayısal sonuç tablosu EK 1’de yer almaktadır


Çalışmada, elektrik dağıtım şebekesinin sağlıklı veya arızalı olduğu durumların saatlik tahmini yapılırken; şebekeye ait iç faktör olan saatlik enerji tüketimi ile dış faktörlerden olan meteorolojik olaylara ait saatlik veriler kullanılmıştır. Derin öğrenme modellerinde kullanılan veri setinin bir bölümü Tablo 14’ te yer almaktadır.

Tablo 14: Derin Öğrenme Modellerinde Kullanılan Veri Seti Örneği

Tarih & Saat	Gün	Arıza Yok:0/Var:1	Elektrik Tüketim (kWh)	Aktüel Basınç (hPa)	İsba Sıcaklığı (°C)	Nisbi Nem (%)	Rüzgar Hızı (m/sn)	Rüzgar Yönü (°)	Sıcaklık (°C)	Yağış Miktarı (mm=kg/m ²)
1-1-2017 3	7	0	43544	1023	15.8	77	2.2	78	1	0
1-1-2017 10	7	1	42451	1022.5	20.7	43	1.9	36	8.9	0
1-1-2017 13	7	1	45874	1021.6	15.8	53	1.3	1	6.8	0
1-1-2017 14	7	1	43915	1021.4	15.8	62	1.5	26	6	0
1-1-2017 15	7	0	41534	1021.5	15.8	68	1.7	99	4.4	0
1-1-2017 16	7	0	39828	1021.8	15.8	71	1.2	233	2.9	0
1-1-2017 17	7	0	39217	1022	15.8	87	0.5	328	0.2	0
1-1-2017 18	7	1	41100	1021.8	15.8	90	0.7	59	0.5	0
1-1-2017 19	7	1	45745	1021.8	15.8	91	0.8	203	0	0
1-1-2017 20	7	0	47388	1021.9	15.8	94	0.7	222	-0.2	0
1-1-2017 21	7	0	46121	1021.9	15.8	95	0.6	209	-0.4	0
.....										
.....										
.....										
.....										
.....										
31-3-2019 17	7	1	22807	1007.3	2.5	52	4.6	40	12.1	0
31-3-2019 18	7	0	24120	1007.8	1.7	51	4.6	50	11.5	0
31-3-2019 19	7	1	26811	1008.1	2.1	58	4.4	10	11.5	0
31-3-2019 20	7	0	29321	1008.1	2.4	57	3.3	66	10.7	0
31-3-2019 21	7	0	28227	1008.4	2.8	60	4.2	24	10.5	0
31-3-2019 22	7	1	27355	1008.4	2.9	63	4.9	46	10.4	0
31-3-2019 23	7	1	26460	1008.2	3	64	2.5	65	9.2	0
Toplam 15734 Saatlik Veri Seti										

Derin öğrenme modelleri kurulmadan önce, veri temizleme ve birleştirme işlemleri gerçekleştirilmiştir. Derin öğrenme modellerinin başarısı için farklı veri kaynaklarından elde edilen veri kümelerinin temizlenmesi, düzenlenmesi, birleştirilmesi ve uyarlanması süreci oldukça önemlidir. Derin öğrenme süreç şeması Şekil 87’ de yer almaktadır.

Şekil 87: Derin Öğrenme Süreci



Verilerin %70' i (11013 saatlik) eğitim (öğrenme) ve %30' u (4721 saatlik) test veri seti olmak üzere rastgele iki gruba ayrılmıştır. Modelin girdisi olarak elektrik tüketimi (kWh), aktüel basınç (hPa), işba sıcaklığı, nisbi nem, rüzgâr hızı (m/s), rüzgâr yönü (°), sıcaklık (°C), yağış miktarı (mm=kg/m²) ve haftanın günü faktörleri kullanılmıştır. Uygun modeli belirleme sürecinde farklı ağ yapıları ile modeller eğitilmiştir. Modelin katmanları ve nöron sayıları tekrar tekrar güncellenmiştir.

Şekil 88: Yaygın Kullanılan Aktivasyon Fonksiyonları

Sigmoid	Tanh	ReLU	Leaky ReLU
$g(z) = \frac{1}{1 + e^{-z}}$	$g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	$g(z) = \max(0, z)$	$g(z) = \max(\epsilon z, z)$ with $\epsilon \ll 1$

Kaynak: (Amidi ve Amidi, 2018).

Derin öğrenme modellerinden Evrişimsel Sinir Ağları (Convolutional Neural Network-CNN) kullanılmıştır. Öğrenme yöntemi olarak ileri beslemeli sınıflandırma (feedforward classification) kullanılmıştır. Öğrenme sürecinde derin sinir ağları 11013 saatlik veri seti kullanılarak gözetimli (supervised learning) şekilde eğitilmiştir. Öğrenme işlemleri modellere göre birbirinden farklı epoch değerleri ile gerçekleştirilmiştir. Oluşturulan modellerde gizli katmanların her birinde Leaky ReLU aktivasyon fonksiyonu kullanılmıştır (Şekil 88). Leaky ReLU sayesinde negatif değerler için de öğrenme işlemi gerçekleştirilebilmektedir. Çıkış katmanında softmax

aktivasyon fonksiyonunu kullanılmıştır. Katman sayıları ve her katmandaki çıktı sayıları modellere göre değişkenlik göstermektedir. Tüm modellere ait veriler EK 3’ te yer almaktadır. Kayıp fonksiyonu (loss function) olarak “Mean Squared Error” ve optimizasyon yöntemi olarak “Stochastic Gradient Descent” kullanılmıştır. Optimizasyon algoritmaları, kayıp fonksiyonunu kullanarak ağı güncellemektedir. Batch size, oluşturulan tüm derin öğrenme modellerinde 100 olarak belirlenmiştir. Batch size sayesinde eğitim verileri 100’ lük gruplar halinde eğitilmiştir. Öğrenme oranı (learning rate) 0.01 olarak; weight initialisation strategy ise XAVIER olarak belirlenmiştir. Derin öğrenme modellerinde bir sonraki katman, önceki katmandaki nöronlarının ağırlıklarını kullanmaktadır. Modelin öğrenme süreci, uygun öğrenme seviyesine ulaşıldığında ve belirlenen maksimum döngü sayısına ulaşıldığında tamamlanmaktadır.

Derin öğrenme modellerinde eğitim veri seti ile gerçekleştirilen öğrenme sürecinden sonra, rastgele ayrılmış 4721 saatlik test veri seti kullanılarak tahmin işlemleri gerçekleştirilmiştir. Toplamda 100 adet farklı derin öğrenme modeli eğitilmiş olup; modellerin katman yapıları ve tahmin başarıları EK 3’ te yer almaktadır. Derin öğrenme modellerinin tamamı Knime Analytics Platformu üzerinde DL4J kullanılarak eğitilmiştir. Oluşturulan modellerden, Model 52, Model 14 ve Model 72’ ye ait derin öğrenme model şemaları Şekil 89, Şekil 90 ve Şekil 91’ de; model parametreleri Tablo 16’ da yer almaktadır. Eğitilen 100 modele ait derin sinir ağı yapıları birbirinden farklılık göstermektedir.


Tablo 15: Seçilen Derin Öğrenme Modellerinin Katman Yapıları

Model Number	Number of Dense Layer	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output
Model-52	6	15	15	15	15	15	2	
Model-14	5	15	15	15	15	15		
Model-72	7	30	30	30	30	30	30	2

Şekil 89, Şekil 90 ve Şekil 91’ de yer alan derin öğrenme modellerinde DL4J Model_INITIALIZER, bir ağ mimarisini başlatmak için kullanılan boş bir derin öğrenme modelini oluşturmaktadır. Dense Layer, giriş bağlantı noktası tarafından sağlanan


derin öğrenme modeline tam olarak bağlı bir katman eklemektedir. Excel Reader, verilerin kayıtlı olduğu elektronik sayfayı okumakta ve çıktı bağlantı noktasını sağlamaktadır. Column Filter, sütunların girdi tablosundan filtrelenmesini sağlamakta ve kalan sütunları çıktı tablosuna iletmektedir.

Şekil 89: Derin Öğrenme Modeli (Model 52: Çeşme Dağıtım Ağı Durumu)




Number to String, sütundaki veya sütun grubundaki sayıları dizilere dönüştürmektedir. String to Number, sütundaki veya sütun grubundaki dizileri sayılara dönüştürmektedir. Normalizer, tüm sayısal sütunların değerlerini normalize etmektedir. Partitioning, tüm veri setini belirtilen oranlarda ve özelliklerde eğitim ve test veri seti olmak üzere iki gruba ayırmaktadır. DL4J Feedforward Learner (Classification), sınıflandırma için ileri beslemeli bir derin öğrenme modelinin gözetimli (supervised) eğitimini gerçekleştirmektedir. Öğrenme prosedürü çeşitli eğitim yöntemleri ve parametreleri kullanılarak ayarlanabilmektedir.

Şekil 90: Derin Öğrenme Modeli (Model 14: Çeşme Dağıtım Ağı Durumu)



DL4J Feedforward Predictor (Classification), öğrenme işleminden sonra sağlanan ağ ve test verilerini kullanarak bir sınıflandırma tahmini oluşturmaktadır.

Şekil 91: Derin Öğrenme Modeli (Model 72: Çeşme Dağıtım Ağı Durumu)



Scorer, iki sütunu öznitelik değer çiftlerine göre karşılaştırmakta ve karşılaştırma matrisini göstermektedir. Çıktısı, her hücredeki eşleşme sayısı ile karşılaştırma matrisidir. Ayrıca, ikinci çıkış noktası, true-positives, false-positives, true-negatives, false-negatives ve genel doğruluk (overall accuracy) değerlerini hesaplamaktadır. Model Writer, KNIME modeli bağlantı noktası nesnelerini Model Reader düğümü ile okunabilen bir dosyaya kaydetmektedir. DL4J Model Writer, sağlanan derin öğrenme modelini belirtilen konuma kaydetmektedir.


Tablo 16: Derin Öğrenme Modeli Parametreleri (Model 52, 14, 72)

Model Content Spec			
	Model 52	Model 14	Model 72
Neural Net Type	array-size [xint] -> 2	array-size [xint] -> 2	array-size [xint] -> 2
	0 [xstring] -> MLP	0 [xstring] -> MLP	0 [xstring] -> MLP
	1 [xstring] -> DEEPCONVOLUTIONAL	1 [xstring] -> DEEPCONVOLUTIONAL	1 [xstring] -> DEEPCONVOLUTIONAL
	array-size [xint] -> 6	array-size [xint] -> 5	array-size [xint] -> 7
Layer Type List	0 [xstring] -> DENSE_LAYER	0 [xstring] -> DENSE_LAYER	0 [xstring] -> DENSE_LAYER
	1 [xstring] -> DENSE_LAYER	1 [xstring] -> DENSE_LAYER	1 [xstring] -> DENSE_LAYER
	2 [xstring] -> DENSE_LAYER	2 [xstring] -> DENSE_LAYER	2 [xstring] -> DENSE_LAYER
	3 [xstring] -> DENSE_LAYER	3 [xstring] -> DENSE_LAYER	3 [xstring] -> DENSE_LAYER
	4 [xstring] -> DENSE_LAYER	4 [xstring] -> DENSE_LAYER	4 [xstring] -> DENSE_LAYER
	5 [xstring] -> DENSE_LAYER		5 [xstring] -> DENSE_LAYER
			6 [xstring] -> DENSE_LAYER
	IsTrained [xboolean] -> true	IsTrained [xboolean] -> true	IsTrained [xboolean] -> true
Feature Columns Types	array-size [xint] -> 9	array-size [xint] -> 9	array-size [xint] -> 9
	0 [xstring] -> Number (double)	0 [xstring] -> Number (double)	0 [xstring] -> Number (double)
	1 [xstring] -> Number (double)	1 [xstring] -> Number (double)	1 [xstring] -> Number (double)
	2 [xstring] -> Number (double)	2 [xstring] -> Number (double)	2 [xstring] -> Number (double)
	3 [xstring] -> Number (double)	3 [xstring] -> Number (double)	3 [xstring] -> Number (double)
	4 [xstring] -> Number (double)	4 [xstring] -> Number (double)	4 [xstring] -> Number (double)
	5 [xstring] -> Number (double)	5 [xstring] -> Number (double)	5 [xstring] -> Number (double)
	6 [xstring] -> Number (double)	6 [xstring] -> Number (double)	6 [xstring] -> Number (double)
	7 [xstring] -> Number (double)	7 [xstring] -> Number (double)	7 [xstring] -> Number (double)
Feature Columns Names	array-size [xint] -> 9	array-size [xint] -> 9	array-size [xint] -> 9
	0 [xstring] -> Bas_Gun_Rak	0 [xstring] -> Bas_Gun_Rak	0 [xstring] -> Bas_Gun_Rak
	1 [xstring] -> Tuketim	1 [xstring] -> Tuketim	1 [xstring] -> Tuketim
	2 [xstring] -> Aktuel Basinc (hPa)	2 [xstring] -> Aktuel Basinc (hPa)	2 [xstring] -> Aktuel Basinc (hPa)
	3 [xstring] -> Isba Sicakligi (°C)	3 [xstring] -> Isba Sicakligi (°C)	3 [xstring] -> Isba Sicakligi (°C)
	4 [xstring] -> Nisbi Nem (%)	4 [xstring] -> Nisbi Nem (%)	4 [xstring] -> Nisbi Nem (%)
	5 [xstring] -> Ruzgar Hizi (m÷sn)	5 [xstring] -> Ruzgar Hizi (m÷sn)	5 [xstring] -> Ruzgar Hizi (m÷sn)
	6 [xstring] -> Ruzgar Yonu (°)	6 [xstring] -> Ruzgar Yonu (°)	6 [xstring] -> Ruzgar Yonu (°)
	7 [xstring] -> Sicaklik (°C)	7 [xstring] -> Sicaklik (°C)	7 [xstring] -> Sicaklik (°C)
Labels	array-size [xint] -> 2	array-size [xint] -> 2	array-size [xint] -> 2
	0 [xstring] -> 0	0 [xstring] -> 0	0 [xstring] -> 0
	1 [xstring] -> 1	1 [xstring] -> 1	1 [xstring] -> 1
	array-size [xint] -> 1	array-size [xint] -> 1	array-size [xint] -> 1
Target Column Names	0 [xstring] -> Ariza_Var_Yok	0 [xstring] -> Ariza_Var_Yok	0 [xstring] -> Ariza_Var_Yok
	LearnerType [xstring] -> feedforward_classification	LearnerType [xstring] -> feedforward_classification	LearnerType [xstring] -> feedforward_classification
	ModelType [xstring] -> MLN	ModelType [xstring] -> MLN	ModelType [xstring] -> MLN


4.4. DERİN ÖĞRENME MODELLERİ ŞEBEKE TAHMİN SONUÇLARI

Çalışmada farklı parametreler kullanılarak, Çeşme ilçesi elektrik dağıtım ağının saatlik çalışma durumu tahmini için 100 farklı derin öğrenme modeli geliştirilmiş ve eğitilmiştir. Derin öğrenme modelleri ile öğrenme işleminden sonra; sağlanan ağ ve test verileri kullanılarak, sınıflandırma yöntemiyle şebeke durum tahmini yapılmıştır. Geliştirilen 100 modele ait ağ özellikleri, parametreler ve true-positives, false-positives, true-negatives, false-negatives ve genel doğruluk (overall accuracy) değerlerini içeren tahmin sonuçları EK 3' te yer almaktadır. Eğitilen modellerin bazılarında ezberleme durumundan kaynaklı olarak istenmeyen tahmin sonuçları alınmıştır. Derin öğrenme ve hedef programlama modelleri hibrit şekilde kullanılarak; 3 farklı durum için elde edilen en iyi derin öğrenme modelleri Model 52, Model 14 ve Model 72 olarak tespit edilmiştir. Bu modellere ait gizli katman yapıları Tablo 15' te yer almaktadır. Çeşme ilçesine ait şebeke durumunu tahmin etmek için oluşturulan modellerde, 11013 (% 70) saatlik eğitim ve 4721 (% 30) saatlik test veri seti kullanılmıştır. Üç model 1000 epochs değeriyle eğitilmiş olup; modellere ait epoch-loss değerleri Şekil 92, Şekil 93 ve Şekil 94' te yer almaktadır.


Şekil 92: Epoch ve Loss Değerleri (Model 52)



Şekil 93: Epoch ve Loss Değerleri (Model 14)



Şekil 94: Epoch ve Loss Değerleri (Model 72)



Derin öğrenme modellerinin tahmin sonuçlarına göre Tablo 17’ de bulunan hata matrisi elde edilmektedir. Model 52, Model 14 ve Model 72’ nin tahmin sonuçlarına göre elde edilen hata matrisleri Tablo 18’ de yer almaktadır.

Tablo 17: Hata Matrisi (Confusion Matrix)

	0	1
0	TP= t_1	FP= t_2
1	FN= t_3	TN= t_4

(0:Şebeke Sağlıklı 1:Şebeke Arızalı)

- t₁: Doğru Pozitif (True Positive-TP) tahmin değeri (0-0)
t₂: Yanlış Pozitif (False Positive-FP) tahmin değeri (0-1)
t₃: Yanlış Negatif (False Negative-FN) tahmin değeri (1-0)
t₄: Doğru Negatif (True Negative-TN) tahmin değeri (1-1)

Tablo 18: Derin Öğrenme Modelleri (Model 52, 14, 72) Tahmin Hata Matrisleri

	Model-52		Model-14		Model-72	
Gerçekleşen/Tahmin	0	1	0	1	0	1
0	3089	370	3311	148	2837	622
1	943	319	1117	145	788	474

(1: Kesinti - 0: Sağlıklı Çalışma Durumu)


Derin modelin eğitim sürecinden sonra 4721 saatlik test veri seti kullanılarak tahmin sonuçları hesaplanmıştır. Test sürecinde şebekenin gerçek hayattaki çalışma durumu ile derin öğrenme modeli tahmin sonuçları karşılaştırılmıştır. Tüm derin öğrenme modellerine ait tahmin sonuçları EK 3' te yer almaktadır. Sonuçlara göre Model 52' de şebekenin sağlıklı çalıştığı 3089 durum ve şebekenin arızalı olduğu 319 durum doğru tahmin edilmiştir. Model 14' te 3311 sağlıklı durum ve 145 arızalı durum doğru tahmin edilmiştir. Model 72 ' de ise 2837 sağlıklı durum ve 474 arızalı durum doğru tahmin edilmiştir.

Tablo 19: Derin Öğrenme Modellerinin Tahmin Genel Doğrulukları

Model No	Doğru Tahmin	Yanlış Tahmin	Overall Accuracy %
Model-52	3408	1313	72.19
Model-14	3456	1265	73.21
Model-72	3311	1410	70.13


Model 52' nin genel tahmin doğruluğu (overall accuracy) % 72.19, Model 14' ün 73.21 ve Model 72' nin 70.13 olarak gerçekleşmiştir. Modellere ait grafikler Şekil 95' te yer almaktadır.

Şekil 95: Derin Öğrenme Modellerinin Genel Tahmin Başarıları



Test veri setinde yer alan ve gerçekleşen 4721 saatlik durumdan 3459’ unda şebeke sağlıklı şekilde çalışırken; 1262 durumda arıza meydana gelmiştir.

Şekil 96: Derin Öğrenme Modelleri Tahmin Genel Doğruluğu




Şekil 96’ da eğitilen 100 modele ait tahmin genel doğruluk skorları yer almaktadır. Eğitilen yüz model arasında tahmin genel doğruluk düzeyi % 45.29 değeriyle en düşük seviyede olan Model 38 ‘e ait derin sinir ağı mimarisi Tablo 20’ de yer almaktadır.

Tablo 20: Tahmin Başarısı En Düşük Derin Sinir Ağı Mimarisi (Model 38)

Model No	Number of Dense Layer	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	0-0	0-1	1-0	1-1	Correct Classified	Wrong Classified	Overall Accuracy %	Error %
Model-38	6	5	7	7	7	7	2	1069	2390	193	1069	2138	2583	45.29	54.71

Derin öğrenme modellerin tahmin genel doğruluğu ile şebekenin arızalı durumunun doğru tahmin edilme başarısının karşılaştırıldığı grafik Şekil 97’ de yer almaktadır. Grafikte yeşil renk tahmin genel doğruluk değerini (overall accuracy) temsil ederken; mavi renk arızalı durumu doğru tahmin etme skorunu göstermektedir.

Şekil 97: Tahmin Genel Doğruluğu ve Arızalı Durum Tahmin Genel Doğruluğu



Derin öğrenme modelleri tarafından yapılan saatlik tahminler, alınan kamu hizmet kalitesi ve işletme operasyon maliyeti bakımından genel olarak değerlendirildiğinde;

- dağıtım ağında arızanın yaşanmayacağına dair tahminde bulunulup; gerçekte arızanın yaşanmadığı durum (TP: True Positive/Doğru Pozitif)
- arızanın yaşanacağına dair tahminde bulunulup; gerçekte arızanın yaşandığı durum (TN: True Negative/Doğru Negative)
- arızanın yaşanacağına dair tahminde bulunulup; gerçekte arızanın yaşanmadığı durum (FP: False Positive/Yanlış Pozitif)
- arızanın yaşanmayacağına dair tahminde bulunulup; gerçekte arızanın yaşandığı (FN: False Negative/Yanlış Negatif)

toplamda dört durum ortaya çıkmaktadır (Tablo 17). Her durumda, kamunun aldığı hizmet kalitesi bakımından ve elektrik dağıtım işletmesinin çeşitli operasyonlarına ait katlanılan yüksek maliyetler bulunmaktadır. Enerji kesintisinin yaşandığı zaman diliminde kamunun ve ekonomik hayatın gördüğü zararın maliyetini hesaplamak oldukça güçtür. Bu nedenle elektrik dağıtım işletmelerinin, abonelerine kesintisiz ve uygun şekilde enerji arzını sağlamaları oldukça önemlidir. Dağıtım işletmeleri, sözleşmelerinde vadettikleri performans kriterleri ile Enerji ve Tabii Kaynaklar Bakanlığı tarafından belirlenen hedef ve performans kriterlerine göre enerji arzını sağlamaktadır. Kamunun enerji kesintisinden dolayı uğradığı maddi-manevi zarar, şebekede oluşan arızaların en kısa zamanda giderilmesi için katlanılan maliyet (değişim, tamir ve bakım), şebekenin önleyici bakım maliyeti, oluşabilecek arızalar için gerekli personel ve ekipmanın 7/24 hazırda bulundurulma maliyeti, Enerji ve Tabii Kaynaklar Bakanlığı ile yapılan sözleşme şartnamelerinde yer alan hüküm ve vaadlere uyulmadığında ortaya çıkabilecek cezai durum maliyetleri gibi birçok maliyet kalemi bulunmaktadır. Dağıtım işletmeleri bu maliyetlere katlanma konusunda gerçek zamanlı ve dinamik şekilde kararlar vermek durumundadır. Diğer bir ifadeyle elektrik dağıtım işletmeleri; hangi zamanda, hangi maliyete, hangi oranda katlanması gerektiği konusunda gerçek zamanlı optimal karar verme problemiyle sürekli yüzleşmektedir.

Dağıtım şebekesinin çalışma durumu ve çalışma durumuna etki eden iç/dış faktörler ile ilgili verilerin sürekli akış halinde olması ve veri seti hacminin gerçek

zamanlı artması nedeniyle; derin öğrenme modellerinin sayılarının da gerçek zamanlı olarak arttırılması; daha doğru tahmin modellerine ulaşılabilinmesi amacıyla oldukça önemlidir. Bu şekilde, eğitilen derin öğrenme modellerinin tahmin sonuçlarından oluşan veri setinin de hacmi sürekli artacaktır. Dağıtım işletmeleri, operasyonlarını gerçekleştirirken gerçek zamanlı tahmin için kullanacakları derin öğrenme modelini veritabanından seçerken, içinde bulundukları durumun gerektirdiği hedefler doğrultusunda kararlar vermek durumundadır. Bu ihtiyaç nedeniyle çalışmada, dağıtım işletmelerinin hedefler doğrultusunda optimum kararlar verebilmesi için derin öğrenme modelleri ile hibrit şekilde çalışan hedef programlama modeli de oluşturulmuştur. Derin öğrenme ve hedef programlama modellerinin gerçek zamanlı ve hibrit şekilde çalışması için önerilen algoritma sonraki bölümde yer almaktadır.

4.5. TAHMİN MODELİ SEÇİM SÜRECİNDE DERİN ÖĞRENME VE HEDEF PROGRAMLAMA YÖNTEMLERİNİN HİBRİT MODELLENMESİ

Çalışmada, Çeşme’ de kurulu olan elektrik dağıtım şebekesi için geçmişe ait aynı veri seti ve farklı derin sinir ağı yapıları kullanılarak eğitilen 100 adet derin öğrenme modelinin sonuçları alınmıştır. Bu modeller arasından kamu yararı ve işletme maliyeti açısından belirtilen hedeflere uygun derin öğrenme modelinin seçimi mümkündür. Daha başarılı tahmin modellerini elde etmek amacıyla; hacmi sürekli artan veri seti kullanılarak eğitilen derin model sayılarının gerçek zamanlı şekilde arttırılması ve derin modellerin tahmin sonuçlarının uygun şekilde veritabanına kayıtları oldukça önemlidir. Gerçek hayatta, derin öğrenme modellerinin tahmin sonuçlarından oluşan veri setinin hacmi, gerçek zamanlı ve sürekli akış halindeki verilerle devamlı artacaktır. Tahmin modellerine ait sonuçlardan oluşan veri seti hacminde yaşanacak bu artışla beraber; hedefler doğrultusunda optimum tahmin sonuçlarına sahip olan derin öğrenme modelinin seçimi de zorlaşacaktır. Elektrik dağıtım işletmesinin bir veya birden çok amacının eş zamanlı yerine getirilebileceği hedef programlama modeli sayesinde; sürekli akış halinde artan derin öğrenme modellerinin tahmin sonuçları kullanılarak mevcut duruma en uygun derin öğrenme modelinin seçimi sağlanacaktır. Çalışmada, kamu yararı ve alınan hizmet kalitesinin artırılması yanında; dağıtım işletmelerinin kendi operasyonları ve katlanacakları

maliyetler açısından belirlenen hedeflerle optimum kararların verilebilmesi için derin öğrenme modelleri ile hibrit şekilde çalışan hedef programlama modeli oluşturulmuştur.

4.5.1. Derin Öğrenme ve Hedef Programlama Modellerinin Hibrit Kullanımı İçin Önerilen Algoritma

Derin öğrenme ve hedef programlama modellerinin hibrit şekilde kullanılarak; elektrik dağıtım ağının saatlik çalışma durumunu gerçek zamanlı öngören derin modelin seçimi için önerilen algoritmaya ait kodlar gizlilik ve özel haklar nedeniyle saklı tutulmuştur. Oluşturulan hedef programlama modelinde genel olarak; enerji arzının devamlılığı, kamunun aldığı hizmet kalitesinin artırılması, elektrik kesintisinde meydana gelebilecek yüksek maliyetlerin ve dağıtım işletmesi operasyon maliyetlerinin azaltılması konularına odaklanılmıştır. Derin öğrenme ve hedef programlama modellerinin gerçek zamanlı ve hibrit şekilde çalışması için önerilen algoritmanın süreç şeması Şekil 98’ de yer almaktadır.

Önerilen Algoritma ve Hedef Programlama Modeli:

/ Algoritmaya ait kodlar gizlilik ve özel haklar nedeniyle saklı tutulmuştur /

Start

.....

.....

.....

if (Yeni derin öğrenme modeli sonucu veritabanına eklendi mi?)

{

.....

.....

for (i=1; i<=k; i++)

{

.....

.....

$$Z_{i \min} = p_1 d_1^+ + p_2 d_2^+ + p_3 d_3^+ + p_4 d_4^+ + p_5 d_5^+ + p_6 d_6^- + p_7 d_7^- + p_8 d_8^+ + p_9 d_9^+ + p_{10} d_{10}^- + p_{11} d_{11}^- + p_{12} d_{12}^- + p_{13} d_{13}^- + p_{14} d_{14}^+ + p_{15} d_{15}^+$$

$$x_{i1}m_1 + x_{i2}m_2 + x_{i3}m_3 + x_{i4}m_4 + d_1^- - d_1^+ = B_i$$

/Toplam maliyette bütçe aşılamaz/

$$x_{i1} - (x_{i1} + x_{i4}) * 0.95 + d_2^- - d_2^+ = 0$$

/x_{i1}, doğru tahminlerin %95' inden büyük olamaz/

$$x_{i2} - (x_{i1} + x_{i4})/2 + d_3^- - d_3^+ = 0$$

/x_{i2}, doğru tahminlerin yarısından büyük olamaz/

$$x_{i3} - (x_{i1} + x_{i4})/3 + d_4^- - d_4^+ = 0$$

/x_{i3}, doğru tahminlerin üçte birinden büyük olamaz/

$$x_{i4} - (x_{i1} + x_{i4}) * 0.95 + d_5^- - d_5^+ = 0$$

/x_{i4}, doğru tahminlerin %95' inden büyük olamaz/

$$x_{i1} * 100/(x_{i1} + x_{i4}) + d_6^- - d_6^+ = \text{Max DTD } [i][1] \quad (1 \leq i)$$

/x_{i1} yüzdelik payı $\geq$ Max DTD [i][1] olmalıdır/

$$x_{i4} * 100/(x_{i1} + x_{i4}) + d_7^- - d_7^+ = \text{Max DTD } [i][4] \quad (1 \leq i)$$

/x_{i4} yüzdelik payı $\geq$ Max DTD [i][4] olmalıdır/

$$x_{i2} * 100/(x_{i1} + x_{i4}) + d_8^- - d_8^+ = \text{Min YTD } [i][2] \quad (1 \leq i)$$

/x_{i2} yüzdelik payı $\leq$ Min YTD [i][2] olmalıdır/

$$x_{i3} * 100/(x_{i1} + x_{i4}) + d_9^- - d_9^+ = \text{Min YTD } [i][3] \quad (1 \leq i)$$

/x_{i3} yüzdelik payı $\leq$ Min YTD [i][3] olmalıdır/

$$(x_{i1} + x_{i4}) * 100/(x_{i1} + x_{i2} + x_{i3} + x_{i4}) + d_{10}^- - d_{10}^+ = GB_i$$

/(x_{i1}+ x_{i4}) ün yüzdelik payı $\geq$ Max Model[i][5] olmalıdır/

$$70 - (x_{i1} + x_{i4}) * 100/(x_{i1} + x_{i2} + x_{i3} + x_{i4}) + d_{11}^- - d_{11}^+ = 0$$

/Tahminlerin %70 ve fazlası doğru olmalıdır/

$$x_{i1} * 100/(x_{i1} + x_{i2} + x_{i3} + x_{i4}) + d_{12}^- - d_{12}^+ = h_{i1}$$

/x_{i1} yüzdelik payı en az h_{i1} değeri kadar olmalıdır/

$$x_{i4} * 100/(x_{i1} + x_{i2} + x_{i3} + x_{i4}) + d_{13}^- - d_{13}^+ = h_{i4}$$

/x_{i4} yüzdelik payı en az h_{i4} değeri kadar olmalıdır/

$$x_{i2} * 100/(x_{i1} + x_{i2} + x_{i3} + x_{i4}) + d_{14}^- - d_{14}^+ = h_{i2}$$

/x_{i2} yüzdelik payı en fazla h_{i2} değeri kadar olmalıdır/

$$x_{i3} * 100/(x_{i1} + x_{i2} + x_{i3} + x_{i4}) + d_{15}^- - d_{15}^+ = h_{i3}$$

/x_{i3} yüzdelik payı en fazla h_{i3} değeri kadar olmalıdır/

$$x_{i1}, x_{i2}, x_{i3}, x_{i4}, h_{i1}, h_{i2}, h_{i3}, h_{i4} \text{ tamsayı}$$

$$x_{i1}, x_{i4}, h_{i1}, h_{i4} > 0$$

$$x_{i2}, x_{i3}, h_{i2}, h_{i3} \geq 0$$

.....

.....

.....

}

.....

.....

}

End

Önerilen algoritmanın pseudo kodu işlem adımları aşağıdaki gibi sıralanmaktadır:

1. Yeni derin öğrenme modelinin eğitimini tamamlaması ve tahmin sonucunun oluşturulması.
2. Yeni derin öğrenme modelinin tahmin sonucunun veritabanına kaydedilmesi (Model $[i][j]$, $0 \leq i \leq k$, $1 \leq j \leq 5$).
3. Tahmin sonuçları ve güncel birim maliyetler kullanılarak; tahmin modelinin maliyetlerinin hesaplanarak veritabanına kaydedilmesi.
4. Veritabanına eklenen her derin öğrenme modelinden ve/veya güncellenen her kısıttan sonra kamunun aldığı hizmet kalitesi (başarı) ve işletme maliyetlerine ait hedeflerle hedef programlama modelinin çalıştırılması.
5. Oluşturulan hedef programlama modeli sonucuna göre modelin başarısının ve maliyetlerinin hesaplanarak veritabanına kaydedilmesi.
6. Döngünün her seferinde gerçek zamanlı şekilde önceden hesaplanan derin öğrenme modeli ve hedef programlama modelinin başarı ve maliyetlerinin farklarının alınması.
7. Hem başarı hem de maliyet farkının en küçük olduğu i 'inci modelin seçilmesi ve bu modelin kullanılması.
8. Daha iyi sonucun elde edildiği i 'inci modele rastlanıldığında önceki modelin unutulması ve yeni i 'inci modelin kullanılması.

Oluşturulan hedef programlama modeline ait değişkenler ve model paramereleri:

m_1 : True Positive (TP) /Doğru Pozitif birim maliyeti (0-0)

m_2 : False Positive (FP) /Yanlış Pozitif birim maliyeti (0-1)

m_3 : False Negative (FN) /Yanlış Negatif birim maliyeti (1-0)

m_4 : True Negative (TN) /Doğru Negatif birim maliyeti (1-1)

m_5 : t_5 birim maliyeti (overall accuracy)

x_{ij} : Hedef programlama modelinde bulunan tahmin değerleri ($0 < j < 5$)

TD : Genel tahmin doğruluk yüzdesi

DTD : Tahmin sonucunun doğru isabet edilenler içindeki payı

YTD : Tahmin sonucunun yanlış isabet edilenler içindeki payı

p_n : Hedeflerin öncelik katsayıları

B_i : Bütçe

h_{ij} : TP,FP, FN,TN hedef değerleri (Min h_{i1} , Max h_{i2} , Max h_{i3} , Min h_{i4})

GB: Kullanıcı tarafından belirlenen hedef genel başarı değeri (Overall accuracy)

Önerilen algoritmada, hedef programlama modelinde bulunan sonuçlara en yakın olan derin model veritabanından seçilmektedir (tahmin doğruluğu, maliyetler vd hedefler). Algoritma, her eklenen derin öğrenme modeli için döngünün tekrarlandığı şekilde oluşturulmuştur. Hedef programlama modelini daha esnek yapıya kavuşturmak ve güncellenecek ve/veya eklenecek her hedef için modeli kullanılabilir hale dönüştürmek amacıyla amaç fonksiyonu;

k : hedef sayısı,

p_n : hedef öncelik katsayısı,

n_n^+, n_n^- : amaç fonksiyonuna ekleme kararı için hedef sapma değişkenlerine ait katsayılar,

$n_1^+, n_1^-, n_2^+, n_2^-, \dots, n_n^+, n_n^- \mid (n_n^+, n_n^- = 0 \text{ veya } 1 \text{ ve } (n_n^+ + n_n^-) = 1 \text{ olmak üzere})$

$$Z_{min} = \sum_{n=1}^k p_n * (n_n^+ d_n^+ + n_n^- d_n^-)$$

şeklinde oluşturulabilmektedir.

Çalışmada, eğitilen ve tahmin sonuçları alınan 100 derin öğrenme modeli arasından; kamu yararının artırılması ve dağıtım işletmesinin maliyetlerinin azaltılması amacıyla oluşturulan hedeflerin sağlandığı en uygun derin öğrenme modelinin seçimi yapılmıştır. Oluşturulan hedef programlama modelinde hedeflere ait öncelik katsayıları Tablo 21’ de yer almaktadır.

Tablo 21: Hedef Programlama Modelinin Hedef Öncelik Katsayıları

Hedef Öncelik Katsayıları	p_1	p_2	p_3	p_4	p_5	p_6	p_7	p_8	p_9	p_{10}	p_{11}	p_{12}	p_{13}	p_{14}	p_{15}
	3	1	5	10	1	5	10	5	10	10	10	10	10	3	10

Hedef programlama modeli 15 hedef ve 3 farklı birim maliyet senaryosu baz alınarak çalıştırılmıştır. Bu senaryolara göre 100 farklı derin öğrenme modeli arasından

hedefleri en iyi şartlarda karşılayan derin öğrenme modelinin seçimi yapılmıştır. Üç duruma ait birim maliyet setleri Tablo 22’ de yer almaktadır.

Tablo 22: Hedef Programlama Modeline Ait Maliyet Senaryoları

Senaryo/Birim Maliyet	m_1	m_2	m_3	m_4
Durum-1	1	1	1	1
Durum-2	1	7	3	1
Durum-3	1	3	7	1

- Durum-1: Tüm birim ceza maliyetleri (penalty cost) eşit değerlere sahiptir.
- Durum-2: Arızanın olmayacağı ve arızanın olacağı durumlar için 1’ er birim maliyet atanmıştır. Tahmin sonucuna göre arızanın yaşanacağı ancak; gerçekte arızanın yaşanmadığı durumlar için birim maliyet yüksek tutulmuştur (7 birim). Tahmin sonucuna göre arızanın yaşanmayacağı ancak; gerçekte arızanın yaşandığı durumlar için birim maliyet düşük tutulmuştur (3 birim).
- Durum-3: Arızanın olmadığı ve arızanın olduğu durumlar için 1’ er birim değer atanmıştır. Tahmin sonucuna göre arızanın yaşanacağı ancak; gerçekte arızanın yaşanmadığı durumlar için birim maliyet düşük tutulmuştur (3 birim). Tahmin sonucuna göre arızanın yaşanmayacağı ancak; gerçekte arızanın yaşandığı durumlar için birim maliyet yüksek tutulmuştur (7 birim).

Tablo 23: Tahmin Hata Matrisi İçin Hedef Değerler

Tahminler İçin % Hedef Değerleri (h_{ij})	h_{i1}	h_{i2}	h_{i3}	h_{i4}
	70.13	3.13	4.1	23

h_{i1} : Arızanın olmadığı durumların doğru tahmininin minimum yüzdelik hedef değeri

h_{i2} : Tahmin sonucuna göre arızanın yaşanacağı; gerçek hayatta arızanın yaşanmadığı durumlar için maksimum yüzdelik hedef değeri

h_{i3} : Tahmin sonucuna göre arızanın yaşanmayacağı; gerçek hayatta arızanın yaşandığı durumlar için maksimum yüzdelik hedef değeri

h_{i4} : Arızanın olduğu durumların doğru tahmininin minimum yüzdelik hedef değeri

Hedef programlama modelinde GB_i ile gösterilen ve kullanıcı tarafından belirlenen minimum hedef genel başarı değeri (overall accuracy) %70 olarak tanımlanmıştır. Bütçe (B_i) ‘ ye de 5000 değeri başlangıç değeri olarak atanmıştır.

Birbirinden farklı 3 senaryo ile çalıştırılan hedef programlama modeline ait amaç fonksiyonu maliyetleri ile tahmin sonuçlarına göre bu maliyetlere sebep olan derin öğrenme modellerinin listesi Tablo 24’ te yer almaktadır. Tabloda farklı 3 durum için öncelik sıralamaları dikkate alınarak; 1’ den başlayan ve önemi azalarak devam eden en iyi ilk 10 derin öğrenme modeli listelenmektedir. Hedef programlama modelinin hedeflerine ve amaç fonksiyonuna ait ceza maliyet (penalty cost) tablosu EK 4’ te yer almaktadır.

Tablo 24: Hedef Programlama İle Seçilen En İyi Derin Öğrenme Modelleri

Derin Öğrenme Modeli Seçim Önceliği	Durum-1			Durum-2			Durum-3		
	Seçilen Model	Overall Accuracy	Min Z_{1j}	Seçilen Model	Overall Accuracy	Min Z_{2j}	Seçilen Model	Overall Accuracy	Min Z_{3j}
1	Model-52	72.19	-11513.9	Model-14	73.21	-1809.4	Model-72	70.13	6786.3
2	Model-61	72.49	-11506.1	Model-7	72.97	-1222.6	Model-92	66.26	7007.2
3	Model-31	71.43	-11379.2	Model-61	72.49	151.9	Model-16	68.84	7069.6
4	Model-62	71.40	-11339.3	Model-15	72.23	329.6	Model-31	71.43	7322.8
5	Model-36	72.21	-11330.6	Model-63	72.04	448.3	Model-91	69.24	7360.7
6	Model-94	71.74	-11329.6	Model-36	72.21	537.4	Model-69	67.15	7393.2
7	Model-7	72.97	-11242.6	Model-52	72.19	804.1	Model-62	71.40	7428.7
8	Model-15	72.23	-11196.4	Model-24	71.76	965.0	Model-74	70.28	7475.8
9	Model-14	73.21	-11175.4	Model-9	71.72	1242.7	Model-37	66.15	7554.8
10	Model-72	70.13	-11129.7	Model-94	71.74	1546.4	Model-42	69.71	7560.9

Çalışmada, Çeşme elektrik dağıtım ağı için eğitilen ve tahmin sonuçları alınan 100 derin model arasında; Durum-1’ e göre “Model-52”, Durum-2’ ye göre “Model-14” ve Durum-3’ e göre “Model-72” en iyi derin öğrenme modelleri olarak tespit edilmiştir. Üç durum için ayrı ayrı en iyi derin öğrenme modelinin seçimi yapılırken; çalıştırılan hedef programlama modelinin amaç fonksiyonunun en küçük değerine, tahmin sonuçlarıyla en yakın ceza maliyeti (penalty cost) olan derin öğrenme modeli

veritabanından sorgulanmıştır. Bu şekilde 3 durum için mevcut hedef ve beklentileri en iyi şekilde karşılayan derin öğrenme modellerinin seçimi yapılmıştır.

Yapılan analizlerde Durum-1’ de her bir birim maliyetin (m_i) aşağıda gösterilen aralıklarda olan değişimi, hedef programlama modelinin kararını etkilememektedir.

$$1 \leq m_1 < 1.5$$


$$1 \leq m_2 < 1.06$$

$$1 \leq m_3 < 1.8$$

$$1 \leq m_4 < 1.08$$


Birim ceza maliyetlerin birbirine eşit olduğu Durum-1’ de hedef programlama modelinden elde edilen sonuçlara göre hedefleri en uygun şekilde karşılayan ilk 10 derin öğrenme modeline ait tahmin genel doğruluk skoru ve modelin ceza maliyeti Şekil 99’ da yer almaktadır. Yapılan analizde Durum-1’ e göre toplam ceza maliyeti bakımından en uygun model Model-52 olarak tespit edilmiştir. Hedefleri karşılamadaki uygunluk düzeyine göre Model-52’ yi sırasıyla Model-61, Model-31, Model-62, Model-36, Model-94, Model-7, Model-15, Model-14 ve Model-72 izlemektedir.

Şekil 99: Durum-1’ e Göre Seçilen Derin Öğrenme Modelleri




Durum-2’ de derin modeller tarafından arıza tahmininin yapıldığı ve gerçekte arızanın yaşanmadığı durumlara ait birim ceza maliyeti; sağlıklı durum tahmininin yapıldığı ve gerçekte arızanın olduğu durumlara ait birim ceza maliyetinden fazladır. Bu senaryoda hedef programlama modelinden elde edilen sonuçlara göre derin öğrenme modellerine ait overall accuracy skoru ve ceza maliyeti Şekil 100’ de yer almaktadır. Yapılan analizde Durum-2’ ye göre toplam ceza maliyeti bakımından en uygun model Model-14 olarak tespit edilmiştir. Hedefleri karşılamadaki uygunluk düzeyine göre Model-14’ ten sonra sırasıyla Model-7, Model-61, Model-15, Model-63, Model-36, Model-52, Model-24, Model-9 ve Model-94 izlemektedir.

Şekil 100: Durum-2’ ye Göre Seçilen Derin Öğrenme Modelleri



Durum-3’ te derin modeller tarafından sağlıklı durum tahmininin yapıldığı ve gerçekte arızanın yaşandığı durumlara ait birim ceza maliyeti; arıza tahmininin yapıldığı ve gerçekte arızanın olmadığı durumlara ait birim ceza maliyetinden fazladır. Bu senaryoda hedef programlama modelinden elde edilen sonuçlara göre derin öğrenme modellerine ait overall accuracy skoru ve ceza maliyeti Şekil 101’ de yer almaktadır. Yapılan analizde Durum-3’ e göre toplam ceza maliyeti bakımından en uygun model Model-72 olarak tespit edilmiştir. Hedefleri karşılamadaki uygunluk düzeyine göre Model-72’ den sonra sırasıyla Model-92, Model-16, Model-31, Model-91, Model-69, Model-62, Model-74, Model-37 ve Model-42 izlemektedir.

Şekil 101: Durum-3' e Göre Seçilen Derin Öğrenme Modelleri



Endüstri 4.0 teknolojileri sayesinde; elektrik dağıtım şebekelerini etkileyen iç ve dış faktörlere ait veriler gerçek zamanlı ve sürekli akış halinde artmaktadır. Elde edilen bu fırsat sayesinde; derin öğrenme modellerinin eğitim ve test süreçlerinde kullandığı veri setlerinin hacmi de sürekli artmaktadır. Veri setlerinin büyük hacimlerde oluşu; derin öğrenme modellerinin daha başarılı tahminlerde bulunabilmesi açısından oldukça önemlidir. Çalışmada önerilen derin öğrenme ve hedef programlamadan oluşan hibrit modelde optimizasyonun sağlanması amacıyla; hedef programlama modelinin kısıt ve parametrelerinin bir kısmı derin öğrenme modellerinden elde edilen sonuçlar kullanılarak otonom şekilde güncellenmektedir. Derin öğrenme modellerinin test sürecinde kullandığı veri setlerinin büyümesi nedeniyle tahmin sonuçlarına ait değerler de artmaktadır. Hedef programlama modelinin hibrit çalışma esnasında bu artıştan etkilenmemesi amacıyla; kısıtlardaki anahtar performans kriterleri yüzdelik oranlar olarak modele dâhil edilmiştir. Çalışmada hedeflenen model; gerçek zamanlı toplanan şebeke durum verileri ile şebekeyi etkileyen iç/dış faktör verileri kullanılarak yeni derin öğrenme modelinin ve hedef programlama modelinin hibrit ve gerçek zamanlı çalıştırılmasıdır. Bu yöntem sayesinde derin öğrenme modeli tahmin sonuçlarının sürekli iyileştirilerek %100 doğruluğa ve tüm hedeflere olabildiğince yaklaşılması sağlınırken; elektrik dağıtım ağı durum bilgisinin gerçek zamanlı öngörülmesi ve şebekeye ait ilgili operasyonların gerçek zamanlı gerçekleştirilmesi hedeflenmektedir.

SONUÇ

Ürünlerin, nesnelerin, süreçlerin, makinaların, robotların, teçhizatların, ekipmanların ve daha birçok platformun gerçek zamanlı birbirine bağlanıp; operasyonların otonom ve gerçek zamanlı gerçekleştirildiği Endüstri 4.0 dönüşümü sayesinde günlük yaşam birçok noktada doğrudan etkilenmektedir. İşleri, süreçleri, operasyonları ve sistemleri düzenleyip yöneten kamu kurumlarının gerekli teknolojik altyapıyı sağlayarak performans ve verimlilik artışı elde etmeleri; daha refah ve gelişmiş bir toplumun oluşmasında önemli katkılar sağlamaktadır. Endüstri 4.0 dönüşümü sayesinde Türkiye kamu ve özel sektör sistemlerinde devlet yönetim etkinliği ve kurumlardan alınan hizmetin kalite düzeyinde önemli iyileşmeler sağlanacaktır. Kamu harcamaları azalacak ve Türkiye' nin uluslararası platformda rekabet gücü artacaktır. Devlet harcamalarının oldukça fazla olduğu enerji, sağlık ve savunma gibi sektörlerde yapılacak etkin iyileştirmeler ve entegre edilecek etkin sistemler sayesinde Türkiye kaynaklarını daha verimli kullanacaktır.

Türkiye'de bakanlıklar, kamu kurum ve kuruluşlar bünyesinde, merkezi devlet kontrolü ve milli veritabanı sistemi kullanılarak gerçekleştirilecek Endüstri 4.0 dönüşümü sayesinde istenmeyen birçok durum ortadan kalkıp süreçler yalınlaşacaktır. Devletin tüm birimleri, süreçleri ve operasyonları gerçek zamanlı izlenebilecek, yapay zekâ uygulamaları sayesinde çoğu süreç otonomlaştırılacak, kaynaklar optimum düzeyde yönetilebilecek ve yatırımlar için gerçek zamanlı raporlamalar elde edilebilecektir. Türkiye daha fazla yatırım yapabilme imkânına kavuşup; Ar-Ge bütçesini artıracaktır. Azalan kamu hizmet giderleri sayesinde kamudan toplanan vergiler azalırken; kamunun refah seviyesi yükselecektir. Petrol, enerji, ilaç ve sağlık harcamaları gibi cari açığa neden olan ithalat kalemleri; israfların azalması ve kaynakların optimum düzeyde kullanılması sonucu azalacaktır.

Endüstri 4.0 entegrasyonu ile milyonlarca makina, eşya ve nesnenin internete bağlanma zorunluluğu bulunmaktadır. Türkiye' de bu alanda kullanılan donanım ve yazılımlara ait yerli teknolojik ürün üretme altyapısının geliştirilmesi; milli güvenliğin sağlanması ve cari açığın azaltılması açısından oldukça önemlidir. Türkiye kamu kurumları arasındaki teknolojik altyapının gerçek zamanlı veri transferini sağlaması; bürokratik aksamaları ve süreçlerde yaşanan israfları engelleyecektir. Kamuya ait

veriler, uygun önlemler eşliğinde siber güvenliğin sağlandığı ve tamamen devlet denetimindeki tek merkezden kontrollü yetkilerle sağlanarak; kamu kurumları ve vatandaşların hizmetine sunulmalıdır. Endüstri 4.0 dönüşümü sayesinde bireylerin verdiği yetkiler doğrultusunda, kişilere ait birçok kamu kurum işlemleri otomatik şekilde gerçekleştirilecektir. Endüstri 4.0 ile kamu kurumlarının tedarik zinciri yönetimi ve fiziki varlık yönetimi otomatikleştirilip; gereksiz satın alımlarının önüne geçilecektir. İş ve personel performans analizleri otomatik ve sağlıklı bir şekilde yapılp; devlet personel istihdamı konusunda tasarruflara gidilebilecektir. İl bazında düşünüldüğünde, kurumlar gerçek zamanlı veri paylaşımı yaparak; imar, enerji dağıtım hatları kurulumu, trafik uygulamaları, yol yapım, asfaltlama-kaldırım, peyzaj, su/kanalizasyon şebekesi uygulamaları, altyapı ve üstyapılara ait tüm belediyeçilik işlemlerine ait uygulamaların sık ve gereksiz tekrarlarının önüne geçilecektir. Bir kurumun yaptığı hizmetin kısa süre sonra başka bir kurum tarafından kendi işlemi için yıkılmasının veya kullanılamaz hale getirilmesinin önüne geçilecektir. Her kurum yapacağı işlemleri ve operasyon planını diğer kurumlarla gerçek zamanlı paylaşarak; kendi aralarında ortak operasyon takvimi geliştirebilecektir. Bu şekilde gereksiz devlet harcamalarından ve yüksek maliyetli israflardan tasarruf sağlanacaktır.

Dünya genelinde çalışmalarına yakın zamanda başlanan Endüstri 4.0 dönüşümünün; enerji sektörü gibi stratejik ve kamu hizmeti bakımından yüksek önem arz eden bir alanda yapılması, Türkiye açısından oldukça önemli bir kazanımdır. Bu çalışmada, enerji sektöründe yer alan elektrik enerjisi dağıtım ağları için Endüstri 4.0 teknolojileri entegrasyonunun, yapay zeka tekniği olan derin öğrenme modelinin ve optimizasyon algoritması olan hedef programlama modelinin sağladığı kazanımlar konusunda gerçek verilerle vaka çalışması yapılmıştır. Çalışmada, Endüstri 4.0 ve teknolojileri konularında literatür araştırması yapılmıştır. Ülkemizdeki çeşitli sektörlerde Endüstri 4.0 dönüşümün katkılarına değinilmiştir. Enerji sektöründe ve elektrik enerjisi dağıtım ağlarında yaşanan arızalarla ilgili kapsamlı literatür taraması yapılmıştır. Yapay zeka, makine öğrenmesi ve derin öğrenme konularında literatür incelenmiştir. Endüstri 4.0 teknolojilerine ait altyapıların sunduğu fırsatlar ile derin öğrenme ve hedef programlama yöntemlerinden oluşan hibrit model önerilmiştir. Enerji sektöründe yapay zekâ teknikleri kullanılarak yapılan önceki çalışmalarda, genellikle şebekenin bir bileşeni, elektrikli cihaz ve teçhizatların kullanım ömrü, enerji

talep tahmini, pil ömrü ve ürün arızaları gibi başlıklara odaklanılmıştır. Elektrik enerjisi tüketimi ve meteorolojik faktörlerin elektrik dağıtım ağlarının çalışma durumu üzerindeki etkisini yapay zekâ tekniklerini kullanarak inceleyen çalışmaya rastlanılmamıştır.

Elektrik enerjisi dağıtım ağlarının sağlıklı ve verimli çalışması, arızaların tahminine, erken tespitine ve ortaya çıkan arızaların hızlı şekilde giderilmesine bağlıdır. Çalışmada, Çeşme’ de kurulu olan elektrik enerjisi dağıtım ağının gerçek zamanlı sistem çalışma durumu tahmini için, saatlik bazda geçmiş veri setleri kullanılarak 100 farklı derin öğrenme modeli eğitilmiş ve modellerin saatlik tahmin sonuçları alınmıştır. Geleceğe ait saatlik şebeke durum tahminleri yapılırken; geçmiş veri setlerinin yanında; elektrik tüketimi gelecek tahmin verileri ile meteorolojik faktörlere ait gelecek tahmin verileri kullanılmaktadır. Elektrik enerjisine kesintisiz ulaşım hedefiyle bireylerin, kamu ve özel sektör işletmelerinin aldığı hizmet kalitesinin artırılmasına paralel; elektrik dağıtım işletmesinin operasyon maliyetlerinin minimizasyonunu sağlayan optimum kararların verilebilmesi için hedef programlama modeli oluşturulmuştur. Ardından derin öğrenme ve hedef programlama modellerini hibrit şekilde çalıştırıp; elektrik dağıtım şebekesinin saatlik durum tahmini için en uygun derin öğrenme modelini belirleyen algoritma önerilmiştir (Şekil 98). Hedef programlama modeli birbirinden farklı 3 senaryo ile çalıştırılarak; bu senaryoların herbiri için 100 derin öğrenme modeli arasından hedefleri karşılayan en iyi derin öğrenme modeli seçilmiştir. Çalışmanın, dağıtım şebekelerinin çalışma durumuna etki eden faktör sayısının ve veri hacminin artırılması yanında; kullanılan tekniklerin daha da geliştirilerek Türkiye’ de kurulu ve kurulacak olan tüm elektrik enerjisi dağıtım şebekelerine uygulanması için ön çalışma olması amaçlanmıştır.

Çalışmada dağıtım şebekesinin saatlik çalışma durumu tahmini için oluşturulan derin öğrenme modelleri eğitilirken; saatlik şebeke durumu (arıza/sağlıklı çalışma), şebekeyi etkileyen enerji tüketim miktarı (iç faktör) ve meteorolojik faktörlere (dış faktör) ait saatlik veriler kullanılmıştır. Veriler 27 aylık süreyi kapsamaktadır. Diğer faktörlerle ait geçmiş dijital veri kayıtları bulunmadığından dolayı bu faktörler derin öğrenme modellerine eklenememiştir. Verilerin %70’ i (11013 saatlik) öğrenme ve %30’ u (4721 saatlik) test veri seti olmak üzere rastgele iki gruba ayrılmıştır. Modelin girdisi olarak elektrik tüketimi (kWh), aktüel basınç (hPa), işba sıcaklığı, nisbi nem,

rüzgâr hızı (m/s), rüzgâr yönü (°), sıcaklık (°C), yağış miktarı (mm=kg/m²) ve haftanın günü faktörleri kullanılmıştır. Uygun modeli belirleme sürecinde farklı ağ yapıları ile modeller eğitilmiştir. Derin öğrenme modellerinde Evrişimsel Sinir Ağları (CNN) ve öğrenme yöntemi olarak ileri beslemeli sınıflandırma kullanılmıştır. Öğrenme sürecinde derin sinir ağları 11013 saatlik veri seti kullanılarak gözetimli şekilde eğitilmiştir. Aynı veri seti ve birbirinden farklı ağ yapıları kullanılarak toplamda 100 farklı derin öğrenme modeli eğitilmiştir. Eğitim sürecinden sonra 4721 saatlik test veri seti kullanılarak tahmin sonuçları hesaplanmıştır. Her derin öğrenme modelinin test sürecinde şebekenin gerçek hayattaki çalışma durumu ve tahmin sonuçları karşılaştırılmıştır.

Dağıtım şebekesini etkileyen iç ve dış faktörlerin yol açtığı hasarı azaltmak için ilgili kurumlar tarafından yapay zekâya dayalı tahmin modelleri kullanılarak; önleyici tedbirlerin alınması ve oluşacak arızanın en kısa sürede giderilmesi için operasyonların planlanması oldukça önemlidir. Gelecekte yapılacak çalışmalarda, dağıtım şebekelerinde Endüstri 4.0 teknolojilerine ait altyapıların daha da gelişmesi sayesinde şebeke durumunu etkileyen iç (iletim kablo uzunlukları, kablo kesitleri, trafo özellikleri, markalar... vd.) ve dış faktörlere ait veriler daha doğru ve kolay biçimde elde edilecektir. Bunun yanında derin sinir ağlarında farklı öğrenme algoritmalarının kullanılması ve katman, nöron ve epoch değerlerinin optimum seviyelerde ayarlanması sayesinde şebeke durumları daha başarılı şekilde tahmin edilecektir.

Elektrik kesintisinin yaşandığı zaman diliminde kamunun gördüğü zararın maliyetini hesaplamak oldukça zordur. Dağıtım işletmeleri, abonelerine kesintisiz ve uygun şekilde enerji arzını sağlamakla yükümlüdür. Dağıtım işletmeleri, sözleşmelerinde vadettikleri performans kriterleri ile Enerji ve Tabii Kaynaklar Bakanlığı tarafından belirlenen hedef ve performans kriterlerine göre enerji arzını sağlamaktadır. Kamunun enerji kesintisinden dolayı uğradığı maddi-manevi zarar, şebekede oluşan arızaların en kısa zamanda giderilmesi için katılan maliyet (değişim, tamir ve bakım), şebekenin önleyici bakım maliyeti, oluşabilecek arızalar için gerekli personel ve ekipmanın 7/24 hazırda bulundurulma maliyeti, Enerji ve Tabii Kaynaklar Bakanlığı ile yapılan sözleşme şartnamelerinde yer alan hüküm ve vaadlere uyulmadığı durumlarda uygulanacak cezai durum maliyeti gibi birçok maliyet kalemi bulunmaktadır. Dağıtım işletmeleri bu maliyetlere katlanma konusunda gerçek

zamanlı ve durum bazlı dinamik kararlar vermek durumundadır. İşletmeler, hangi zamanda, hangi maliyete, hangi oranda katlanması gerektiği problemiyle sürekli karşılaşarak operasyonlarını yürütmektedir.

Dağıtım şebekelerinin çalışma durumunu daha başarılı şekilde tahmin etmek amacıyla; sürekli akış halinde artan şebeke durum verileri ile şebekeyi etkileyen iç/dış faktörlere ait veri setleri kullanılarak yeni derin öğrenme modellerinin eğitilmesi ve elde edilen tahmin sonuçlarının veritabanına kayıtları oldukça önemlidir. Bu şekilde derin öğrenme modellerinin tahmin sonuçlarından oluşan veri setinin hacmi de sürekli artacaktır. Dağıtım işletmeleri, gerçek zamanlı şebeke durum tahmini için kullanılacak derin öğrenme modelini veritabanından seçerken; içinde bulundukları durumun gerektirdiği hedefler doğrultusunda kararlar vermek durumundadır. Bu nedenle, durum bazlı hedefler doğrultusunda optimum kararların verilebilmesi için derin öğrenme modelleri ile hibrit şekilde çalışan hedef programlama modeli oluşturulmuştur. Hedef programlama modeli sayesinde, veritabanında sürekli artan derin öğrenme modellerine ait tahmin sonuçları kullanılarak; mevcut hedeflerin karşılandığı en uygun derin öğrenme modelinin seçimi sağlanmaktadır. Ayrıca çalışmada, derin öğrenme ve hedef programlama modellerinden oluşan hibrit modeli gerçek zamanlı çalıştıran yeni bir algoritma geliştirilmiştir. Literatürde bu alandaki boşluk doldurulmaya çalışılmıştır.

Çalışmada birbirinden farklı 3 senaryo ile oluşturulan hedefler doğrultusunda hedef programlama modeli çalıştırılmıştır. Hedef programlama modeline ait amaç fonksiyonu ceza maliyetleri kullanılarak; tahmin sonuçlarına göre bu ceza maliyetlerine en yakın sonuçlar veren derin öğrenme modelleri bulunmuştur. Her senaryo için öncelik sıralamaları 1' den başlayan ve önemi azalarak devam eden en iyi ilk 10 derin öğrenme modeli Tablo 24' te listelenmiştir. Çeşme elektrik dağıtım ağı için eğitilen ve tahmin sonuçları alınan 100 derin öğrenme modeli arasında; Durum-1' e göre en iyi model "Model-52", Durum-2' ye göre "Model-14" ve Durum-3' e göre "Model-72" olarak tespit edilmiştir. Üç durum için en iyi derin öğrenme modelinin seçimi yapılırken; hedef programlama modelinin amaç fonksiyonunun en küçük değerine, tahmin sonuçlarıyla en yakın ceza maliyeti (penalty cost) bulunan derin öğrenme modeli veritabanından sorgulanmıştır. Bu şekilde 3 durum için mevcut hedef ve beklentileri en iyi şekilde karşılayan derin öğrenme modellerinin seçimi yapılmıştır.

Üç senaryoya ait hedef programlama amaç fonksiyonu ceza maliyetleri ve seçilen derin öğrenme modellerinin tahmin genel doğruluk (overall accuracy) değerlerine ait karşılaştırmalı analizler Şekil 99, Şekil 100 ve Şekil 101’ de yer almaktadır.

Çeşme elektrik dağıtım şebeke durum tahmini için eğitilen derin öğrenme modellerinin genel tahmin başarıları, dağıtım işletmesinin mevcut durumda operasyonlarına ait işleyiş için önemli bir katma değer oluşturmuştur. Şebekenin saatlik çalışma durumu tahmini için oluşturulan hibrit model sayesinde; Durum-1 için overall accuracy değeri %72.19 olan Model-52, Durum-2 için %73.21 değeriyle Model-14 ve Durum-3 için %70.13 değeriyle Model-72 hedefleri en iyi şartlarda karşılayan modeller olarak tespit edilmiştir. Çeşme’ de gerçekleştirilen pilot uygulamadan elde edilen sonuçlara göre geliştirilmeye açık olan bu çalışma, Türkiye elektrik enerjisi dağıtım ağının genelinde hayata geçirildiğinde (dağıtım şebekesini etkileyen iç ve dış faktör güncellemesi ilgili bölge bazında yapılarak);

- Enerjiye kesintisiz ulaşım konusunda bireylerin, kamu ve özel sektör işletmelerinin aldığı hizmet kalitesi artacaktır.
- Dağıtım şebekelerinin yapay zekâya dayalı çalışma öngörüsü sayesinde; kamuya verilen hizmetlerde devlet harcamaları ve elektrik dağıtım işletmelerinin operasyon maliyetleri azalacaktır.
- Dinamik iç ve dış faktör koşullarında enerji dağıtım altyapılarının gerçek zamanlı güvenilirlik analizleri yapılacaktır. Şebekelerin otonom arıza öngörü sistemi oluşturulacak ve şebeke arıza olasılıkları azaltılacaktır.
- Arızalı şebeke bileşenlerine erken ulaşım sağlanacaktır. Arıza tamir ve bakım süreleri kısalarak; elektrik kesintileri azalacaktır. Elektrik kesinti sürelerinin azaltılması sayesinde ekonomiye verilen zarar azalacaktır.
- Şebeke sistemleri için geleceğe ait dinamik davranış modelleri oluşturulacaktır.
- Elektrik dağıtım şebekelerinin güvenilirlik kontrolü ve operasyonları yapay zekâ ile otonomlaştırılacaktır.

Çeşme elektrik dağıtım şebekesinin çalışma durumuna etki eden iç ve dış faktörlerin bir kısmına ait geçmiş dijital veri kayıtlarına ulaşamadığından; bu faktörler, eğitilen derin öğrenme modellerinde kullanılamamıştır. Bu durum ve diğer etkenler nedeniyle; derin öğrenme modellerinin genel tahmin doğruluk sonuçlarında

%100 seviyesinin bir miktar uzağında kalınmıştır. Bu alanda yapılacak sonraki araştırmalara yol göstermesi ve tahmin başarılarının daha yüksek seviyelere ulaşabilmesi amacıyla çeşitli durum tespitleri ve tavsiyeler aşağıda sıralanmaktadır:

- Çeşme ilçesinin yüzölçümü 260 km² olup: meteorolojik faktörlere ait ölçümler ilçede iki farklı konumda yapılmaktadır. Elektrik dağıtım ağı ise ilçenin geneline kurulu durumdadır. İlçenin her noktasında bulunan, yükselti farklılığı, bina ve ağaç gibi rüzgâr hızı, rüzgâr yönü ve diğer meteorolojik faktörleri etkileyebilecek etkenler nedeniyle; şebekenin farklı noktalarını etkileyen meteorolojik faktörlerin şiddetinde, ölçüm istasyonlarının elde ettiği değerlerden sapmalar gerçekleşmektedir. Bu durum derin öğrenme modellerinin tahmin sonuçlarını olumsuz yönde etkilemektedir. Elektrik dağıtım şebekelerinde IoT sistemlerinin ve IoT kapsama alanının geliştirilmesi sayesinde; meteorolojik faktörlere ve şebeke durum verilerine ait gerçek zamanlı toplanan verilerin ilgili konum bazında doğruluğu ve güvenliği artacaktır. Bu şekilde derin sinir ağlarının öğrenme yetenekleri ve tahmin başarıları da artacaktır.
- Şebekeyi oluşturan trafo, makina, teçhizat ve ekipman özellikleri (yaş, kapasite, üretici firma, önceki bakım zamanından sonra geçen süre, bakım nedeni, bakım süresi, arıza nedeni vd), iletim tellerine ait özellikler (kapasite, uzunluklar, miktarlar, tel çeşitleri, tel kesitleri, kullanım ömürleri, genleşme katsayıları, risk katsayıları vd), ilgili komponentin konumu ve konuma ait coğrafi-ekolojik özellikler, tarih, saat, kesintisi süresi, koruma eylemi, soğutma türü gibi birçok etkene ait dijital veri kaydına ulaşamamıştır. Bu faktörlere ait veriler olmadan derin öğrenme modelleri eğitilmiştir. Eksik faktörlerin derin modellere eklenmesi sayesinde modellerin tahmin başarısı artacaktır. Daha fazla ve nitelikli verilerin anlık toplanabilmesinin yanında; şebeke durumu için erken tanı ve erken müdahale yeteneklerinin kazanılabilmesi amacıyla kritik noktalarda veri toplayacak donanımların fazlalaştırılması gerekmektedir. Ayrıca siber fiziksel sistem ve yapay zekâ altyapılarının geliştirilerek; şebekeye anlık otonom müdahalelerde bulunabilme yeteneğinin kazanılması oldukça önemlidir.

- Çalışmada, derin öğrenme modellerinin eğitim sürecine; modellerin ağ yapıları ve özellikleri için parametre optimizasyonu modülü eklenmemiştir. Geliştirilen algoritma sayesinde optimizasyon işlemi; derin öğrenme modellerinin hedef programlama modeli ile hibrit çalıştığı sistem önerilerek sağlanmıştır. Sonraki çalışmalarda derin öğrenme modellerine parametre optimizasyonu algoritmalarının da eklenmesi tahmin başarısını artıracaktır.
- Elektrik dağıtım ağlarında nesnelerin internetine (IoT) ait donanımların daha fazla entegre edilmesi sayesinde; gerçek zamanlı şebeke komponenti bazlı faktör ölçümleri (iç ve dış faktör) ve noktasal arıza tespiti kolaylaşacaktır. Bu şekilde Endüstri 4.0 entegrasyon seviyesi de artacaktır.
- Bölgesel sanayileşme ve turizm verileri, nüfus verileri (artış-azalış, cinsiyet artış-azalış verileri), bölgesel gayrisafi yurtiçi hasıla verileri, geçmiş, gerçek zamanlı ve gelecek tahminlerine ait meteoroloji verileri ve enerji tüketimi gibi faktörlerle oluşturulacak gösterge katsayılarının da şebeke durumunu tahmin eden derin öğrenme modellerine girdi olarak eklenmesi, tahmin hassasiyetini pozitif yönde etkileyecektir.
- Bazı durumlarda bir yerleşim yerinde meydana gelen elektrik kesintisi, farklı bir alanda meydana gelen kesinti sonucunda oluşabilmektedir. Mevcut durumda şebekenin her komponentinde o komponentin anlık durumunu (arızalı/sağlıklı) bildirecek bir IoT sensörü bulunmamaktadır. Bu nedenle eldeki geçmiş dijital verilerle bu iki durumun ayrımı yapılamayıp; derin öğrenme modelleri bu veri setiyle eğitilmiştir. Bu durum derin öğrenme modellerinin tahmin başarılarını negatif yönde etkilemiştir. Dağıtım şebekelerinde daha fazla ve daha gelişmiş IoT entegrasyonu sayesinde Endüstri 4.0 entegrasyon seviyesi ile derin öğrenme modellerinin tahmin başarıları artacaktır.

KAYNAKÇA

Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... Zheng, X. (2016). TensorFlow: A system for large-scale machine learning. *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation, OSDI 2016* içinde (ss. 265–283).

Abbas, Z. ve Yoon, W. (2015). A survey on energy conserving mechanisms for the internet of things: Wireless networking aspects. *Sensors*, 15(10), 24818–24847.

Abdelaziz, F. Ben, Masri, H. ve Alaya, H. (2017). A recourse goal programming approach for airport bus routing problem. *Annals of Operations Research*, 251(1–2), 383–396.

Abdelfatah, M., El-Shimy, M. ve Ismail, H. M. (2011). Reliability analysis of 220 kV power transformers in Egypt. *Ain Shams Engineering Journal*, 2(3–4), 183–194. doi:10.1016/j.asej.2011.09.005

Abdelfatah, M., El-Shimy, M. ve Ismail, H. M. (2013). Outage data analysis of utility power transformers based on outage reports during 2002-2009. *International Journal of Electrical Power and Energy Systems*, 47(1), 41–51. doi:10.1016/j.ijepes.2012.10.060

Achi, H. El, Belousova, T., Chen, L., Wahed, A., Wang, I., Hu, Z., ... Nguyen, A. N. D. (2019). Automated diagnosis of lymphoma with digital pathology images using deep learning. *Annals of Clinical and Laboratory Science*, 49(2), 153–160.

Addo-Tenkorang, R. ve Helo, P. T. (2016). Big data applications in operations/supply-chain management: A literature review. *Computers and Industrial Engineering*, 101, 528–543. doi:10.1016/j.cie.2016.09.023

Ahuett-Garza, H. ve Kurfess, T. (2018). A brief discussion on the trends of habilitating technologies for Industry 4.0 and Smart manufacturing. *Manufacturing Letters*, 15,

60–63.

Akdeniz, E. ve Bagriyanik, M. (2016). A knowledge based decision support algorithm for power transmission system vulnerability impact reduction. *International Journal of Electrical Power and Energy Systems*, 78, 436–444. doi:10.1016/j.ijepes.2015.11.041

Aldweesh, A., Derhab, A. ve Emam, A. Z. (2020). Deep learning approaches for anomaly-based intrusion detection systems: A survey, taxonomy, and open issues. *Knowledge-Based Systems*, 189, 105124. doi:10.1016/j.knosys.2019.105124

Alpaydın, E. (2018). *Yapay Öğrenme*. Boğaziçi Üniversitesi Yayınevi.

Amidi, A. ve Amidi, S. (2018). CS 230-Super VIP Cheatsheet: Deep Learning. Stanford University. <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks> adresinden erişildi.

Anaya, K. L. ve Pollitt, M. G. (2017). Using stochastic frontier analysis to measure the impact of weather on the efficiency of electricity distribution businesses in developing economies. *European Journal of Operational Research*, 263(3), 1078–1094. doi:10.1016/j.ejor.2017.05.054

Anderson, D. ve McNeill, G. (1992). Artificial neural networks technology. *Kaman Sciences Corporation*, 258(6), 1–83.

Aouni, B., Colapinto, C. ve La Torre, D. (2014). Financial portfolio management through the goal programming model: Current state-of-the-art. *European Journal of Operational Research*, 234(2), 536–545.

Azmi, A., Jasni, J., Azis, N. ve Kadir, M. Z. A. A. (2017). Evolution of transformer health index in the form of mathematical equation. *Renewable and Sustainable Energy Reviews*, 76, 687–700. doi:10.1016/j.rser.2017.03.094

Badri, A., Boudreau-Trudel, B. ve Souissi, A. S. (2018). Occupational health and safety in the industry 4.0 era: A cause for major concern? *Safety Science*, 109, 403–411. doi:10.1016/j.ssci.2018.06.012

Bahrin, M. A. K., Othman, M. F., Azli, N. H. N. ve Talib, M. F. (2016). Industry 4.0: A review on industrial automation and robotic. *Jurnal Teknologi*, 78(6–13), 137–143.

Bal Beşikçi, E., Arslan, O., Turan, O. ve Ölçer, A. I. (2016). An artificial neural network based decision support system for energy efficient ship operations. *Computers and Operations Research*, 66, 393–401. doi:10.1016/j.cor.2015.04.004

Balakrishna, P., Rajagopal, K. ve Swarup, K. S. (2017). Distribution automation analysis based on extended load data from AMI systems integration. *International Journal of Electrical Power and Energy Systems*, 86, 154–162. doi:10.1016/j.ijepes.2016.10.005

Baldi, P. (2012). Autoencoders, unsupervised learning, and deep architectures. *Proceedings of ICML workshop on unsupervised and transfer learning* içinde (ss. 37–49).

Baqqar, M. (2015). Machine Performance and Condition Monitoring Using Motor Operating Parameters Through Artificial Intelligence Techniques. University of Huddersfield.

Bartodziej, C. J. (2017). *The Concept Industry 4.0 - An Empirical Analysis of Technologies and Applications in Production Logistics*. Springer Fachmedien Wiesbaden GmbH. Springer. doi:10.1007/978-3-658-16502-4

Basheer, I. A. ve Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3–31.

Basurko, O. C. ve Uriondo, Z. (2015). Condition-based maintenance for medium speed diesel engines used in vessels in operation. *Applied Thermal Engineering*, 80, 404–412.

Baur, C. ve Wee, D. (2015). Manufacturing's next act. *McKinsey & Company*, 6.

Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and Trends in Machine Learning*, 2(1), 1–27. doi:10.1561/22000000006

Bengio, Y., Ducharme, R., Vincent, P. ve Jauvin, C. (2001). A neural probabilistic language model. *Journal of machine learning research*, 3(Feb), 1137–1155.

Benysek, G., Kazmierkowski, M., Popczyk, J. ve Strzelecki, R. (2011). Power electronic systems as a crucial part of Smart Grid infrastructure-a survey. *Bulletin of the Polish Academy of Sciences: Technical sciences*, 59(4), 455–473.

Berecibar, M., Devriendt, F., Dubarry, M., Villarreal, I., Omar, N., Verbeke, W. ve Van Mierlo, J. (2016). Online state of health estimation on NMC cells based on predictive analytics. *Journal of Power Sources*, 320, 239–250.

Borkowski, M., Fdhila, W., Nardelli, M., Rinderle-Ma, S. ve Schulte, S. (2019). Event-based failure prediction in distributed business processes. *Information Systems*, 81, 220–235. doi:10.1016/j.is.2017.12.005

Bossi, A., Dind, J. E., Frisson, J. M., Khoudiakov, U., Light, H. F. ve Al., E. (1983). An International Survey of Failures in Large Power Transformers in Service. *Final report of the CIGRE Working Group 12.05, Electra*, 88(88), 21–48.

Boulemtafes, A., Derhab, A. ve Challal, Y. (2020). A review of privacy-preserving techniques for deep learning. *Neurocomputing*, 384, 21–45. doi:10.1016/j.neucom.2019.11.041

Boullé, N., Dallas, V., Nakatsukasa, Y. ve Samaddar, D. (2020). Classification of chaotic time series with deep learning. *Physica D: Nonlinear Phenomena*, 403, 132261. doi:10.1016/j.physd.2019.132261

Broström, E. ve Söder, L. (2005). Modelling of ICE storms for power transmission reliability calculations. *15th Power Systems Computation Conference, PSCC 2005* içinde . PSCC.

Broström, E. ve Söder, L. (2007). Ice storm impact on power system reliability. *12 th International Workshop on Atmospheric Icing on Structures (IWAIS 2007), Yokohama, Japan* içinde .

Bueno, A. F., Godinho Filho, M. ve Frank, A. G. (2020). Smart Production Planning and Control in the Industry 4.0 context: A systematic literature review. *Computers & Industrial Engineering*, 106774.

Bunse, B., Kagermann, H. ve Wahlster, W. (2014). *Industrie 4.0, Smart Manufacturing for the Future. Report. Germany Trade & Invest. Germany Trade & Invest.*

<http://www.gtai.de/GTAI/Navigation/EN/Invest/Service/Publications/business-information,t=industrie-40--smart-manufacturing-for-the-future,did=917080.html> adresinden erişildi.

Caballero, R., Ruiz, F., Uría, M. V. R. ve Romero, C. (2006). Interactive meta-goal programming. *European Journal of Operational Research*, 175(1), 135–154.

Cárdenas, A. A., Manadhata, P. K. ve Rajan, S. P. (2013). Big data analytics for security. *IEEE Security & Privacy*, 11(6), 74–76.

Carta, J. A., Ramirez, P. ve Velazquez, S. (2009). A review of wind speed probability distributions used in wind energy analysis: Case studies in the Canary Islands. *Renewable and sustainable energy reviews*, 13(5), 933–955.

Catrinu, M. D. ve Nordgård, D. E. (2011). Integrating risk analysis and multi-criteria decision support under uncertainty in electricity distribution system asset management. *Reliability Engineering and System Safety*, 96(6), 663–670. doi:10.1016/j.ress.2010.12.028

Chen, M., Mao, S. ve Liu, Y. (2014). Big data: A survey. *Mobile Networks and Applications*, 19(2), 171–209. doi:10.1007/s11036-013-0489-0

Chiarello, F., Trivelli, L., Bonaccorsi, A. ve Fantoni, G. (2018). Extracting and mapping industry 4.0 technologies using wikipedia. *Computers in Industry*, 100, 244–257. doi:10.1016/j.compind.2018.04.006

Collobert, R., Weston, J., Bottou, L., Karlen, M., Kavukcuoglu, K. ve Kuksa, P. (2011). Natural language processing (almost) from scratch. *Journal of Machine Learning Research*, 12(Aug), 2493–2537.

Cortes, C. ve Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273–297.

Coughlin, K. ve Goldman, C. (2008). Physical Impacts of Climate Change on the Western US Electricity System: A Scoping Study. *Lawrence Berkeley National Laboratory*, 29. <http://escholarship.org/uc/item/8rc6q28> adresinden erişildi.

Cristaldi, L., Leone, G., Ottoboni, R., Subbiah, S. ve Turrin, S. (2016). A comparative study on data-driven prognostic approaches using fleet knowledge. *2016 IEEE International Instrumentation and Measurement Technology Conference Proceedings* içinde (ss. 1–6). IEEE.

Dalenogare, L. S., Benitez, G. B., Ayala, N. F. ve Frank, A. G. (2018). The expected contribution of Industry 4.0 technologies for industrial performance. *International Journal of Production Economics*, 204, 383–394. doi:10.1016/j.ijpe.2018.08.019

De Santis, E., Rizzi, A. ve Sadeghian, A. (2018). A cluster-based dissimilarity learning approach for localized fault classification in Smart Grids. *Swarm and Evolutionary Computation*, 39, 267–278. doi:10.1016/j.swevo.2017.10.007

Deloitte. (2015). Industry 4.0. Challenges and solutions for the digital transformation and use of exponential technologies. *Deloitte*, 1–30.

Deng, L. (2014). A tutorial survey of architectures, algorithms, and applications for deep learning. *APSIPA Transactions on Signal and Information Processing*, 3. doi:10.1017/atsip.2013.9

Deng, L. ve Yu, D. (2014). Deep learning: methods and applications. *Foundations and Trends® in Signal Processing*, 7(3–4), 197–387.

Diez-Olivan, A., Del Ser, J., Galar, D. ve Sierra, B. (2019). Data fusion and machine learning for industrial prognosis: Trends and perspectives towards Industry 4.0. *Information Fusion*, 50, 92–111. doi:10.1016/j.inffus.2018.10.005

Diez-Olivan, A., Pagan, J. A., Sanz, R. ve Sierra, B. (2017). Data-driven prognostics using a combination of constrained K-means clustering, fuzzy modeling and LOF-based score. *Neurocomputing*, 241, 97–107.

Dimakopoulou, A. G., Pramataris, K. C. ve Tsekrekos, A. E. (2014). Applying real options to IT investment evaluation: The case of radio frequency identification (RFID) technology in the supply chain. *International Journal of Production Economics*, 156, 191–207. doi:10.1016/j.ijpe.2014.06.005

Đozić, D. J. ve Urošević, B. D. G. (2019). Application of artificial neural networks for testing long-term energy policy targets. *Energy*, 174, 488–496.

Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179–211.

doi:10.1016/0364-0213(90)90002-E

Erdenebayar, U., Kim, Y. J., Park, J. U., Joo, E. Y. ve Lee, K. J. (2019). Deep learning approaches for automatic detection of sleep apnea events from an electrocardiogram. *Computer Methods and Programs in Biomedicine*, 180, 105001. doi:10.1016/j.cmpb.2019.105001

Erol, S., Jäger, A., Hold, P., Ott, K. ve Sihn, W. (2016). Tangible Industry 4.0: A Scenario-Based Approach to Learning for the Future of Production. *Procedia CIRP*, 54, 13–18. doi:10.1016/j.procir.2016.03.162

Faheem, M., Shah, S. B. H., Butt, R. A., Raza, B., Anwar, M., Ashraf, M. W., ... Gungor, V. C. (2018). Smart grid communication and information technologies in the perspective of Industry 4.0: Opportunities and challenges. *Computer Science Review*, 30, 1–30. doi:10.1016/j.cosrev.2018.08.001

Farooq, M. U., Waseem, M., Mazhar, S., Khairi, A. ve Kamal, T. (2015). A review on internet of things (IoT). *International Journal of Computer Applications*, 113(1), 1–7.

Fatorachian, H. ve Kazemi, H. (2020). Impact of Industry 4.0 on supply chain performance. *Production Planning & Control*, 1–19.

Fischetti, M., Sartor, G. ve Zanette, A. (2015). MIP-and-refine matheuristic for smart grid energy management. *International Transactions in Operational Research*, 22(1), 49–59.

Foresight. (2013). The Future of Manufacturing: A new era of opportunity and challenge for the UK Summary Report The Government Office for Science, London. *Summary Report, The Government Office for Science, London*.

Froger, A., Gendreau, M., Mendoza, J. E., Pinson, É. ve Rousseau, L. M. (2016). Maintenance scheduling in the electricity industry: A literature review. *European*

Journal of Operational Research, 251(3), 695–706. doi:10.1016/j.ejor.2015.08.045

Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4), 193–202. doi:10.1007/BF00344251

Gao, L. ve Zhao, Y. (2011). Application on cloud computing in the future library. *2011 IEEE International Conference on Cloud Computing and Intelligence Systems* içinde (ss. 175–177). IEEE.

Gardner, M. W. ve Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, 32(14–15), 2627–2636.

Gerbert, P., Lorenz, M., Rubmann, M., Waldner, M., Justus, J., Engel, P. ve Harnisch, M. (2015). Industry 4.0: The future of productivity and growth in manufacturing industries. *BCG perspective*, 1–20. doi:10.1007/978-981-13-3384-2_13

Gerlak, A. K., Weston, J., McMahan, B., Murray, R. L. ve Mills-Novoa, M. (2018). Climate risk management and the electricity sector. *Climate Risk Management*, 19, 12–22. doi:10.1016/j.crm.2017.12.003

Gharehgozli, A. H., Tavakkoli-Moghaddam, R. ve Zaerpour, N. (2009). A fuzzy-mixed-integer goal programming model for a parallel-machine scheduling problem with sequence-dependent setup times and release dates. *Robotics and Computer-Integrated Manufacturing*, 25(4–5), 853–859.

Ghoseiri, K. ve Ghannadpour, S. F. (2010). Multi-objective vehicle routing problem with time windows using goal programming and genetic algorithm. *Applied Soft Computing*, 10(4), 1096–1107.

Giannetti, C. ve Ransing, R. S. (2016). Risk based uncertainty quantification to

improve robustness of manufacturing operations. *Computers and Industrial Engineering*, 101, 70–80. doi:10.1016/j.cie.2016.08.002

Gilchrist, A. (2016). *Industry 4.0: the industrial internet of things*. Apress.

Giri, P. K., Maiti, M. K. ve Maiti, M. (2014). Fuzzy stochastic solid transportation problem using fuzzy goal programming approach. *Computers & Industrial Engineering*, 72, 160–168.

Gobbo, J. A., Busso, C. M., Gobbo, S. C. O. ve Carreão, H. (2018). Making the links among environmental protection, process safety, and industry 4.0. *Process Safety and Environmental Protection*, 117, 372–382. doi:10.1016/j.psep.2018.05.017

Gölzer, P., Cato, P. ve Amberg, M. (2015). Data Processing Requirements of Industry 4.0-Use Cases for Big Data Applications. *ECIS içinde* .

Gonen, T. (2011). *Electrical power transmission system engineering: Analysis and design*. CRC press.

Goodfellow, I., Bengio, Y. ve Courville, A. (2016). *Deep learning*. MIT press.

Güler, M. G. (2013). A hierarchical goal programming model for scheduling the outpatient clinics. *Expert systems with applications*, 40(12), 4906–4914.

Guo, L., Li, N., Jia, F., Lei, Y. ve Lin, J. (2017). A recurrent neural network based health indicator for remaining useful life prediction of bearings. *Neurocomputing*, 240, 98–109.

Guo, Y., Tan, Z., Chen, H., Li, G., Wang, J., Huang, R., ... Ahmad, T. (2018). Deep learning-based fault diagnosis of variable refrigerant flow air-conditioning system for building energy saving. *Applied Energy*, 225, 732–745. doi:10.1016/j.apenergy.2018.05.075

Hatcher, W. G. ve Yu, W. (2018). A Survey of Deep Learning: Platforms, Applications and Emerging Research Trends. *IEEE Access*, 6, 24411–24432. doi:10.1109/ACCESS.2018.2830661

He, M. ve Zhang, J. (2011). A dependency graph approach for fault detection and localization towards secure smart grid. *IEEE Transactions on Smart Grid*, 2(2), 342–351. doi:10.1109/TSG.2011.2129544

Hecht-Nielsen, R. (1990). *Neurocomputing*, Addison. *Wesely Publishing Company*. Hornik, K. Stinchcombe, M. White, H. (1989). *Multilayer feedforward networks are universal approximators*, *Neural Networks*, 2(359366), 3168–3176.

Hecklau, F., Galeitzke, M., Flachs, S. ve Kohl, H. (2016). Holistic Approach for Human Resource Management in Industry 4.0. *Procedia CIRP*, 54, 1–6. doi:10.1016/j.procir.2016.05.102

Helbing, G. ve Ritter, M. (2018). Deep Learning for fault detection in wind turbines. *Renewable and Sustainable Energy Reviews*, 98, 189–198. doi:10.1016/j.rser.2018.09.012

Hermann, M., Pentek, T. ve Otto, B. (2016). Design principles for industrie 4.0 scenarios. *Proceedings of the Annual Hawaii International Conference on System Sciences* içinde (C. 2016-March, ss. 3928–3937). IEEE. doi:10.1109/HICSS.2016.488

Hines, P., Apt, J. ve Talukdar, S. (2008). Trends in the history of large blackouts in the United States. *IEEE Power and Energy Society 2008 General Meeting: Conversion and Delivery of Electrical Energy in the 21st Century*, PES içinde (ss. 1–8). IEEE. doi:10.1109/PES.2008.4596715

Hines, P., Apt, J. ve Talukdar, S. (2009). Large blackouts in North America: Historical trends and policy implications. *Energy Policy*, 37(12), 5249–5259. doi:10.1016/j.enpol.2009.07.049

Hinton, G. E. ve Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504–507. doi:10.1126/science.1127647

Hinton, Geoffrey E. (2005). What kind of a graphical model is the brain? *IJCAI International Joint Conference on Artificial Intelligence* içinde (C. 5, ss. 1765–1775).

Hinton, Geoffrey E. (2007). Learning multiple layers of representation. *Trends in Cognitive Sciences*, 11(10), 428–434. doi:10.1016/j.tics.2007.09.004

Hinton, Geoffrey E., Srivastava, N., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*. <http://arxiv.org/abs/1207.0580> adresinden erişildi.

Hocine, A., Zhuang, Z.-Y., Kouaissah, N. ve Li, D.-C. (2020). Weighted-additive fuzzy multi-choice goal programming (WA-FMCGP) for supporting renewable energy site selection decisions. *European Journal of Operational Research*.

Hu, W., Huang, Y., Wei, L., Zhang, F. ve Li, H. (2015). Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*, 2015.

Huang, F. J. ve LeCun, Y. (2006). Large-scale learning with SVM and convolutional nets for generic object categorization. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* içinde (C. 1, ss. 284–291). doi:10.1109/CVPR.2006.164

Huang, G. Q., Zhong, R. Y. ve Tsui, K. L. (2015). Special issue on “big data for service and manufacturing supply chain management”. *International Journal of Production Economics*, 165, 172–173. doi:10.1016/j.ijpe.2015.05.009

Ibrahim, M. S., Dong, W. ve Yang, Q. (2020). Machine learning driven smart electric power systems: Current trends and new perspectives. *Applied Energy*, 272, 115237.

Ignizio, J. P. (1978). A review of goal programming: A tool for multiobjective analysis. *Journal of the Operational Research Society*, 29(11), 1109–1119.

Ignizio, J. P. (1983). Generalized goal programming an overview. *Computers & Operations Research*, 10(4), 277–289.

Ignizio, J. P. (1985). An algorithm for solving the linear goal programming problem by solving its dual. *Journal of the Operational Research Society*, 36(6), 507–515.

Ivakhnenko, A. G. ve Lapa, V. G. (1965). *Cybernetic predicting devices*. CCM Information Corporation. PURDUE UNIV LAFAYETTE IND SCHOOL OF ELECTRICAL ENGINEERING.

Ivanov, D., Dolgui, A., Sokolov, B., Werner, F. ve Ivanova, M. (2016). A dynamic model and an algorithm for short-term supply chain scheduling in the smart factory industry 4.0. *International Journal of Production Research*, 54(2), 386–402. doi:10.1080/00207543.2014.999958

Jagers, J., Khosa, J., Klerk, P. De ve Gaunt, C. (2007). Transformer reliability and condition assessment in a South African utility. *International Symposium on ... içinde* (ss. 1–6). <http://web.uct.ac.za/staff/gaunt/ISH2007t6-442.pdf> adresinden erişildi.

Jana, R. K., Sharma, D. K. ve Chakraborty, B. (2016). A hybrid probabilistic fuzzy goal programming approach for agricultural decision-making. *International Journal of Production Economics*, 173, 134–141.

Javid, N., Khalili-Damghani, K., Makui, A. ve Abdi, F. (2020). Multi-objective flexibility-complexity trade-off problem in batch production systems using fuzzy goal programming. *Expert Systems with Applications*, 148, 113266.

Jia, R., Liu, Y. ve Bai, X. (2020). Sustainable supplier selection and order allocation: Distributionally robust goal programming model and tractable approximation. *Computers & Industrial Engineering*, 140, 106267.

Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., ... Darrell, T. (2014). Caffe: Convolutional architecture for fast feature embedding. *MM 2014 - Proceedings of the 2014 ACM Conference on Multimedia* içinde (ss. 675–678). ACM. doi:10.1145/2647868.2654889

Jongen, R., Galski, E., Morshuis, P., Smit, J. ve Janssen, A. (2007). Statistical analysis of power transformer component life time data. *8th International Power Engineering Conference, IPEC 2007* içinde (ss. 1273–1277). IEEE.

Kagermann, H., Wahlster, W. ve Helbig, J. (2013). Recommendations for implementing the strategic initiative Industrie 4.0: Final report of the Industrie 4.0 Working Group. *Acatech, München*, 19–26.

Kamble, S. S., Gunasekaran, A. ve Gawankar, S. A. (2018). Sustainable Industry 4.0 framework: A systematic literature review identifying the current trends and future perspectives. *Process Safety and Environmental Protection*, 117, 408–425. doi:10.1016/j.psep.2018.05.009

Kamble, S. S., Gunasekaran, A. ve Sharma, R. (2018). Analysis of the driving and dependence power of barriers to adopt industry 4.0 in Indian manufacturing industry. *Computers in Industry*, 101, 107–119. doi:10.1016/j.compind.2018.06.004

Kaymakamlığı, Ç. (2020). Çeşme İlçesi' nin Tarihi ve Coğrafi Yapısı. 13 Ekim 2020 tarihinde <http://www.cesme.gov.tr/tarihi-ve-cograf-yapisi> adresinden erişildi.

Kees, A., Oberländer, A., Röglinger, M. ve Rosemann, M. (2015). Understanding the internet of things: A conceptualisation of business-to-thing (B2T) interactions. *23rd European Conference on Information Systems, ECIS 2015* içinde (C. 2015-May).

Khan, N., Yaqoob, I., Hashem, I. A. T., Inayat, Z., Ali, M., Kamaleldin, W., ... Gani, A. (2014). Big data: survey, technologies, opportunities, and challenges. *The scientific world journal*, 2014.

Khwaja, A. S., Anpalagan, A., Naeem, M. ve Venkatesh, B. (2020). Joint bagged-boosted artificial neural networks: Using ensemble machine learning to improve short-term electricity load forecasting. *Electric Power Systems Research*, 179, 106080. doi:10.1016/j.epsr.2019.106080

Kim, A., Yang, Y., Lessmann, S., Ma, T., Sung, M. C. ve Johnson, J. E. V. (2020). Can deep learning predict risky retail investors? A case study in financial risk behavior forecasting. *European Journal of Operational Research*, 283(1), 217–234. doi:10.1016/j.ejor.2019.11.007

Kim, J. ve Kim, Y. (2016). Benefits of cloud computing adoption for smart grid security from security perspective. *The Journal of Supercomputing*, 72(9), 3522–3534.

Kiraz, A., Canpolat, O., Özkurt, C. ve Taşkın, H. (2020). Analysis of the factors affecting the Industry 4.0 tendency with the structural equation model and an application. *Computers & Industrial Engineering*, 150, 106911.

Klievink, B., Romijn, B.-J., Cunningham, S. ve de Bruijn, H. (2017). Big data in the public sector: Uncertainties and readiness. *Information systems frontiers*, 19(2), 267–283.

Kolberg, D. ve Zühlke, D. (2015). Lean Automation enabled by Industry 4.0 Technologies. *IFAC-PapersOnLine*, 28(3), 1870–1875. doi:10.1016/j.ifacol.2015.06.359

Konstantakopoulos, I. C., Barkan, A. R., He, S., Veeravalli, T., Liu, H. ve Spanos, C. (2019). A deep learning and gamification approach to improving human-building interaction and energy efficiency in smart infrastructure. *Applied Energy*, 237, 810–821. doi:10.1016/j.apenergy.2018.12.065

Kraus, M., Feuerriegel, S. ve Oztekin, A. (2020). Deep learning in business analytics and operations research: Models, applications and managerial implications. *European Journal of Operational Research*, 281(3), 628–641. doi:10.1016/j.ejor.2019.09.018

Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems* içinde (ss. 1097–1105).

Kruse, R., Borgelt, C., Braune, C., Mostaghim, S. ve Steinbrecher, M. (2016). Multilayer perceptrons. *Computational Intelligence* içinde (ss. 47–92). Springer.

Kumar, K. R. ve Kalavathi, M. S. (2018). Artificial intelligence based forecast models for predicting solar power generation. *Materials Today: Proceedings*, 5(1), 796–802. doi:10.1016/j.matpr.2017.11.149

Larsen, P. H., Boehlert, B., Eto, J., Hamachi-LaCommare, K., Martinich, J. ve Rennels, L. (2018). Projecting future costs to U.S. electric utility customers from power interruptions. *Energy*, 147, 1256–1277. doi:10.1016/j.energy.2017.12.081

Lasi, H., Fettke, P., Kemper, H.-G., Feld, T. ve Hoffmann, M. (2014). Industry 4.0. *Business & Information Systems Engineering*, 6(4), 239.

Lawan, S. M., Abidin, W. A. W. Z. ve Masri, T. (2019). Implementation of a topographic artificial neural network wind speed prediction model for assessing onshore wind power potential in Sibuloh, Sarawak. *Egyptian Journal of Remote Sensing and Space Science*. doi:10.1016/j.ejrs.2019.08.003

Le Cun, Y. Le, Guyon, I., Jackel, L. D., Henderson, D., Boser, B., Howard, R. E., ... Graf, H. P. (1989). Handwritten Digit Recognition: Applications of Neural Network Chips and Automatic Learning. *IEEE Communications Magazine*, 27(11), 41–46. doi:10.1109/35.41400

LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. ve Jackel, L. D. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541–551. doi:10.1162/neco.1989.1.4.541

LeCun, Yann, Bengio, Y. ve Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436–444.

Lee, C.-S., Wang, M.-H., Yen, S.-J., Wei, T.-H., Wu, I.-C., Chou, P.-C., ... Yan, T.-H. (2016). Human vs. computer go: Review and prospect [discussion forum]. *IEEE Computational intelligence magazine*, 11(3), 67–72.

Lee, H., Grosse, R., Ranganath, R. ve Ng, A. Y. (2009). Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations. *Proceedings of the 26th annual international conference on machine learning* içinde (ss. 609–616).

Lee, J., Davari, H., Singh, J. ve Pandhare, V. (2018). Industrial Artificial Intelligence for industry 4.0-based manufacturing systems. *Manufacturing Letters*, 18, 20–23. doi:10.1016/j.mfglet.2018.09.002

Leung, S. C. H. ve Chan, S. S. W. (2009). A goal programming model for aggregate production planning with resource utilization constraint. *Computers & Industrial Engineering*, 56(3), 1053–1064.

Li, D., Tan, J., Yu, Q. ve Li, Z. (2021). Deep-learning-assisted power loss management for active distribution networks. *The Electricity Journal*, 34(1), 106888.

Li, P., Zhou, K., Lu, X. ve Yang, S. (2020). A hybrid deep learning model for short-term PV power forecasting. *Applied Energy*, 259, 114216. doi:10.1016/j.apenergy.2019.114216

Li, X., Li, D., Wan, J., Vasilakos, A. V, Lai, C.-F. ve Wang, S. (2017). A review of industrial wireless networks in the context of Industry 4.0. *Wireless networks*, 23(1), 23–41.

Lim, C., Kim, K. H., Kim, M. J., Heo, J. Y., Kim, K. J. ve Maglio, P. P. (2018). From data to value: A nine-factor framework for data-based value creation in information-intensive services. *International Journal of Information Management*, 39, 121–135. doi:10.1016/j.ijinfomgt.2017.12.007

Liou, C. Y., Cheng, W. C., Liou, J. W. ve Liou, D. R. (2014). Autoencoder for words. *Neurocomputing*, 139, 84–96. doi:10.1016/j.neucom.2013.09.055

Lipton, Z. C., Berkowitz, J. ve Elkan, C. (2015). A Critical Review of Recurrent Neural Networks for Sequence Learning. *arXiv preprint arXiv:1506.00019*. <http://arxiv.org/abs/1506.00019> adresinden erişildi.

Loskyll, M., Heck, I., Schlick, J. ve Schwarz, M. (2012). Context-Based Orchestration for Control of Resource-Efficient Manufacturing Processes. *Future Internet*, 4(3), 737–761. doi:10.3390/fi4030737

Lu, Y. (2017). Industry 4.0: A survey on technologies, applications and open research issues. *Journal of Industrial Information Integration*, 6, 1–10. doi:10.1016/j.jii.2017.04.005

Lu, Y., Sun, L., Zhang, X., Feng, F., Kang, J. ve Fu, G. (2018). Condition based maintenance optimization for offshore wind turbine considering opportunities based on neural network approach. *Applied Ocean Research*, 74, 69–79.

Martins, M. A. (2014). Condition and risk assessment of power transformers: A general approach to calculate a Health Index. *Ciencia e Tecnologia dos Materiais*, 26(1), 9–16. doi:10.1016/j.ctmat.2014.09.002

Marugán, A. P., Márquez, F. P. G., Perez, J. M. P. ve Ruiz-Hernández, D. (2018). A survey of artificial neural network in wind energy systems. *Applied energy*, 228, 1822–1836.

Mayr, A., Weigelt, M., Masuch, M., Meiners, M., Hüttel, F. ve Franke, J. (2018). Application Scenarios of Artificial Intelligence in Electric Drives Production. *Procedia Manufacturing*, 24, 40–47. doi:10.1016/j.promfg.2018.06.006

McCulloch, W. S. ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115–133.

McElroy, A. J. (1975). On the significance of recent EHV transformer failures involving winding resonance. *IEEE Transactions on Power Apparatus and Systems*, 94(4), 1301–1316. doi:10.1109/T-PAS.1975.31968

Mekki, H., Mellit, A. ve Salhi, H. (2016). Artificial neural network-based modelling and fault detection of partial shaded photovoltaic modules. *Simulation Modelling Practice and Theory*, 67, 1–13. doi:10.1016/j.simpat.2016.05.005

Metwally, I. A. (2011). Failures, monitoring and new trends of power transformers. *IEEE Potentials*, 30(3), 36–43. doi:10.1109/MPOT.2011.940233

Mikolov, T., Karafiát, M., Burget, L., Jan, C. ve Khudanpur, S. (2010). Recurrent neural network based language model. *Proceedings of the 11th Annual Conference of the International Speech Communication Association, INTERSPEECH 2010* içinde (ss. 1045–1048).

Mills, E. (2012). Electric Grid Disruptions and Extreme Weather. *US Disaster Reanalysis Workshop National Climatic Data Center, 2012.*

Min, S., Lee, B. ve Yoon, S. (2017). Deep learning in bioinformatics. *Briefings in bioinformatics, 18*(5), 851–869.

Minerva, R., Biru, A. ve Rotondi, D. (2015). Towards a definition of the Internet of Things (IoT). *IEEE Internet Initiative, 1*(1), 1–86.

Minhas, M. S. A., Reynders, J. P. ve de Klerk, P. J. (1999). Failures in power system transformers and appropriate monitoring techniques. *IEE Conference Publication* içinde (C. 1, ss. 94–97). IET. doi:10.1049/cp:19990516

Moghaddam, K. S. (2013). Multi-objective preventive maintenance and replacement scheduling in a manufacturing system using goal programming. *International Journal of Production Economics, 146*(2), 704–716.

Mohamed, E. A. ve Rao, N. D. (1995). Artificial neural network based fault diagnostic system for electric power distribution feeders. *Electric Power Systems Research, 35*(1), 1–10.

Mokhtari, H. ve Hasani, A. (2017). A multi-objective model for cleaner production-transportation planning in manufacturing plants via fuzzy goal programming. *Journal of Manufacturing Systems, 44*, 230–242.

Moktadir, M. A., Ali, S. M., Kusi-Sarpong, S. ve Shaikh, M. A. A. (2018). Assessing challenges for implementing Industry 4.0: Implications for process safety and environmental protection. *Process Safety and Environmental Protection, 117*, 730–741. doi:10.1016/j.psep.2018.04.020

Mosallam, A., Medjaher, K. ve Zerhouni, N. (2016). Data-driven prognostic method based on Bayesian approaches for direct remaining useful life prediction. *Journal of Intelligent Manufacturing*, 27(5), 1037–1048.

Mosterman, P. J. ve Zander, J. (2016). Industry 4.0 as a cyber-physical system study. *Software & Systems Modeling*, 15(1), 17–29.

Mousavian, S., Valenzuela, J. ve Wang, J. (2013). Real-time data reassurance in electrical power systems based on artificial neural networks. *Electric Power Systems Research*, 96, 285–295.

Mrugalska, B. ve Wyrwicka, M. K. (2017). Towards Lean Production in Industry 4.0. *Procedia Engineering*, 182, 466–473. doi:10.1016/j.proeng.2017.03.135

Muhammed, T. ve Shaikh, R. A. (2017). An analysis of fault detection strategies in wireless sensor networks. *Journal of Network and Computer Applications*, 78, 267–287. doi:10.1016/j.jnca.2016.10.019

Mumtaz, W. ve Qayyum, A. (2019). A deep learning framework for automatic diagnosis of unipolar depression. *International Journal of Medical Informatics*, 132, 103983. doi:10.1016/j.ijmedinf.2019.103983

Murugan, R. ve Ramasamy, R. (2015). Failure analysis of power transformer for effective maintenance planning in electric utilities. *Engineering Failure Analysis*, 55, 182–192. doi:10.1016/j.engfailanal.2015.06.002

Musilek, P., Arnold, D. ve Lozowski, E. P. (2009). An ice accretion forecasting system (IAFS) for powertransmission lines using numerical weather prediction. *Scientific Online Letters on the Atmosphere*, 5, 25–28. doi:10.2151/sola.2009-007

Napolitano, F., Tossani, F., Borghetti, A., Nucci, C. A., Martinez, M. L. B., Lopes, G. P., ... Fagundes, D. R. (2016). Lightning performance of a real distribution network with focus on transformer protection. *Electric Power Systems Research*, 139, 60–67. doi:10.1016/j.epsr.2015.11.019

Nawaz, K., Petrov, I. ve Buchmann, A. P. (2014). Configurable, energy-efficient, application-and channel-aware middleware approaches for cyber-physical systems. *Computational Intelligence for Decision Support in Cyber-Physical Systems* içinde (ss. 3–65). Springer.

Ng, A. (2015). *What data scientists should know about deep learning*. https://www.slideshare.net/ExtractConf/andrew-ng-chief-scientist-at-baidu?qid=5b682b9d-510e-4d31-b5ea-36e7b153a413&v=&b=&from_search=1 adresinden erişildi.

Nwobi-Okoye, C. C. (2018). Transfer function based performance assessment of power distribution facilities: A case study of distribution transformers. *Journal of Electrical Systems and Information Technology*, 5(3), 977–993. doi:10.1016/j.jesit.2016.12.001

Ortmeyer, T. H. (2017). *Electric power distribution. Smart Grid: Networking, Data Management, and Business Models*. Tata McGraw-Hill Education. doi:10.1201/b19664

Öztürk, A. (2012). *Yöneylem Araştırması* (14. Baskı.). Ekin Basım Yayın.

Pabla, A. S. (2012). *Electric power distribution*. Tata McGraw-Hill Education.

Pang, Q. H. ve Wu, X. Y. (2014). Optimization scheduling model of double line Shiplock based on nonlinear goal programming. *Journal of applied research and technology*, 12(2), 192–200.

Paszke, A., Gross, S., Chintala, S., Chanan, G., Yang, E., Facebook, Z. D., ... Lerer, A. (2019). Automatic differentiation in PyTorch. *Advances in Neural Information Processing Systems* 32, 8024–8035. <http://papers.neurips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep-learning-library.pdf> adresinden erişildi.

Patterson, J. ve Gibson, A. (2017). *Deep learning: A practitioner's approach*. “O'Reilly Media, Inc.”

Pereira, T., Barreto, L. ve Amaral, A. (2017). Network and information security challenges within Industry 4.0 paradigm. *Procedia Manufacturing*, 13, 1253–1260. doi:10.1016/j.promfg.2017.09.047

Pisching, M. A., Junqueira, F., Filho, D. J. S. ve Miyagi, P. E. (2015). Service composition in the cloud-based manufacturing focused on the industry 4.0. L. M. Camarinha-Matos, T. A. Baldissera, G. Di Orio ve F. Marques (Ed.), *IFIP Advances in Information and Communication Technology* içinde (C. 450, ss. 65–72). Cham: Springer International Publishing. doi:10.1007/978-3-319-16766-4_7

Preuveneers, D. ve Ilie-Zudor, E. (2017). The intelligent industry of the future: A survey on emerging trends, research challenges and opportunities in Industry 4.0. *Journal of Ambient Intelligence and Smart Environments*, 9(3), 287–298.

Qu, Y., He, D., Yoon, J., Van Hecke, B., Bechhoefer, E. ve Zhu, J. (2014). Gearbox tooth cut fault diagnostics using acoustic emission and vibration sensors—A comparative study. *Sensors*, 14(1), 1372–1393.

Rafael, L. D., Jaione, G. E., Cristina, L. ve Ibon, S. L. (2020). An Industry 4.0 maturity model for machine tool companies. *Technological Forecasting and Social Change*, 159, 120203.

Rahman, N. A., Masood, I. ve Rahman, M. N. A. (2016). Recognition of unnatural variation patterns in metal-stamping process using artificial neural network and statistical features. *IOP Conf. Series: Materials Sci. and Eng.* içinde (C. 160, ss. 1–7).

Rani, S., Talwar, R., Malhotra, J., Ahmed, S. H., Sarkar, M. ve Song, H. (2015). A novel scheme for an energy efficient Internet of Things based on wireless sensor networks. *Sensors*, 15(11), 28603–28626.

Ranzato, M. A., Poultney, C., Chopra, S. ve LeCun, Y. (2007). Efficient learning of sparse representations with an energy-based model. *Advances in Neural Information Processing Systems* içinde (ss. 1137–1144). doi:10.7551/mitpress/7503.003.0147

Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B. ve Yang, G. Z. (2017). Deep Learning for Health Informatics. *IEEE Journal of Biomedical and Health Informatics*, 21(1), 4–21. doi:10.1109/JBHI.2016.2636665

Reed, D. A. (2008). Electric utility distribution analysis for extreme winds. *Journal of Wind Engineering and Industrial Aerodynamics*, 96(1), 123–140. doi:10.1016/j.jweia.2007.04.002

Rexhepi, V. (2017). An Analysis of Power Transformer Outages and Reliability Monitoring. *Energy Procedia*, 141, 418–422. doi:10.1016/j.egypro.2017.11.053

Rivera, J. ve Van der Muelen, R. (2013). Gartner Says the Internet of Things Installed Base Will Grow to 26 Billion Units By 2020. *Gartner*. <http://www.gartner.com/newsroom/id/2636073> adresinden erişildi.

Roncero-Clemente, C. ve Roanes-Lozano, E. (2018). A multi-criteria computer package for power transformer fault detection and diagnosis. *Applied Mathematics and Computation*, 319, 153–164. doi:10.1016/j.amc.2017.02.024

Rosemann, M. (2013). The Internet of Things: new digital capital in the hands of customers. *Business Transformation Journal*, 2013(9), 6–15. <http://eprints.qut.edu.au/66451/> adresinden erişildi.

Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. doi:10.1037/h0042519

Rüßmann, M., Lorenz, M., Gerbert, P., Waldner, M., Justus, J., Engel, P. ve Harnisch, M. (2015). Industry 4.0: The future of productivity and growth in manufacturing industries. *Boston Consulting Group*, 9(1), 54–89.

Safizadeh, M. S. ve Latifi, S. K. (2014). Using multi-sensor data fusion for vibration fault diagnosis of rolling element bearings by accelerometer and load cell. *Information Fusion*, 18, 1–8.

Sainath, T. N., Mohamed, A. R., Kingsbury, B. ve Ramabhadran, B. (2013). Deep convolutional neural networks for LVCSR. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings* içinde (ss. 8614–8618). IEEE. doi:10.1109/ICASSP.2013.6639347

San Cristóbal, J. R. (2012). A goal programming model for the optimal mix and location of renewable energy plants in the north of Spain. *Renewable and Sustainable Energy Reviews*, 16(7), 4461–4464.

Saviozzi, M., Massucco, S. ve Silvestro, F. (2019). Implementation of advanced functionalities for Distribution Management Systems: Load forecasting and modeling through Artificial Neural Networks ensembles. *Electric Power Systems Research*, 167, 230–239. doi:10.1016/j.epsr.2018.10.036

Sayar, M. ve Güneş, M. (2015). Akıllı İş Süreç Yönetimi (iBPM) ve Sağlık Sektöründe Bir Uygulama'. *15th Production Research Symposium, Izmir, 14-16 October, 2015, Proceedings* içinde (ss. 561–570).

Sayar, M. ve Yüksel, H. (2020). Real-Time Prediction of Electricity Distribution Network Status Using Artificial Neural Network Model: A Case Study in Salihli (Manisa, Turkey). *Celal Bayar University Journal of Science*, 16(3), 307–321.

Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural Networks*, 61, 85–117. doi:10.1016/j.neunet.2014.09.003

Schmidhuber, J. ve Hochreiter, S. (1997). Long short-term memory. *Neural Comput*, 9(8), 1735–1780.

Schmidt, R., Möhring, M., Härting, R. C., Reichstein, C., Neumaier, P. ve Jozinović, P. (2015). Industry 4.0 - Potentials for creating smart products: Empirical research results. W. Abramowicz (Ed.), *Lecture Notes in Business Information Processing* içinde (C. 208, ss. 16–27). Cham: Springer International Publishing. doi:10.1007/978-3-319-19027-3_2

Seidgar, H., Zandieh, M. ve Mahdavi, I. (2017). An efficient meta-heuristic algorithm for scheduling a two-stage assembly flow shop problem with preventive maintenance activities and reliability approach. *International Journal of Industrial and Systems Engineering*, 26(1), 16–41.

Şeker, A., Diri, B. ve Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3(3), 47–64.

Shaban, S. E., Hazzaa, M. H. ve El-Tayebany, R. A. (2019). Applying Monte Carlo and artificial intelligence techniques for ²³⁵U mass prediction in samples with different enrichments. *Nuclear Instruments and Methods in Physics Research, Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 916, 322–326. doi:10.1016/j.nima.2018.10.008

Shafiq, S. I., Sanin, C., Szczerbicki, E. ve Toro, C. (2016). Virtual engineering factory: Creating experience base for industry 4.0. *Cybernetics and Systems*, 47(1–2), 32–47.

Shahbaz, M., Masood, S. A., Shaheen, M. ve Khan, A. (2010). Data mining methodology in perspective of manufacturing databases. *J Am Sci*.

Shakshuki, E. M., Malik, H. ve Sheltami, T. (2014). WSN in cyber physical systems: Enhanced energy management routing approach using software agents. *Future Generation Computer Systems*, 31, 93–104.

Shao, X.-F., Liu, W., Li, Y., Chaudhry, H. R. ve Yue, X.-G. (2020). Multistage implementation framework for smart supply chain management under industry 4.0. *Technological Forecasting and Social Change*, 162, 120354.

Shen, S., Sadoughi, M., Chen, X., Hong, M. ve Hu, C. (2019). A deep learning method for online capacity estimation of lithium-ion batteries. *Journal of Energy Storage*, 25, 100817. doi:10.1016/j.est.2019.100817

Silva, S., Costa, P., Gouvea, M., Lacerda, A., Alves, F. ve Leite, D. (2018). High impedance fault detection in power distribution systems using wavelet transform and evolving neural network. *Electric Power Systems Research*, 154, 474–483.

Slomp, J. ve Klingenberg, W. (2004). A proposal to use artificial neural networks for process control of punching/blanking operations. *Flexible Automation and Intelligent Manufacturing. FAIM2004, Toronto, Canada*.

Smolensky, P. (1986). *Information processing in dynamical systems: Foundations of harmony theory BT - Parallel Distributed Processing: Volume 1: Foundations. Parallel Distributed Processing: Volume 1: Foundations*. Colorado Univ at Boulder Dept of Computer Science. papers2://publication/uuid/71B954A2-8DB5-4D8F-9390-E56B11DE293D adresinden erişildi.

Sridhar, S., Hahn, A. ve Govindarasu, M. (2011). Cyber-physical system security for the electric power grid. *Proceedings of the IEEE*, 100(1), 210–224.

Stock, T. ve Seliger, G. (2016). Opportunities of Sustainable Manufacturing in Industry 4.0. *Procedia CIRP*, 40, 536–541. doi:10.1016/j.procir.2016.01.129

Strange, R. ve Zucchella, A. (2017). Industry 4.0, global value chains and international business. *Multinational Business Review*.

Sun, C.-C., Hahn, A. ve Liu, C.-C. (2018). Cyber security of a power grid: State-of-the-art. *International Journal of Electrical Power & Energy Systems*, 99, 45–56.

Sun, W. ve Xu, Y. (2016). Financial security evaluation of the electric power industry in China based on a back propagation neural network optimized by genetic algorithm. *Energy*, 101, 366–379.

Sung, T. K. (2018). Industry 4.0: A Korea perspective. *Technological Forecasting and Social Change*, 132, 40–45. doi:10.1016/j.techfore.2017.11.005

Suwanasri, T., Chaidee, E. ve Adsoongnoen, C. (2008). Failure statistics and power transformer condition evaluation by dissolved gas analysis technique. *Proceedings of 2008 International Conference on Condition Monitoring and Diagnosis, CMD 2008* içinde (ss. 492–496). IEEE. doi:10.1109/CMD.2008.4580333

Süzen, A. ve Kayaalp, K. (2018). *Derin Öğrenme ve Türkiye’deki Uygulamaları*.

Tjahjono, B., Esplugues, C., Ares, E. ve Pelaez, G. (2017). What does Industry 4.0 mean to Supply Chain? *Procedia Manufacturing*, 13, 1175–1182. doi:10.1016/j.promfg.2017.09.191

Torres-Ruiz, A. ve Ravindran, A. R. (2019). Use of interval data envelopment analysis, goal programming and dynamic eco-efficiency assessment for sustainable supplier management. *Computers & Industrial Engineering*, 131, 211–226.

Trappey, A. J. C., Trappey, C. V., Hareesh Govindarajan, U., Chuang, A. C. ve Sun, J. J. (2017). A review of essential standards and patent landscapes for the Internet of Things: A key enabler for Industry 4.0. *Advanced Engineering Informatics*, 33, 208–229. doi:10.1016/j.aei.2016.11.007

Trappey, A. J. C., Trappey, C. V., Ma, L. ve Chang, J. C. M. (2015). Intelligent engineering asset management system for power transformer maintenance decision supports under various operating conditions. *Computers and Industrial Engineering*, 84, 3–11. doi:10.1016/j.cie.2014.12.033

Trocconi, A., Dubus, L. ve Haupt, S. E. (2014). *Weather matters for energy. Choice Reviews Online* (C. 52). Springer. doi:10.5860/choice.52-0863

Trstenjak, M. ve Cosic, P. (2017). Process Planning in Industry 4.0 Environment. *Procedia Manufacturing*, 11, 1744–1750. doi:10.1016/j.promfg.2017.07.303

Türkoğlu, S. P. (2017). Karar vermede hedef programlama yöntemi ve uygulamaları. *Osmaniye Korkut Ata Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 1(2), 29–46.

Tvenge, N. ve Martinsen, K. (2018). Integration of digital learning in industry 4.0. *Procedia Manufacturing*, 23, 261–266. doi:10.1016/j.promfg.2018.04.027

Vaidya, S., Ambad, P. ve Bhosle, S. (2018). Industry 4.0–a glimpse. *Procedia Manufacturing*, 20, 233–238.

Velilla, E., Valencia, J. ve Jaramillo, F. (2014). Performance evaluation of two solar photovoltaic technologies under atmospheric exposure using artificial neural network models. *Solar Energy*, 107, 260–271. doi:10.1016/j.solener.2014.04.033

Waibel, M. W., Steenkamp, L. P., Moloko, N. ve Oosthuizen, G. A. (2017). Investigating the effects of smart production systems on sustainability elements. *Procedia Manufacturing*, 8, 731–737.

Wallach, I., Dzamba, M. ve Heifets, A. (2015). AtomNet: A Deep Convolutional Neural Network for Bioactivity Prediction in Structure-based Drug Discovery. *arXiv preprint arXiv:1510.02855*. <http://arxiv.org/abs/1510.02855> adresinden erişildi.

Wang, H., Lei, Z., Zhang, X., Zhou, B. ve Peng, J. (2019). A review of deep learning for renewable energy forecasting. *Energy Conversion and Management*, 198, 111799. doi:10.1016/j.enconman.2019.111799

Wang, H. Z., Wang, G. B., Li, G. Q., Peng, J. C. ve Liu, Y. T. (2016). Deep belief network based deterministic and probabilistic wind speed forecasting approach. *Applied Energy*, 182, 80–93. doi:10.1016/j.apenergy.2016.08.108

Wang, J., Zhao, X., Guo, X. ve Li, B. (2018). Analyzing the research subjects and hot topics of power system reliability through the Web of Science from 1991 to 2015. *Renewable and Sustainable Energy Reviews*, 82, 700–713. doi:10.1016/j.rser.2017.09.064

Wang, Q. ve Guo, G. (2019). Benchmarking deep learning techniques for face recognition. *Journal of Visual Communication and Image Representation*, 65, 102663. doi:10.1016/j.jvcir.2019.102663

Wang, S., Wan, J., Zhang, D., Li, D. ve Zhang, C. (2016). Towards smart factory for industry 4.0: A self-organized multi-agent system with big data based feedback and coordination. *Computer Networks*, 101, 158–168. doi:10.1016/j.comnet.2015.12.017

Wang, Z., Wang, Y. ve Srinivasan, R. S. (2018). A novel ensemble learning approach to support building energy use prediction. *Energy and Buildings*, 159, 109–122. doi:10.1016/j.enbuild.2017.10.085

Ward, D. M. (2013). The effect of weather on grid systems and the reliability of electricity supply. *Climatic Change*, 121(1), 103–113. doi:10.1007/s10584-013-0916-z

Wauters, M. ve Vanhoucke, M. (2017). A Nearest Neighbour extension to project duration forecasting with Artificial Intelligence. *European Journal of Operational Research*, 259(3), 1097–1111. doi:10.1016/j.ejor.2016.11.018

Weng, J., Coher, P. ve Herniou, M. (1992). Camera Calibration with Distortion Models and Accuracy Evaluation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(10), 965–980. doi:10.1109/34.159901

Weyer, S., Schmitt, M., Ohmer, M. ve Gorecky, D. (2015). Towards industry 4.0 - Standardization as the crucial challenge for highly modular, multi-vendor production systems. *IFAC-PapersOnLine*, 28(3), 579–584. doi:10.1016/j.ifacol.2015.06.143

Wong, K. S. ve Kim, M. H. (2017). Privacy protection for data-driven smart manufacturing systems. *International Journal of Web Services Research*, 14(3), 17–32. doi:10.4018/IJWSR.2017070102

Wu, N. ve Wang, H. (2018). Deep learning adaptive dynamic programming for real time energy management and control strategy of micro-grid. *Journal of Cleaner Production*, 204, 1169–1177. doi:10.1016/j.jclepro.2018.09.052

Xiong, H. Y., Alipanahi, B., Lee, L. J., Bretschneider, H., Merico, D., Yuen, R. K. C., ... Frey, B. J. (2015). The human splicing code reveals new insights into the genetic determinants of disease. *Science*, 347(6218), 1254806. doi:10.1126/science.1254806

Yang, C., Lan, S., Shen, W., Huang, G. Q., Wang, X. ve Lin, T. (2017). Towards product customization and personalization in IoT-enabled cloud manufacturing. *Cluster Computing*, 20(2), 1717–1730.

Yang, Y., Hong, W. ve Li, S. (2019). Deep ensemble learning based probabilistic load forecasting in smart grids. *Energy*, 189, 116324. doi:10.1016/j.energy.2019.116324

Yildirim, O., Baloglu, U. B. ve Acharya, U. R. (2019). A deep learning model for automated sleep stages classification using PSG signals. *International Journal of Environmental Research and Public Health*, 16(4), 599. doi:10.3390/ijerph16040599

Yongxing, C., Yufang, Z. ve Hongyu, Z. (2017). Real-time Evaluation Model of Power Line Fault Probability based on Multiple Meteorological factors. *Procedia Computer Science*, 107, 231–235. doi:10.1016/j.procs.2017.03.084

Yue, X., Cai, H., Yan, H., Zou, C. ve Zhou, K. (2015). Cloud-assisted industrial cyber-physical systems: An insight. *Microprocessors and Microsystems*, 39(8), 1262–1270.

Yüksel, H. (2020). An empirical evaluation of industry 4.0 applications of companies in Turkey: The case of a developing country. *Technology in Society*, 63, 101364.

Zamfirescu, C. B., Pirvu, B. C., Loskyll, M. ve Zuehlke, D. (2014). Do not cancel my race with cyber-physical systems. *IFAC Proceedings Volumes (IFAC-PapersOnline)*, 19(3), 4346–4351. doi:10.3182/20140824-6-za-1003.01600

Žarković, M. ve Stojković, Z. (2019). Artificial intelligence SF6 circuit breaker health assessment. *Electric Power Systems Research*, 175, 105912. doi:10.1016/j.epsr.2019.105912

Zhang, J. ve Li, J. (2020). Testing and verification of neural-network-based safety-critical control software: A systematic literature review. *Information and Software Technology*, 106296.

Zhang, S., Zhai, B., Guo, X., Wang, K., Peng, N. ve Zhang, X. (2019). Synchronous estimation of state of health and remaining useful lifetime for lithium-ion battery using the incremental capacity and artificial neural networks. *Journal of Energy Storage*, 26, 100951.

Zhang, W., Wulan, G., Zhai, J., Xu, L., Zhao, D., Liu, X., ... Zhou, J. (2018). An intelligent power distribution service architecture using cloud computing and deep learning techniques. *Journal of Network and Computer Applications*, 103, 239–248. doi:10.1016/j.jnca.2017.09.001

Zhao, H., Liu, H., Hu, W. ve Yan, X. (2018). Anomaly detection and fault analysis of wind turbine components based on deep learning network. *Renewable Energy*, 127, 825–834. doi:10.1016/j.renene.2018.05.024

Zhong, R. Y., Huang, G. Q., Lan, S., Dai, Q. Y., Chen, X. ve Zhang, T. (2015). A big data approach for logistics trajectory discovery from RFID-enabled production data. *International Journal of Production Economics*, 165, 260–272. doi:10.1016/j.ijpe.2015.02.014

Zhong, R. Y., Newman, S. T., Huang, G. Q. ve Lan, S. (2016). Big Data for supply chain management in the service and manufacturing sectors: Challenges, opportunities, and future perspectives. *Computers and Industrial Engineering*, 101, 572–591. doi:10.1016/j.cie.2016.07.013

Zhong, R. Y., Xu, X., Klotz, E. ve Newman, S. T. (2017). Intelligent manufacturing in the context of industry 4.0: a review. *Engineering*, 3(5), 616–630.

Zhou, F., Gao, Y. ve Wen, C. (2017). A novel multimode fault classification method based on deep learning. *Journal of Control Science and Engineering*, 2017.

Zhou, K., Liu, T. ve Zhou, L. (2015). Industry 4.0: Towards future industrial opportunities and challenges. *2015 12th International conference on fuzzy systems and knowledge discovery (FSKD)* içinde (ss. 2147–2152). IEEE.

Zolotová, I., Papcun, P., Kajáti, E., Miškuf, M. ve Mocnej, J. (2020). Smart and cognitive solutions for Operator 4.0: Laboratory H-CPPS case studies. *Computers and Industrial Engineering*, 139. doi:10.1016/j.cie.2018.10.032

Zonta, T., da Costa, C. A., da Rosa Righi, R., de Lima, M. J., da Trindade, E. S. ve Li, G. P. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering*, 106889.



EKLER

EK 1: Faktörler İçin Korelasyon Tablosu

Faktörler	Tüketim	Aktuel Basınc (hPa)	Buhar Basıncı (hPa)	İsba Sıcaklığı (°C)	Max Aktuel Basınc (hPa)	Max Nisbi Nem (%)	Max Rüzgar Yonu (°)	Max Rüzgar Hızı (m/sn)	Max Sıcaklık (°C)	Min Aktuel Basınc (hPa)	Min Nisbi Nem (%)	Min Sıcaklık (°C)	Nisbi Nem (%)	Ortalama Rüzgar Hızı (m/sn)	Rüzgar Hızı (m/sn)	Rüzgar Yonu (°)	Sıcaklık (°C)	Yağış Miktarı (mm=kg/m ²)
Tüketim	1.000	-0.256	0.423	0.296	-0.240	-0.144	0.050	-0.062	0.373	-0.234	-0.118	0.382	-0.163	-0.038	-0.038	0.054	0.373	-0.027
Aktuel Basınc (hPa)	-0.256	1.000	-0.535	-0.399	0.999	-0.033	-0.141	-0.037	-0.464	0.999	-0.030	-0.476	-0.029	-0.036	-0.036	-0.134	-0.469	-0.099
Buhar Basıncı (hPa)	0.423	-0.535	1.000	0.761	-0.531	-0.025	0.185	-0.169	0.854	-0.519	-0.017	0.862	-0.001	-0.146	-0.146	0.212	0.857	-0.052
İsba Sıcaklığı (°C)	0.296	-0.399	0.761	1.000	-0.384	0.016	0.153	-0.228	0.643	-0.374	0.011	0.642	0.041	-0.144	-0.144	0.169	0.642	-0.040
Max Aktuel Basınc (hPa)	-0.240	0.999	-0.531	-0.384	1.000	-0.032	-0.131	-0.043	-0.460	0.999	-0.028	-0.472	-0.029	-0.027	-0.027	-0.136	-0.465	-0.091
Max Nisbi Nem (%)	-0.144	-0.033	-0.025	0.016	-0.032	1.000	0.014	-0.391	-0.476	-0.032	0.959	-0.467	0.969	-0.427	-0.427	-0.018	-0.475	0.174
Max Rüzgar Yonu (°)	0.050	-0.141	0.185	0.153	-0.131	0.014	1.000	-0.108	0.179	-0.128	0.006	0.177	0.003	-0.075	-0.075	0.537	0.178	-0.006
Max Rüzgar Hızı (m/sn)	-0.062	-0.037	-0.169	-0.228	-0.043	-0.391	-0.108	1.000	0.000	-0.056	-0.368	0.016	-0.359	0.904	0.904	-0.087	0.009	0.069
Max Sıcaklık (°C)	0.373	-0.464	0.854	0.643	-0.460	-0.476	0.179	0.000	1.000	-0.450	-0.475	0.993	-0.472	0.040	0.040	0.212	0.997	-0.103
Min Aktuel Basınc (hPa)	-0.234	0.999	-0.519	-0.374	0.999	-0.032	-0.128	-0.056	-0.450	1.000	-0.028	-0.462	-0.029	-0.039	-0.039	-0.133	-0.456	-0.100
Min Nisbi Nem (%)	-0.118	-0.030	-0.017	0.011	-0.028	0.959	0.006	-0.368	-0.475	-0.028	1.000	-0.450	0.955	-0.394	-0.394	-0.019	-0.468	0.163
Min Sıcaklık (°C)	0.382	-0.476	0.862	0.642	-0.472	-0.467	0.177	0.016	0.993	-0.462	-0.450	1.000	-0.462	0.059	0.059	0.210	0.996	-0.108
Nisbi Nem (%)	-0.163	-0.029	-0.001	0.041	-0.029	0.969	0.003	-0.359	-0.472	-0.029	0.955	-0.462	1.000	-0.412	-0.412	-0.017	-0.469	0.147
Ort Rüzgar Hızı (m/sn)	-0.038	-0.036	-0.146	-0.144	-0.027	-0.427	-0.075	0.904	0.040	-0.039	-0.394	0.059	-0.412	1.000	1.000	-0.085	0.050	0.052
Rüzgar Hızı (m/sn)	-0.038	-0.036	-0.146	-0.144	-0.027	-0.427	-0.075	0.904	0.040	-0.039	-0.394	0.059	-0.412	1.000	1.000	-0.085	0.050	0.052
Rüzgar Yonu (°)	0.054	-0.134	0.212	0.169	-0.136	-0.018	0.537	-0.087	0.212	-0.133	-0.019	0.210	-0.017	-0.085	-0.085	1.000	0.211	-0.011
Sıcaklık (°C)	0.373	-0.469	0.857	0.642	-0.465	-0.475	0.178	0.009	0.997	-0.456	-0.468	0.996	-0.469	0.050	0.050	0.211	1.000	-0.104
Yağış Miktarı (mm=kg/m ²)	-0.027	-0.099	-0.052	-0.040	-0.091	0.174	-0.006	0.069	-0.103	-0.100	0.163	-0.108	0.147	0.052	0.052	-0.011	-0.104	1.000

EK 2: Elektrik Kesintilerinde Yaşanan Etkilenme Süreleri (Saat)

Aylar	OG-İmarİci-2017	AG-İmarİci-2017	OG-İmarDisi-2017	AG-İmarDisi-2017	OG-İmarİci-2018	AG-İmarİci-2018	OG-İmarDisi-2018	AG-İmarDisi-2018	OG-İmarİci-2019	AG-İmarİci-2019	OG-İmarDisi-2019	AG-İmarDisi-2019	OG-İmarİci-Genel Toplam	AG-İmarİci-Genel Toplam	OG-İmarDisi-Genel Toplam	AG-İmarDisi-Genel Toplam
Ocak	587	351013	0	266	615	192336	0	0	238	134492	22	20146	1440	677841	22	20412
Şubat	4165	7934864	0	0	151081	13880272	0	37094	120	73119	7	2765	155366	21888255	7	39859
Mart	0	29448	0	336	740	166035	0	1197	504	178172	205	15145	1244	373655	205	16678
Nisan	0	1129874	0	0	62	62147	0	2041	0	0	0	0	62	1192021	0	2041
Mayıs	296	187185	0	0	52	169434	0	922	0	0	0	0	348	356619	0	922
Haziran	140	88612	0	249	97	75549	0	0	0	0	0	0	237	164161	0	249
Temmuz	429	36211	42	9903	38	82126	0	495	0	0	0	0	467	118337	42	10398
Ağustos	255	1042	0	48785	94	42832	24	2687	0	0	0	0	349	43874	24	51472
Eylül	0	0	0	6705	386	92330	76	18654	0	0	0	0	386	92330	76	25359
Ekim	9225	6247751	0	1210	866	249060	168	10161	0	0	0	0	10091	6496811	168	11371
Kasım	406	334169	0	0	136	41241	22	3279	0	0	0	0	542	375410	22	3279
Aralık	631	92730	0	0	161	80973	2	5693	0	0	0	0	792	173703	2	5693
Genel Toplam	16134	16432899	42	67454	154328	15134335	292	82223	862	385783	234	38056	171324	31953017	568	187733

EK 3: Çeşme Elektrik Dağıtım Ağı Çalışma Durumuna Ait Derin Öğrenme Modelleri ve Tahmin Başarıları

Model No	Number of Dense Layer	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Dense Layer Output	Number of Training Iterations	Batch Sizes	Epochs	0-0	0-1	1-0	1-1	Correct Classified	Wrong Classified	% 0-0	% 0-1	% 1-0	% 1-1	Overall Accuracy of 1-1 %	Overall Accuracy %
Model-1	5	5	7	7	7	5								10	100	100	2297	1162	664	598	2895	1826	79.3	63.6	36.4	20.7	47.4	61.32
Model-2	5	10	15	15	15	2								10	100	1000	3048	411	967	295	3343	1378	91.2	29.8	70.2	8.8	23.4	70.81
Model-3	5	10	15	15	15	2								5	100	1000	2888	571	861	401	3289	1432	87.8	39.9	60.1	12.2	31.8	69.67
Model-4	5	15	15	15	15	2								10	100	1000	2746	713	807	455	3201	1520	85.8	46.9	53.1	14.2	36.1	67.80
Model-5	5	15	15	15	15	15								10	100	1000	3311	494	916	346	3311	1410	100.0	35.0	65.0	10.5	27.4	70.13
Model-6	5	10	15	15	15	2								20	100	1000	2511	948	681	581	3092	1629	81.2	58.2	41.8	18.8	46.0	65.50
Model-7	5	15	15	15	15	2								20	100	1000	3262	197	1079	183	3445	1276	94.7	15.4	84.6	5.3	14.5	72.97
Model-8	5	15	15	15	15	2								25	100	1000	2539	920	719	543	3082	1639	82.4	56.1	43.9	17.6	43.0	65.28
Model-9	5	10	15	15	15	2								30	100	1000	3103	356	979	283	3386	1335	91.6	26.7	73.3	8.4	22.4	71.72
Model-10	5	10	10	10	10	10								10	100	1000	3041	418	988	274	3315	1406	91.7	29.7	70.3	8.3	21.7	70.22
Model-11	5	10	10	10	10	10								20	100	1000	1949	1510	533	729	2678	2043	72.8	73.9	26.1	27.2	57.8	56.73
Model-12	5	10	10	10	10	10								15	100	1000	3113	346	1027	235	3348	1373	93.0	25.2	74.8	7.0	18.6	70.92
Model-13	5	15	15	15	15	15								15	100	1000	2873	586	881	381	3254	1467	88.3	39.9	60.1	11.7	30.2	68.93
Model-14	5	15	15	15	15	15								20	100	1000	3311	148	1117	145	3456	1265	95.8	11.7	88.3	4.2	11.5	73.21
Model-15	5	10	15	15	15	10								10	100	1500	3154	305	1006	256	3410	1311	92.5	23.3	76.7	7.5	20.3	72.23
Model-16	5	10	15	15	15	2								15	100	1000	2727	732	739	523	3250	1471	83.9	49.8	50.2	16.1	41.4	68.84
Model-17	5	10	15	15	15	2								20	100	1000	2511	948	681	581	3092	1629	81.2	58.2	41.8	18.8	46.0	65.50
Model-18	5	10	15	15	15	2								25	100	1000	1525	1934	352	910	2435	2286	62.6	84.6	15.4	37.4	72.1	51.58
Model-19	5	10	15	15	15	2								15	100	1250	2917	542	863	399	3316	1405	88.0	38.6	61.4	12.0	31.6	70.24
Model-20	5	10	15	15	15	2								15	100	1250	2957	502	888	374	3331	1390	88.8	36.1	63.9	11.2	29.6	70.56
Model-21	5	10	15	15	15	2								10	100	1500	2900	559	869	393	3293	1428	88.1	39.1	60.9	11.9	31.1	69.75
Model-22	5	20	20	20	20	2								10	100	1000	3057	402	950	312	3369	1352	90.7	29.7	70.3	9.3	24.7	71.36
Model-23	5	20	20	20	20	2								15	100	1000	3010	449	914	348	3358	1363	89.6	32.9	67.1	10.4	27.6	71.13
Model-24	5	20	20	20	20	2								20	100	1000	3138	321	1012	250	3388	1333	92.6	24.1	75.9	7.4	19.8	71.76
Model-25	5	20	20	20	20	2								25	100	1000	2309	1150	616	646	2955	1766	78.1	65.1	34.9	21.9	51.2	62.59
Model-26	5	10	10	10	10	2								5	100	1000	2977	482	917	345	3322	1399	89.6	34.5	65.5	10.4	27.3	70.37
Model-27	5	10	10	10	10	2								10	100	1000	2999	460	1007	255	3254	1467	92.2	31.4	68.6	7.8	20.2	68.93
Model-28	5	10	10	10	10	10								20	100	1500	1610	1849	391	871	2481	2240	64.9	82.5	17.5	35.1	69.0	52.55
Model-29	5	20	20	20	20	2								5	100	1000	2890	569	851	411	3301	1420	87.5	40.1	59.9	12.5	32.6	69.92

Model-30	5	30	30	30	30	2								5	100	1000	2789	670	819	443	3232	1489	86.3	45.0	55.0	13.7	35.1	68.46
Model-31	5	30	30	30	30	2								10	100	1000	2994	465	884	378	3372	1349	88.8	34.5	65.5	11.2	30.0	71.43
Model-32	5	30	30	30	30	2								15	100	1000	2741	718	797	465	3206	1515	85.5	47.4	52.6	14.5	36.8	67.91
Model-33	5	5	7	7	7	2								10	100	100	2059	1400	581	681	2740	1981	75.1	70.7	29.3	24.9	54.0	58.04
Model-34	5	5	7	7	7	2								10	100	1000	2490	969	656	606	3096	1625	80.4	59.6	40.4	19.6	48.0	65.58
Model-35	6	5	7	7	7	7	5							10	100	100	1938	1521	501	761	2699	2022	71.8	75.2	24.8	28.2	60.3	57.17
Model-36	6	5	7	7	7	7	5							10	100	1000	3126	333	979	283	3409	1312	91.7	25.4	74.6	8.3	22.4	72.21
Model-37	6	5	7	7	7	7	2							10	100	1000	2492	967	631	631	3123	1598	79.8	60.5	39.5	20.2	50.0	66.15
Model-38	6	5	7	7	7	7	2							15	100	1000	1069	2390	193	1069	2138	2583	50.0	92.5	7.5	50.0	84.7	45.29
Model-39	6	7	7	7	7	7	2							10	100	1000	2505	954	683	579	3084	1637	81.2	58.3	41.7	18.8	45.9	65.33
Model-40	6	10	15	15	15	15	2							5	100	1000	3005	454	912	350	3355	1366	89.6	33.2	66.8	10.4	27.7	71.07
Model-41	6	10	15	15	15	15	2							10	100	1000	2832	627	844	418	3250	1471	87.1	42.6	57.4	12.9	33.1	68.84
Model-42	6	10	15	15	15	15	2							15	100	1000	2840	619	811	451	3291	1430	86.3	43.3	56.7	13.7	35.7	69.71
Model-43	6	8	8	8	8	8	2							10	100	1000	2978	481	905	357	3335	1386	89.3	34.7	65.3	10.7	28.3	70.64
Model-44	6	10	10	10	10	10	2							10	100	1000	2955	504	907	355	3310	1411	89.3	35.7	64.3	10.7	28.1	70.11
Model-45	6	10	10	10	10	10	2							10	100	250	2516	943	674	588	3104	1617	81.1	58.3	41.7	18.9	46.6	65.75
Model-46	6	10	10	10	10	10	2							10	100	500	2167	1292	578	684	2851	1870	76.0	69.1	30.9	24.0	54.2	60.39
Model-47	6	10	10	10	10	10	2							10	100	1000	2589	870	725	537	3126	1595	82.8	54.5	45.5	17.2	42.6	66.22
Model-48	6	10	10	10	10	10	2							10	100	750	2207	1252	603	659	2866	1855	77.0	67.5	32.5	23.0	52.2	60.71
Model-49	6	8	8	8	8	8	2							15	100	1000	2508	951	663	599	3107	1614	80.7	58.9	41.1	19.3	47.5	65.81
Model-50	6	8	8	8	8	8	2							20	100	1000	2013	1446	514	748	2761	1960	72.9	73.8	26.2	27.1	59.3	58.48
Model-51	6	8	8	8	8	8	2							5	100	1000	2853	606	866	396	3249	1472	87.8	41.2	58.8	12.2	31.4	68.82
Model-52	6	15	15	15	15	15	2							10	100	1000	3089	370	943	319	3408	1313	90.6	28.2	71.8	9.4	25.3	72.19
Model-53	6	15	15	15	15	15	2							15	100	1000	2947	512	897	365	3312	1409	89.0	36.3	63.7	11.0	28.9	70.16
Model-54	6	20	20	20	20	20	2							5	100	1000	2821	638	859	403	3224	1497	87.5	42.6	57.4	12.5	31.9	68.29
Model-55	6	20	20	20	20	20	2							10	100	1000	2939	520	867	395	3334	1387	88.2	37.5	62.5	11.8	31.3	70.62
Model-56	6	20	20	20	20	20	2							15	100	1000	3036	423	952	310	3346	1375	90.7	30.8	69.2	9.3	24.6	70.88
Model-57	6	20	20	20	20	20	2							20	100	1000	2520	939	712	550	3070	1651	82.1	56.9	43.1	17.9	43.6	65.03
Model-58	6	30	30	30	30	30	2							5	100	1000	2877	582	866	396	3273	1448	87.9	40.2	59.8	12.1	31.4	69.33
Model-59	6	30	30	30	30	30	2							10	100	1000	2885	574	848	414	3299	1422	87.5	40.4	59.6	12.5	32.8	69.88
Model-60	6	30	30	30	30	30	2							15	100	1000	3096	363	990	272	3368	1353	91.9	26.8	73.2	8.1	21.6	71.34
Model-61	6	30	30	30	30	30	2							20	100	1000	3137	322	977	285	3422	1299	91.7	24.8	75.2	8.3	22.6	72.49
Model-62	7	15	15	15	15	15	15	2						5	100	1000	2998	461	889	373	3371	1350	88.9	34.1	65.9	11.1	29.6	71.40
Model-63	7	15	15	15	15	15	15	2						10	100	1000	3169	290	1030	232	3401	1320	93.2	22.0	78.0	6.8	18.4	72.04
Model-64	7	15	15	15	15	15	15	2						15	100	1000	2408	1051	758	504	2912	1809	82.7	58.1	41.9	17.3	39.9	61.68
Model-65	7	15	15	15	15	15	15	2						20	100	1000	1586	1873	316	946	2532	2189	62.6	85.6	14.4	37.4	75.0	53.63
Model-66	7	20	20	20	20	20	20	2						5	100	1000	2787	672	788	474	3261	1460	85.5	46.0	54.0	14.5	37.6	69.07
Model-67	7	20	20	20	20	20	20	2						10	100	1000	3046	413	942	320	3366	1355	90.5	30.5	69.5	9.5	25.4	71.30
Model-68	7	20	20	20	20	20	20	2						15	100	1000	2628	831	709	553	3181	1540	82.6	54.0	46.0	17.4	43.8	67.38
Model-69	7	20	20	20	20	20	20	2						20	100	1000	2580	879	672	590	3170	1551	81.4	56.7	43.3	18.6	46.8	67.15
Model-70	7	30	30	30	30	30	30	2						5	100	1000	2934	525	875	387	3321	1400	88.3	37.5	62.5	11.7	30.7	70.35
Model-71	7	30	30	30	30	30	30	2						10	100	1000	2946	513	886	376	3322	1399	88.7	36.7	63.3	11.3	29.8	70.37
Model-72	7	30	30	30	30	30	30	2						15	100	1000	2837	622	788	474	3311	1410	85.7	44.1	55.9	14.3	37.6	70.13
Model-73	7	30	30	30	30	30	30	2						20	100	1000	3459	0	1261	1	3460	1261	100.0	0.0	100.0	0.0	0.1	73.29
Model-74	7	50	50	50	50	50	50	2						5	100	1000	2891	568	835	427	3318	1403	87.1	40.5	59.5	12.9	33.8	70.28
Model-75	7	50	50	50	50	50	50	2						10	100	1000	2659	800	745	517	3176	1545	83.7	51.8	48.2	16.3	41.0	67.27

Model-76	7	50	50	50	50	50	50	2					15	100	1000	2832	627	829	433	3265	1456	86.7	43.1	56.9	13.3	34.3	69.16
Model-77	7	50	50	50	50	50	50	2					20	100	500	2454	1005	671	591	3045	1676	80.6	60.0	40.0	19.4	46.8	64.50
Model-78	7	100	100	100	100	100	100	2					5	100	1000	2996	463	932	330	3326	1395	90.1	33.2	66.8	9.9	26.1	70.45
Model-79	7	100	100	100	100	100	100	2					10	100	1000	2785	674	818	444	3229	1492	86.2	45.2	54.8	13.8	35.2	68.40
Model-80	7	100	100	100	100	100	100	2					15	100	500	2698	763	776	484	3180	1541	84.8	49.5	50.4	15.2	38.4	67.359
Model-81	9	15	15	15	15	15	15	15	15	2			5	100	1000	2643	816	734	528	3171	1550	83.3	52.6	47.4	16.7	41.8	67.17
Model-82	9	15	15	15	15	15	15	15	15	2			10	100	1000	2075	1384	573	689	2764	1957	75.1	70.7	29.3	24.9	54.6	58.55
Model-83	9	15	15	15	15	15	15	15	15	2			15	100	1000	1886	1573	476	786	2672	2049	70.6	76.8	23.2	29.4	62.3	56.60
Model-84	9	20	20	20	20	20	20	20	20	2			5	100	1000	2601	858	763	499	3100	1621	83.9	52.9	47.1	16.1	39.5	65.66
Model-85	9	20	20	20	20	20	20	20	20	2			10	100	1000	2950	509	884	378	3328	1393	88.6	36.5	63.5	11.4	30.0	70.49
Model-86	9	20	20	20	20	20	20	20	20	2			15	100	1000	3459	0	1262	0	3459	1262	100.0	0.0	100.0	0.0	0.0	73.27
Model-87	9	30	30	30	30	30	30	30	30	2			5	100	1000	2936	523	877	385	3321	1400	88.4	37.4	62.6	11.6	30.5	70.35
Model-88	9	30	30	30	30	30	30	30	30	2			10	100	1000	2958	501	902	360	3318	1403	89.2	35.7	64.3	10.8	28.5	70.28
Model-89	9	30	30	30	30	30	30	30	30	2			15	100	1000	3459	0	1262	0	3459	1262	100.0	0.0	100.0	0.0	0.0	73.27
Model-90	11	10	15	15	15	15	15	15	15	15	15	2	10	100	1000	1682	1777	457	805	2487	2234	67.6	79.5	20.5	32.4	63.8	52.68
Model-91	11	15	15	15	15	25	25	15	15	15	15	2	5	100	1000	2783	676	776	486	3269	1452	85.1	46.6	53.4	14.9	38.5	69.24
Model-92	11	15	15	15	15	25	25	15	15	15	15	2	10	100	1000	2471	988	605	657	3128	1593	79.0	62.0	38.0	21.0	52.1	66.26
Model-93	11	15	15	15	15	25	25	15	15	15	15	2	15	100	1000	1545	1914	365	897	2442	2279	63.3	84.0	16.0	36.7	71.1	51.73
Model-94	11	20	20	20	20	20	20	20	20	20	20	2	5	100	1000	3053	406	928	334	3387	1334	90.1	30.4	69.6	9.9	26.5	71.74
Model-95	11	20	20	20	20	20	20	20	20	20	20	2	10	100	1000	2489	970	649	613	3102	1619	80.2	59.9	40.1	19.8	48.6	65.71
Model-96	11	20	20	20	20	20	20	20	20	20	20	2	15	100	1000	3459	0	1262	0	3459	1262	100.0	0.0	100.0	0.0	0.0	73.27
Model-97	11	30	30	30	30	30	30	30	30	30	30	2	5	100	1000	2321	1138	619	643	2964	1757	78.3	64.8	35.2	21.7	51.0	62.78
Model-98	11	30	30	30	30	30	30	30	30	30	30	2	10	100	1000	3456	3	1256	6	3462	1259	99.8	0.2	99.8	0.2	0.5	73.33
Model-99	11	30	30	30	30	30	30	30	30	30	30	2	15	100	1000	1251	2208	340	922	2173	2548	57.6	86.7	13.3	42.4	73.1	46.03
Model-100	11	50	50	50	50	50	50	50	50	50	50	2	10	100	500	3458	1	1262	0	3458	1263	100.0	0.1	99.9	0.0	0.0	73.25

EK 4: Hedef Programlama Modeli Hedeflere ve Amaç Fonksiyonuna Ait Ceza Maliyetleri (Penalty Cost)

Model No	0-0	0-1	1-0	1-1	Overall Accuracy %	H1 Maliyet (Durum1) d_1^+	H1 Maliyet (Durum2) d_1^+	H1 Maliyet (Durum3) d_1^+	H2 d_2^+	H3 d_3^+	H4 d_4^+	H5 d_5^+	H6 d_6^-	H7 d_7^-	H8 d_8^+	H9 d_9^+	H10 d_{10}^-	H11 d_{11}^-	H12 d_{12}^-	H13 d_{13}^-	H14 d_{14}^+	H15 d_{15}^+	Z _{1j} (Durum1)	Z _{2j} (Durum2)	Z _{3j} (Durum3)
Model-1	2297	1162	664	598	61.32	-279	8021	6029	-453	-286	-301	-2152	11	29	36	14	12	9	21	10	21	10	-6530	18370	12394
Model-2	3048	411	967	295	70.81	-279	4121	6345	-128	-1261	-147	-2881	-1	41	8	20	2	-1	6	16	6	16	-10560	2640	9312
Model-3	2888	571	861	401	69.67	-279	4869	6029	-237	-1074	-235	-2724	2	38	13	17	4	0	9	14	9	14	-10453	4991	8471
Model-4	2746	713	807	455	67.80	-279	5613	5989	-295	-888	-260	-2586	4	36	18	16	5	2	12	13	12	13	-9632	8044	9172
Model-5	2965	494	916	346	70.13	-279	4517	6205	-180	-1162	-188	-2799	1	40	11	19	3	0	7	15	7	15	-10432	3956	9020
Model-6	2511	948	681	581	65.50	-279	6771	5703	-426	-598	-350	-2356	9	31	26	13	8	5	17	10	17	10	-8939	12211	9007
Model-7	3262	197	1079	183	72.97	-279	3061	6589	-11	-1526	-69	-3090	-5	45	1	22	0	-3	1	19	1	19	-11243	-1223	9361
Model-8	2539	920	719	543	65.28	-279	6679	5875	-389	-621	-308	-2385	8	32	26	14	8	5	16	11	16	11	-8604	12270	9858
Model-9	3103	356	979	283	71.72	-279	3815	6307	-114	-1337	-150	-2934	-2	42	6	20	1	-2	4	17	4	17	-11039	1243	8719
Model-10	3041	418	988	274	70.22	-279	4205	6485	-108	-1240	-117	-2875	-2	42	8	21	3	0	6	17	6	17	-10090	3362	10202
Model-11	1949	1510	533	729	56.73	-279	9847	5939	-595	171	-360	-1815	17	23	52	11	16	13	29	7	29	7	-4488	25890	14166
Model-12	3113	346	1027	235	70.92	-279	3851	6575	-68	-1328	-89	-2946	-3	43	6	22	2	-1	4	18	4	18	-10296	2094	10266
Model-13	2873	586	881	381	68.93	-279	4999	6179	-218	-1041	-204	-2710	2	38	14	18	4	1	9	15	9	15	-9900	5934	9474
Model-14	3311	148	1117	145	73.21	-279	2843	6719	28	-1580	-35	-3138	-6	46	0	23	0	-3	0	20	0	20	-11175	-1809	9819
Model-15	3154	305	1006	256	72.23	-279	3563	6367	-86	-1400	-131	-2984	-2	42	5	20	1	-2	3	17	3	17	-11196	330	8742
Model-16	2727	732	739	523	68.84	-279	5591	5619	-361	-893	-344	-2565	6	34	18	14	4	1	12	12	12	12	-10624	6986	7070
Model-17	2511	948	681	581	65.50	-279	6771	5703	-426	-598	-350	-2356	9	31	26	13	8	5	17	10	17	10	-8939	12211	9007
Model-18	1525	1934	352	910	51.58	-279	12029	5701	-788	717	-460	-1403	28	13	75	5	22	18	38	3	38	3	-2389	34535	15551
Model-19	2917	542	863	399	70.24	-279	4699	5983	-233	-1116	-242	-2751	2	38	12	17	3	0	8	14	8	14	-10784	4150	8002
Model-20	2957	502	888	374	70.56	-279	4509	6053	-207	-1164	-222	-2790	1	39	11	18	3	-1	7	15	7	15	-10838	3526	8158
Model-21	2900	559	869	393	69.75	-279	4813	6053	-228	-1088	-229	-2735	2	38	13	17	3	0	9	14	9	14	-10460	4816	8536
Model-22	3057	402	950	312	71.36	-279	4033	6225	-144	-1283	-173	-2889	-1	41	8	19	2	-1	5	16	5	16	-10982	1954	8530
Model-23	3010	449	914	348	71.13	-279	4243	6103	-180	-1230	-205	-2842	1	40	9	18	2	-1	6	15	6	15	-11039	2527	8107
Model-24	3138	321	1012	250	71.76	-279	3671	6435	-81	-1373	-117	-2969	-2	43	5	21	1	-2	4	17	4	17	-10885	965	9257
Model-25	2309	1150	616	646	62.59	-279	7853	5717	-498	-328	-369	-2161	12	28	35	12	11	7	21	9	21	9	-7556	16840	10432
Model-26	2977	482	917	345	70.37	-279	4447	6187	-179	-1179	-190	-2811	1	40	10	19	3	0	7	15	7	15	-10566	3612	8832
Model-27	2999	460	1007	255	68.93	-279	4495	6683	-92	-1167	-78	-2836	-2	42	10	22	4	1	7	17	7	17	-9213	5109	11673
Model-28	1610	1849	391	871	52.55	-279	11597	5765	-747	609	-436	-1486	25	15	70	7	21	17	36	4	36	4	-2760	32868	15372
Model-29	2890	569	851	411	69.92	-279	4837	5965	-246	-1082	-249	-2725	3	38	13	17	3	0	9	14	9	14	-10660	4688	8072
Model-30	2789	670	819	443	68.46	-279	5379	5975	-281	-946	-258	-2627	4	36	16	16	5	2	11	13	11	13	-9960	7014	8802
Model-31	2994	465	884	378	71.43	-279	4279	5955	-209	-1221	-240	-2825	1	39	10	17	2	-1	7	15	7	15	-11379	2295	7323
Model-32	2741	718	797	465	67.91	-279	5623	5939	-305	-885	-272	-2581	5	35	18	16	5	2	12	13	12	13	-9750	7956	8904
Model-33	2059	1400	581	681	58.04	-279	9283	6007	-544	30	-332	-1922	15	25	47	12	15	12	27	8	27	8	-5014	23672	13844

Model-34	2490	969	656	606	65.58	-279	6847	5595	-451	-579	-376	-2335	10	30	27	12	8	4	17	10	17	10	-9126	12252	8496
Model-35	1938	1521	501	761	57.17	-279	9849	5769	-626	172	-399	-1803	18	22	52	10	16	13	29	7	29	7	-4933	25451	13211
Model-36	3126	333	979	283	72.21	-279	3677	6261	-113	-1372	-157	-2956	-2	42	5	20	1	-2	4	17	4	17	-11331	537	8289
Model-37	2492	967	631	631	66.15	-279	6785	5441	-475	-595	-410	-2336	10	30	27	11	7	4	17	9	17	9	-9605	11587	7555
Model-38	1069	2390	193	1069	45.29	-279	14447	5659	-962	1321	-520	-962	40	0	108	0	28	25	47	0	47	0	529	44707	18343
Model-39	2505	954	683	579	65.33	-279	6811	5727	-425	-588	-345	-2351	9	31	27	13	8	5	17	10	17	10	-8826	12444	9192
Model-40	3005	454	912	350	71.07	-279	4269	6101	-182	-1224	-206	-2837	1	40	9	18	2	-1	6	15	6	15	-11011	2633	8129
Model-41	2832	627	844	418	68.84	-279	5171	6039	-256	-998	-239	-2670	3	37	15	17	4	1	10	14	10	14	-10052	6298	8902
Model-42	2840	619	811	451	69.71	-279	5057	5825	-286	-1027	-286	-2675	4	36	15	16	3	0	10	13	10	13	-10751	5257	7561
Model-43	2978	481	905	357	70.64	-279	4417	6113	-190	-1187	-207	-2811	1	39	10	18	3	-1	7	15	7	15	-10796	3292	8380
Model-44	2955	504	907	355	70.11	-279	4559	6171	-190	-1151	-196	-2790	1	39	11	18	3	0	8	15	8	15	-10468	4046	8882
Model-45	2516	943	674	588	65.75	-279	6727	5651	-433	-609	-361	-2361	9	31	26	13	7	4	17	10	17	10	-9129	11889	8661
Model-46	2167	1292	578	684	60.39	-279	8629	5773	-541	-134	-372	-2024	14	26	41	11	13	10	24	8	24	8	-6443	20281	11713
Model-47	2589	870	725	537	66.22	-279	6391	5811	-381	-693	-317	-2433	7	33	24	14	7	4	15	11	15	11	-9129	10881	9141
Model-48	2207	1252	603	659	60.71	-279	8439	5843	-516	-181	-352	-2064	13	27	39	12	12	9	23	9	23	9	-6496	19658	11870
Model-49	2508	951	663	599	65.81	-279	6753	5601	-444	-603	-373	-2353	9	31	26	12	7	4	17	10	17	10	-9227	11869	8413
Model-50	2013	1446	514	748	58.48	-279	9425	5697	-610	66	-406	-1875	17	23	48	10	15	12	27	7	27	7	-5650	23462	12278
Model-51	2853	606	866	396	68.82	-279	5089	6129	-234	-1019	-217	-2691	2	38	14	18	4	1	10	14	10	14	-9919	6185	9305
Model-52	3089	370	943	319	72.19	-279	3827	6119	-149	-1334	-193	-2919	-1	41	7	19	1	-2	5	16	5	16	-11514	804	7680
Model-53	2947	512	897	365	70.16	-279	4587	6127	-199	-1144	-207	-2781	1	39	11	18	3	0	8	15	8	15	-10548	4050	8670
Model-54	2821	638	859	403	68.29	-279	5267	6151	-242	-974	-216	-2660	3	38	16	18	5	2	10	14	10	14	-9640	6998	9650
Model-55	2939	520	867	395	70.62	-279	4575	5963	-228	-1147	-244	-2772	2	38	11	17	3	-1	8	14	8	14	-10991	3571	7735
Model-56	3036	423	952	310	70.88	-279	4163	6279	-143	-1250	-163	-2869	-1	41	8	19	2	-1	6	16	6	16	-10679	2647	8995
Model-57	2520	939	712	550	65.03	-279	6779	5871	-397	-596	-311	-2367	8	32	26	14	8	5	17	11	17	11	-8490	12684	9960
Model-58	2877	582	866	396	69.33	-279	4945	6081	-232	-1055	-225	-2713	2	38	13	17	4	1	9	14	9	14	-10223	5449	8857
Model-59	2885	574	848	414	69.88	-279	4861	5957	-249	-1076	-252	-2720	3	37	13	17	3	0	9	14	9	14	-10651	4769	8057
Model-60	3096	363	990	272	71.34	-279	3879	6387	-104	-1321	-133	-2928	-2	42	6	20	2	-1	5	17	5	17	-10751	1723	9247
Model-61	3137	322	977	285	72.49	-279	3607	6227	-114	-1389	-164	-2966	-2	42	5	20	1	-2	4	17	4	17	-11506	152	8012
Model-62	2998	461	889	373	71.40	-279	4265	5977	-204	-1225	-235	-2829	1	39	9	17	2	-1	7	15	7	15	-11339	2293	7429
Model-63	3169	290	1030	232	72.04	-279	3521	6481	-62	-1411	-104	-2999	-3	43	4	21	1	-2	3	18	3	18	-10952	448	9328
Model-64	2408	1051	758	504	61.68	-279	7543	6371	-358	-405	-213	-2262	7	33	32	17	12	8	19	12	19	12	-6230	17236	13720
Model-65	1586	1873	316	946	53.63	-279	11591	5363	-819	607	-528	-1459	28	13	70	3	20	16	37	3	37	3	-3827	31783	13099
Model-66	2787	672	788	474	69.07	-279	5329	5793	-311	-959	-299	-2624	5	35	16	15	4	1	11	13	11	13	-10496	6328	7720
Model-67	3046	413	942	320	71.30	-279	4083	6199	-152	-1270	-180	-2878	0	40	8	19	2	-1	6	16	6	16	-10987	2099	8447
Model-68	2628	831	709	553	67.38	-279	6125	5637	-394	-760	-351	-2469	8	33	22	13	6	3	14	11	14	11	-9914	9298	7834
Model-69	2580	879	672	590	67.15	-279	6339	5511	-432	-706	-385	-2422	9	31	23	12	6	3	15	10	15	10	-9977	9877	7393
Model-70	2934	525	875	387	70.35	-279	4621	6021	-221	-1136	-232	-2768	2	38	12	17	3	0	8	14	8	14	-10782	3918	8118
Model-71	2946	513	886	376	70.37	-279	4571	6063	-210	-1148	-221	-2780	1	39	11	18	3	0	8	15	8	15	-10735	3815	8291
Model-72	2837	622	788	474	70.13	-279	5029	5693	-308	-1034	-316	-2671	4	36	15	15	3	0	10	13	10	13	-11130	4794	6786
Model-73	3459	0	1261	1	73.29	-279	2243	7287	172	-1730	108	-3286	-10	50	-4	27	0	-3	-3	23	-3	23	89557	97123	112255
Model-74	2891	568	835	427	70.28	-279	4799	5867	-261	-1091	-271	-2725	3	37	13	16	3	0	9	14	9	14	-10962	4272	7476
Model-75	2659	800	745	517	67.27	-279	6011	5791	-358	-788	-314	-2500	6	34	21	14	6	3	14	12	14	12	-9654	9216	8556
Model-76	2832	627	829	433	69.16	-279	5141	5949	-270	-1006	-259	-2669	3	37	15	16	4	1	10	13	10	13	-10324	5936	8360
Model-77	2454	1005	671	591	64.50	-279	7093	5757	-439	-518	-344	-2302	10	31	29	13	9	6	18	10	18	10	-8397	13719	9711
Model-78	2996	463	932	330	70.45	-279	4363	6239	-164	-1200	-177	-2830	0	40	10	19	3	0	7	16	7	16	-10535	3391	9019
Model-79	2785	674	818	444	68.40	-279	5401	5977	-283	-941	-258	-2624	4	36	17	16	5	2	11	13	11	13	-9927	7113	8841

Model-80	2698	763	776	484	67.359	-279	5851	5903	-323	-828	-285	-2537	5	35	20	15	6	3	13	12	13	12	-9556	8834	8990
Model-81	2643	816	734	528	67.17	-279	6085	5757	-369	-770	-323	-2484	7	33	21	14	6	3	14	11	14	11	-9651	9441	8457
Model-82	2075	1384	573	689	58.55	-279	9171	5927	-551	2	-348	-1937	15	25	46	12	15	11	26	8	26	8	-5363	22987	13255
Model-83	1886	1573	476	786	56.60	-279	10111	5723	-652	237	-415	-1752	20	21	55	9	17	13	30	6	30	6	-4727	26443	13279
Model-84	2601	858	763	499	65.66	-279	6395	6015	-344	-692	-270	-2446	6	34	23	16	8	4	15	12	15	12	-8592	11430	10290
Model-85	2950	509	884	378	70.49	-279	4543	6043	-212	-1155	-225	-2784	1	39	11	18	3	0	8	15	8	15	-10822	3644	8144
Model-86	3459	0	1262	0	73.27	-279	2245	7293	173	-1730	109	-3286	-10	50	-4	27	0	-3	-3	23	-3	23	89575	97147	112291
Model-87	2936	523	877	385	70.35	-279	4613	6029	-219	-1138	-230	-2770	2	38	11	17	3	0	8	14	8	14	-10771	3905	8153
Model-88	2958	501	902	360	70.28	-279	4531	6135	-194	-1158	-204	-2792	1	39	11	18	3	0	7	15	7	15	-10597	3833	8645
Model-89	3459	0	1262	0	73.27	-279	2245	7293	173	-1730	109	-3286	-10	50	-4	27	0	-3	-3	23	-3	23	89575	97147	112291
Model-90	1682	1777	457	805	52.68	-279	11297	6017	-681	534	-372	-1558	23	18	67	9	21	17	35	6	35	6	-2471	32257	16417
Model-91	2783	676	776	486	69.24	-279	5329	5729	-323	-959	-314	-2620	5	35	16	15	4	1	11	12	11	12	-10663	6161	7361
Model-92	2471	988	605	657	66.26	-279	6859	5327	-501	-576	-438	-2315	11	29	27	10	7	4	18	9	18	9	-9811	11603	7007
Model-93	1545	1914	365	897	51.73	-279	11935	5739	-775	693	-449	-1423	27	13	74	6	21	18	37	4	37	4	-2406	34236	15648
Model-94	3053	406	928	334	71.74	-279	4013	6101	-165	-1288	-201	-2884	0	40	8	18	1	-2	5	16	5	16	-11330	1546	7810
Model-95	2489	970	649	613	65.71	-279	6839	5555	-458	-581	-385	-2334	10	30	27	12	7	4	17	10	17	10	-9241	12113	8261
Model-96	3459	0	1262	0	73.27	-279	2245	7293	173	-1730	109	-3286	-10	50	-4	27	0	-3	-3	23	-3	23	89575	97147	112291
Model-97	2321	1138	619	643	62.78	-279	7787	5711	-495	-344	-369	-2173	12	28	34	12	10	7	21	9	21	9	-7654	16544	10316
Model-98	3456	3	1256	6	73.33	-279	2251	7263	167	-1728	102	-3283	-10	50	-4	27	0	-3	-3	23	-3	23	89504	97094	112130
Model-99	1251	2208	340	922	46.03	-279	13649	6177	-813	1122	-384	-1142	33	8	97	7	27	24	44	3	44	3	904	42688	20272
Model-100	3458	1	1262	0	73.25	-279	2251	7295	173	-1728	109	-3285	-10	50	-4	27	0	-3	-3	23	-3	23	89588	97178	112310