

T.C.
BALIKESİR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

MAKİNE ÖĞRENME ALGORİTMALARI KULLANILARAK
TOPLAM EKİPMAN ETKİNLİĞİ ÖLÇÜTÜNÜN TAHMİN
EDİLMESİ

DOKTORA TEZİ

ÜMİT YILMAZ

BALIKESİR, 2023

**T.C.
BALIKESİR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI**

**MAKİNE ÖĞRENME ALGORİTMALARI KULLANILARAK
TOPLAM EKİPMAN ETKİNLİĞİ ÖLÇÜTÜNÜN TAHMİN
EDİLMESİ**

DOKTORA TEZİ

ÜMİT YILMAZ

TEZ DANIŞMANI

DOÇ. DR. ÖZLEM KUVAT

BALIKESİR, 2023

T.C.
BALIKESİR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

TEZ ONAYI

Enstitümüzün İşletme Anabilim Dalı'nda 201812508001 numaralı Ümit YILMAZ hazırladığı Makine Öğrenme Algoritmaları Kullanılarak Toplam Ekipman Etkinliği Ölçütünün Tahmin Edilmesi konulu DOKTORA tezi ile ilgili TEZ SAVUNMA SINAVI, Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliği uyarınca 27.11.2023 tarihinde yapılmış, sorulan sorulara alınan cevaplar sonunda tezin onayına OY BİRLİĞİ/OY ÇOKLUĞU ile karar verilmiştir.

Üye (Başkan) Prof. Dr. Şakir SAKARYA

İmza

Üye (Danışman) Doç. Dr. Özlem KUVAT

İmza

Üye Dr. Öğr. Üyesi Fatih AYDIN

İmza

Üye Prof. Dr. Aybeniz AKDENİZ AR

İmza

Üye Doç. Dr. Gülnil AYDIN

İmza

Enstitü Onayı

ETİK BEYAN

Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Tez Yazım Kuralları'na uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

27/11/2023

İmza

Ümit YILMAZ

ÖNSÖZ

Doktora tez aşamamda değerli fikirleri ile tarafıma yön veren, olumlu yaklaşımıyla kendime olan güvenimi tazeleyen ve desteğini bir an olsun esirgemeyen danışmanım Doç. Dr. Özlem KUVAT'a, akademik hayata girişimden itibaren birçok dönüm noktamda dokunuşu olan ve pozitif yaklaşımıyla akademiye olan inancımı güçlendiren, ders aşamasında finans alanında altyapı oluşturmama büyük emek veren, ilk danışmanlığımı yapan ve tez izleme komitesi üyeliği ile tarafımı onurlandıran Prof. Dr. Şakir SAKARYA'ya, değerli görüşleri ile tezin uygulama kısmının şekillenmesine yardımcı olan ve tez izleme komitesi üyeliği ile tarafımı şerefliendiren Dr. Öğr. Üyesi Fatih AYDIN'a, verdiği yüksek lisans derslerine beni de kabul edip yapay sinir ağları ve derin öğrenme konularında teorik altyapımın güçlenmesinde emeği olan ve bir dönem tez izleme komitesi üyeliği ile tarafımı onurlandıran Dr. Öğr. Üyesi Kamil TOPAL'a teşekkürlerimi bir borç bilirim. Ayrıca tez savunma sınavımda yer alan Prof. Dr. Aybeniz AKDENİZ AR ve Doç. Dr. Gülnil AYDIN'a teşekkürlerimi sunarım.

Doktora eğitimimin ders aşamasında akademik gelişimime büyük katkılar sağlayan Prof. Dr. Sinan AYTEKİN'e, Prof. Dr. Hüseyin AKAY'a, Prof. Dr. Oya SEYMEN'e ve Prof. Dr. Mesut SAÇKES'e teşekkürlerimi sunarım.

Tez çalışmasında kullandığım veri setini benimle paylaşan ve gizlilik gereği ismini veremediğim değerli dostuma şükranlarımı sunarım.

Doktora eğitimimim boyunca bana inancını yitirmeyen ve sürekli destekleyen eşim Özlem AKDOĞAN YILMAZ'a, Rabbimin bana en kıymetli hediyeleri olan kızlarım Azra Sare YILMAZ'a ve Alya Yağmur YILMAZ'a, eğitim hayatım boyunca maddi ve manevi desteklerini ve sevgilerini esirgemeyen annem Nebibe YILMAZ'a ve babam Sabahattin YILMAZ'a teşekkürlerimi sunarım.

BALIKESİR, 2023

ÜMİT YILMAZ

ÖZET

MAKİNE ÖĞRENME ALGORİTMALARI KULLANILARAK TOPLAM EKİPMAN ETKİNLİĞİ ÖLÇÜTÜNÜN TAHMİN EDİLMESİ

YILMAZ, Ümit

Doktora Tezi, İşletme Anabilim Dalı

Tez Danışmanı: Doç. Dr. Özlem KUVAT

2023, 142 Sayfa

Pazarlar daha rekabetçi hale geldikçe ve üretim küreselleştikçe, her üretim tesisinin rekabetçi kalabilmek için süreçlerini sıkı bir şekilde takip etmesi ve iyileştirmesi gerekmektedir. Bu hedef doğrultusunda üretim tesisleri, performanslarını ve verimliliklerini artırmak amacıyla odaklanılacak noktaları belirlemek için performans değerlendirme sistemlerini kullanmaktadır. Toplam ekipman etkinliği (TEE), üretim ekipmanının performansını değerlendirmek için yaygın olarak kullanılan bir metriktir. TEE, kullanılabilirliği, performansı ve kaliteyi birleştirerek üretim etkinliğini tanımlamaktadır. Bu doktora tez çalışmasında, Türkiye’de faaliyet gösteren bir kutu fabrikasının oluklu mukavva departmanından elde edilen bir veri seti kullanılarak TEE’yi tahmin etmek için derin öğrenme mimarilerine dayalı yaklaşımlar önerilmiştir. Bu yaklaşımların kullanımıyla işletme yöneticilerinin üretim hatlarındaki aksaklıkları belirlemesine ve TEE’yi iyileştirmek için veriye dayalı kararlar almasına yardımcı olmak amaçlanmıştır. Verilerin analizi ve TEE’nin tahmini için Uzun Kısa Süreli Bellek (Long Short Term Memory, LSTM), Çift Yönlü Uzun Kısa Süreli Bellek (Bi-directional Long Short Term Memory, Bi-LSTM) ve Geçitlendirilmiş Özyinelemeli Birimler (Gated Recurrent Units, GRU) mimarilerine dayalı model mimarileri geliştirilmiştir. Geliştirilen model mimarileri ile elde edilen bulgular bu algoritmaların üretim ortamında TEE’yi tahmin etme potansiyeline sahip olduğunu ve ekipman performansının iyileştirilmesi için kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Toplam Ekipman Etkinliği, Derin Öğrenme, Öznitelik Seçimi, Oluklu Mukavva

ABSTRACT

PREDICTING OVERALL EQUIPMENT EFFECTIVENESS MEASURE USING MACHINE LEARNING ALGORITHMS

YILMAZ, Ümit

PhD Thesis, Department of Business Administration

Advisor: Assoc. Prof. Dr. Özlem KUVAT

2023, 142 pages

As markets become more competitive and production becomes globalized, every production facility needs to closely monitor and improve its processes to remain competitive. In line with this goal, production facilities use performance evaluation systems to identify areas of focus to improve their performance and efficiency. Overall equipment effectiveness (OEE) is a widely used metric for evaluating the performance of production equipment. OEE defines production efficiency by combining availability, performance and quality. In this PhD thesis, approaches based on deep learning architectures are proposed to predict OEE using a dataset obtained from the corrugated cardboard department of a box factory operating in Turkey. The use of these approaches is intended to help business managers identify disruptions in production lines and make data-based decisions to improve OEE. Model architectures based on Long Short Term Memory (LSTM), Bi-directional Long Short Term Memory (Bi-LSTM) and Gated Recurrent Units (GRU) architectures were developed for data analysis and OEE prediction. The findings obtained with the developed model architectures show that these algorithms have the potential to predict OEE in a production environment and can be used to improve equipment performance.

Keywords: Overall Equipment Effectiveness, Deep Learning, Feature Selection, Corrugated Cardboard

*Değerli eşim Özlem AKDOĞAN YILMAZ'a ve
hayatımı renklendiren kızlarım Azra Sare YILMAZ ve Alya Yağmur YILMAZ'a...*



İÇİNDEKİLER

	Sayfa
ÖNSÖZ	iii
ÖZET.....	iv
ABSTRACT	v
İÇİNDEKİLER	vii
ÇİZELGELER LİSTESİ	xi
ŞEKİLLER LİSTESİ	xiii
KISALTMALAR LİSTESİ.....	xvi
1. GİRİŞ	1
1.1. Araştırmanın Konusu	2
1.2. Araştırmanın Amacı	2
1.3. Araştırmanın Önemi	3
1.4. Araştırmanın Varsayımları	4
1.5. Araştırmanın Sınırlılıkları	4
1.6. Tanımlar	4
2. İLGİLİ ALANYAZIN	6
2.1. Kuramsal Çerçeve	6
2.1.1. Toplam Ekipman Etkinliği	6
2.1.1.1. Altı Büyük Kayıp	9
2.1.1.2. Toplam Ekipman Etkinliğinin Hesaplanması	11
2.1.1.3. Toplam Ekipman Etkinliği Çerçevesi	15
2.1.1.4. Toplam Ekipman Etkinliğinden Türetilen Göstergeler	17
2.1.1.4.1. Toplam Tesis Etkinliği	17
2.1.1.4.2. Toplam Fabrika Etkinliği	18
2.1.1.4.3. Genel Verim Etkinliği	18
2.1.1.4.4. Toplam Kaynak Etkinliği	20
2.1.1.4.5. Toplam Hat Etkinliği	20

2.1.1.4.6. İmalat Hattının Toplam Ekipman Etkinliği.....	21
2.1.1.4.7. Üretim Ekipman Etkinliği	21
2.1.1.4.8. Toplam Varlık Etkinliği	22
2.1.1.4.9. Toplam Etkin Ekipman Performansı.....	23
2.1.1.4.10. Küresel Süreç Etkinliği	23
2.1.2. Makine Öğrenmesi	24
2.1.2.1. Makine Öğrenmesi Türleri.....	28
2.1.2.1.1. Denetimli Öğrenme	30
2.1.2.1.2. Denetimsiz Öğrenme.....	31
2.1.2.1.3. Yarı Denetimli Öğrenme.....	31
2.1.2.1.4. Pekiştirmeli Öğrenme.....	31
2.1.2.2. Makine Öğrenmesi Programlama Dilleri	32
2.1.3. Öznitelik Seçimi.....	33
2.1.3.1. Öznitelik Seçim Yöntemleri.....	34
2.1.3.1.1. Geriye Doğru Eleme	34
2.1.3.1.2. İleriye Doğru Seçim	35
2.1.3.1.3. Adımsal Seçim	35
2.1.3.1.4. Korelasyon Tabanlı Öznitelik Seçim Algoritması	35
2.1.3.1.5. Genetik Algoritma.....	35
2.1.3.1.6. Rastgele Orman	36
2.1.3.1.7. Ekstra Ağaç Algoritması	36
2.1.3.1.8. Ridge Regresyonu	36
2.1.3.1.9. Lasso Regresyonu	37
2.1.3.1.10. Elastik Net.....	37
2.1.3.2. Doğrulama Yöntemi.....	37
2.1.3.3. Eğitim Yöntemi	38
2.1.3.4. Performans Değerlendirme Ölçütleri	38

2.1.4. Derin Öğrenme.....	39
2.1.4.1. Tekrarlayan Sinir Ağları	51
2.1.4.2. Uzun Kısa Süreli Bellek.....	52
2.1.4.3. Çift Yönlü Uzun Kısa Süreli Bellek.....	54
2.1.4.4. Geçitlendirilmiş Özyinelemeli Birimler.....	55
2.2. İlgili Araştırmalar.....	57
3. YÖNTEM.....	63
3.1. Araştırmanın Modeli	63
3.2. Evren ve Örneklem	64
3.3. Veri Toplama Araçları ve Teknikleri.....	67
3.4. Veri Toplama Süreci	69
3.5. Verilerin Analizi.....	69
4. BULGULAR VE YORUMLAR	71
4.1. Toplam Ekipman Etkinliğinin Tahmin Edilmesi için LSTM Model Mimarilerinin Geliştirilmesi.....	82
4.1.1. LSTM Model Mimarisinin RMSprop Algoritması ile Optimizasyonu ...	83
4.1.2. LSTM Model Mimarisinin Adam Algoritması ile Optimizasyonu	88
4.2. Toplam Ekipman Etkinliğinin Tahmin Edilmesi için Bi-LSTM Model Mimarilerinin Geliştirilmesi.....	93
4.2.1. Bi-LSTM Model Mimarisinin RMSprop Algoritması ile Optimizasyonu	94
4.2.2. Bi-LSTM Model Mimarisinin Adam Algoritması ile Optimizasyonu	99
4.3. Toplam Ekipman Etkinliğinin Tahmin Edilmesi için GRU Model Mimarilerinin Geliştirilmesi.....	104
4.3.1. GRU Model Mimarisinin RMSprop Algoritması ile Optimizasyonu....	105
4.3.2. GRU Model Mimarisinin Adam Algoritması ile Optimizasyonu.....	110
4.4. Toplam Ekipman Etkinliğinin Tahmini için Geliştirilen Modellerin Karşılaştırılması	115

4.4.1. RMSprop Algoritması ile Optimize Edilen Modellerin Karşılaştırılması	115
4.4.2. Adam Algoritması ile Optimize Edilen Modellerin Karşılaştırılması ...	116
4.4.3. Optimizasyon Algoritmalarına Göre Optimum Sonuç Veren Model Mimarilerinin Performans Ölçüt Değerlerinin Karşılaştırılması	117
5. SONUÇ VE ÖNERİLER.....	119
5.1. Sonuçlar.....	119
5.2. Öneriler	121
KAYNAKÇA	122



ÇİZELGELER LİSTESİ

Sayfa

<u>Cizelge 1.</u> Performans Ölçümünün Fonksiyonları.....	7
<u>Cizelge 2.</u> Altı Büyük Kayıp.....	11
<u>Cizelge 3.</u> Toplam Ekipman Etkinliği Yaklaşımına Göre Performans Ölçütlerinin Hesaplanması	12
<u>Cizelge 4.</u> Toplam Ekipman Etkinliğinin Ölçümünde Kriterlerin Durumları	14
<u>Cizelge 5.</u> Makine Öğrenmesi Kategorileri Arasındaki Farklar	29
<u>Cizelge 6.</u> Öznitelik Seçimi Öncesi Öznitelikler	72
<u>Cizelge 7.</u> Yönteme Göre Seçilen Öznitelikler ve Performans Ölçütleri	75
<u>Cizelge 8.</u> Derin Sinir Ağları Mimarilerinin Tasarım Hiperparametreleri	78
<u>Cizelge 9.</u> RMSprop Algoritması ile Optimize Edilen LSTM Modellerinin Performans Ölçüt Değerleri.....	84
<u>Cizelge 10.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen LSTM Modelinin Performans Ölçüt Değerleri	85
<u>Cizelge 11.</u> Adam Algoritması ile Optimize Edilen LSTM Modellerinin Performans Ölçüt Değerleri.....	89
<u>Cizelge 12.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen LSTM Modelinin Performans Ölçüt Değerleri	90
<u>Cizelge 13.</u> RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modellerinin Performans Ölçüt Değerleri	95
<u>Cizelge 14.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modelinin Performans Ölçüt Değerleri.....	96
<u>Cizelge 15.</u> Adam Algoritması ile Optimize Edilen Bi-LSTM Modellerinin Performans Ölçüt Değerleri	100
<u>Cizelge 16.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen Bi-LSTM Modelinin Performans Ölçüt Değerleri	101
<u>Cizelge 17.</u> RMSprop Algoritması ile Optimize Edilen GRU Modellerinin Performans Ölçüt Değerleri.....	106
<u>Cizelge 18.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen GRU Modelinin Performans Ölçüt Değerleri	107

<u>Cizelge 19.</u> Adam Algoritması ile Optimize Edilen GRU Modellerinin Performans Ölçüt Değerleri.....	111
<u>Cizelge 20.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen GRU Modelinin Performans Ölçüt Değerleri	112
<u>Cizelge 21.</u> RMSprop Algoritması ile Optimize Edilen LSTM, Bi-LSTM ve GRU Model Mimarilerinin Test Edilmesi Sonucunda Elde Edilen Optimal Performans Ölçüt Değerleri.....	116
<u>Cizelge 22.</u> Adam Algoritması ile Optimize Edilen LSTM, Bi-LSTM ve GRU Model Mimarilerinin Test Edilmesi Sonucunda Elde Edilen Optimal Performans Ölçüt Değerleri.....	117
<u>Cizelge 23.</u> Optimizasyon Algoritmalarına Göre Optimum Sonuç Veren Modellere İlişkin Performans Ölçüt Sonuçları.....	118

ŞEKİLLER LİSTESİ

Sayfa

<u>Sekil 1.</u> Entegre Bir Toplam Ekipman Etkinliği Çerçevesi	15
<u>Sekil 2.</u> Makine Öğrenmesi ve Bilgisayar Bilimindeki Güncel Gündem Konuları Arasındaki İlişkiler.....	25
<u>Sekil 3.</u> Bir Makine Öğrenmesi Sistem Konfigürasyonu.....	26
<u>Sekil 4.</u> Makine Öğrenmesi Yaklaşımlarını Kullanmak için Temel Prosedürler	27
<u>Sekil 5.</u> Makine Öğrenmesi.....	30
<u>Sekil 6.</u> Derin Sinir Ağlarının Temel Yapısı	41
<u>Sekil 7.</u> Derin Öğrenme	42
<u>Sekil 8.</u> Eniyileme Algoritmalarının Evrimsel Haritası.....	45
<u>Sekil 9.</u> Evrişimli Katman.....	48
<u>Sekil 10.</u> Tam Bağlı Katman.....	49
<u>Sekil 11.</u> a) Basit Bir Sinir Ağı, b) Bırakma Sonrası Sinir Ağı	50
<u>Sekil 12.</u> Temel Bir Tekrarlayan Sinir Ağı Hücresi	52
<u>Sekil 13.</u> Uzun Kısa Süreli Bellek Mimari Yapısı.....	53
<u>Sekil 14.</u> Çift Yönlü Uzun Kısa Süreli Bellek Mimarisi	55
<u>Sekil 15.</u> Geçitlendirilmiş Özyinelemeli Birim	56
<u>Sekil 16.</u> Toplam Ekipman Etkinliğinin Tahmin Edilmesi için Gerçekleştirilen İşlem Adımları	63
<u>Sekil 17.</u> Düz Yatak Kalıp Kesme ve Kırma	66
<u>Sekil 18.</u> Rotary Kesme ve Kırma	66
<u>Sekil 19.</u> İşletme İş Akış Şeması	67
<u>Sekil 20.</u> Öznitelik Seçimi için Geliştirilen Modelin Akış Şeması.....	73
<u>Sekil 21.</u> Test İşlemi Sonrasında Elde Edilen Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları	76
<u>Sekil 22.</u> Test İşlemi Sonrasında Elde Edilen Çıktı Değerleri ile Hedef Değerlerin Karşılaştırılması	77
<u>Sekil 23.</u> Toplam Ekipman Etkinliğinin Tahmini İçin Geliştirilen Modellerin Akış Şeması	81
<u>Sekil 24.</u> LSTM Model Mimarisi	83

<u>Sekil 25.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen LSTM Modelinin Eğitim Seyri	86
<u>Sekil 26.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen LSTM Modelinin Çıktı Değerleri ile Hedef Değerler.....	87
<u>Sekil 27.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen LSTM Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları.....	88
<u>Sekil 28.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen LSTM Modelinin Eğitim Seyri.....	91
<u>Sekil 29.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen LSTM Modelinin Çıktı Değerleri ile Hedef Değerler	92
<u>Sekil 30.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen LSTM Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları	93
<u>Sekil 31.</u> Bi-LSTM Model Mimarisi	94
<u>Sekil 32.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modelinin Eğitim Seyri	97
<u>Sekil 33.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modelinin Çıktı Değerleri ile Hedef Değerler	98
<u>Sekil 34.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları....	99
<u>Sekil 35.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen Bi-LSTM Modelinin Eğitim Seyri	102
<u>Sekil 36.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen Bi-LSTM Modelinin Çıktı Değerleri ile Hedef Değerler.....	103
<u>Sekil 37.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen Bi-LSTM Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları.....	104
<u>Sekil 38.</u> GRU Model Mimarisi.....	105
<u>Sekil 39.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen GRU Modelinin Eğitim Seyri	108
<u>Sekil 40.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen GRU Modelinin Çıktı Değerleri ile Hedef Değerler.....	109
<u>Sekil 41.</u> Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen GRU Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları.....	110
<u>Sekil 42.</u> Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen GRU Modelinin Eğitim Seyri.....	113

Sekil 43. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen GRU Modelinin Çıktı Değerleri ile Hedef Değerler 114

Sekil 44. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen GRU Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları 115



KISALTMALAR LİSTESİ

AdaDelta	: Adaptive Learning Rate Method (Uyarlanabilir Öğrenme Oranı Yöntemi)
AdaGrad	: Adaptive Gradient Algorithm (Uyarlanabilir Gradyan Algoritması)
Adam	: Adaptive Moment Estimation (Uyarlanabilir Moment Tahmini)
AdaMax	: An Extension of Adam Based on the Infinity Norm (Sonsuzluk Normuna Dayanan Adam Eniyileycisinin Bir Uzantısı)
AMSGrad	: Adaptive Mean Square Gradient (Uyarlanabilir Kareler Ortalaması Gradyan Algoritması)
Bi-LSTM	: Bi-directional Long Short Term Memory (Çift Yönlü Uzun Kısa Süreli Bellek)
GPE	: Global Process Effectiveness (Küresel Süreç Etkinliği)
GRU	: Gated Recurrent Units (Geçitlendirilmiş Özyinelemeli Birimler)
LSTM	: Long Short Term Memory (Uzun Kısa Süreli Bellek)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hatası)
MSE	: Mean Squared Error (Ortalama Karesel Hata)
Nadam	: Nesterov-accelerated Adaptive Moment Estimation (Nesterov Hızlandırılmalı Uyarlanabilir Moment Tahmini)
NAG	: Nesterov Accelerated Gradient (Nesterov Hızlandırılmış Gradyan)
OEEML	: Overall Equipment Efficiency of a Manufacturing Line (İmalat Hattının Toplam Ekipman Etkinliği)
OAE	: Overall Asset Effectiveness (Toplam Varlık Etkinliği)
OPE	: Overall Plant Effectiveness (Toplam Tesis Etkinliği)
ORE	: Overall Resource Effectiveness (Toplam Kaynak Etkinliği)
OTE	: Overall Throughput Effectiveness (Genel Verim Etkinliği)
PEE	: Production Equipment Effectiveness (Üretim Ekipman Etkinliği)

R	: Korelasyon Katsayısı
R²	: Belirlilik Katsayısı
RMSE	: Root Mean Squared Error (Ortalama Hata Kare Kökü)
RMSprop	: Root Mean Square Propagation (Karekök Ortalama Yayılımı)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağları)
TEE	: Toplam Ekipman Etkinliği
TEEP	: Total Equipment Effectiveness Performance (Toplam Etkin Ekipman Performansı)



1. GİRİŞ

Uluslararası alanda varlıklarını sürdürmeyi hedefleyen ve pazar paylarını artırmak isteyen imalat işletmeleri, bu amaçlar doğrultusunda zorlu bir rekabet ortamına girmek durumundadır. Rekabetçi pazarlarda müşteri memnuniyetini artırmak pazar payını korumanın ve genişletmenin kilit bir unsuru olarak öne çıkmaktadır. Müşteri memnuniyeti, üretilen ürünün yüksek kaliteli olması, hızlı teslim edilmesi, güvenilir olması, özelleştirilebilir olması ve aynı zamanda tüm bu özellikleri düşük maliyetle sağlayabilmesi ile elde edilmektedir. Bahsi geçen bu özellikler pazar gereksinimlerini özetler niteliktedir.

İmalat işletmeleri, uluslararası arenada rekabet güçlerini sürdürebilmek ve artırabilmek adına pazar gereksinimlerini karşılamalıdır. Pazar gereksinimleri ile imalat şirketinin üretim performansı arasındaki fark, rekabet gücü, pazar payı ve karlılık kaybına yol açmaktadır. Bundan dolayı, imalat işletmeleri pazar gereksinimlerini karşılayabilmek için üretim performanslarını sürekli olarak iyileştirmek zorundadırlar. Bu zorunlulukla başa çıkmak isteyen imalat işletmeleri için performans ölçümleri, üretimdeki iyileşmeleri yönlendirmek ve yönetmek açısından, büyük bir öneme sahiptir.

Üretim operasyonlarında sıkça kullanılan performans ölçütlerinden biri, toplam ekipman etkinliğidir. Bu ölçüt, bir işletmenin performans ölçüm sisteminin bir parçası olarak imalat performansını izlemek için yaygın bir şekilde kullanılmaktadır. Toplam ekipman etkinliği, bir üretim operasyonunun ne kadar etkin bir şekilde gerçekleştiğini ölçmeyi amaçlamaktadır. Bu basit ve kullanışlı araç, üretim verimliliği kaybına neden olan faktörleri belirlemektedir. Bu faktörleri ekipman kullanımı, süreç performansı ve ürün kalitesi olmak üzere üç ana gruba ayırarak, ekipmanın etkinliğini artırmaya çalışmaktadır.

Toplam ekipman etkinliğinin ölçülmesinin amacı, ekipmanın etkinliğini artırmaktır. Bu ölçüt, imalat işletmelerinde düzenli aralıklarla incelenerek, etkinlik

kaybını azaltmak amacıyla ekipman iyileştirmelerinin planlanmasına ve uygulanmasına öncelik etmektedir. Bu tez çalışması, toplam ekipman etkinliği değerini başarılı bir şekilde tahmin etmek amacıyla gerçekleştirilmiştir. Tez çalışmasının ana odak noktası, toplam ekipman etkinliğini önceden tahmin ederek bu sayede potansiyel iyileştirme alanlarını belirlemek ve bu alanlarda uygulanabilecek çözümleri önermektir. Bu şekilde, toplam ekipman etkinliğinin artırılması hedeflenmektedir.

Bu tez çalışması keşifsel, tanımlayıcı ve uygulamalı bir araştırma planlaması olacak şekilde yapılmıştır. Tez çalışmasının amacında belirtilen hususlara erişebilmek için alan yazın araştırması, işletmeye ait genel bilgilerin elde edilmesi ve işletmenin üretim süreçlerine ilişkin geçmiş verilerin toplanması ve göstergenin tahmini için önerilen yöntemin uygulanması faaliyetleri gerçekleştirilmiştir.

1.1. Araştırmanın Konusu

Bir kutu fabrikasının oluklu mukavva departmanından elde edilen planlı duruş süreleri ve üretim öncesinde net olarak bilinen siparişe dayalı bilgilerin toplam ekipman etkinliği tahmini başarısı üzerine ne derecede etkili olduğu bu tez çalışmasının konusunu oluşturmaktadır.

1.2. Araştırmanın Amacı

Bu tez çalışmasının amacı, Türkiye’de faaliyet gösteren bir kutu fabrikasının oluklu mukavva departmanından elde edilen veri seti kullanılarak ve makine öğrenmesi tekniklerinden olan derin öğrenme yöntemlerine dayalı model mimarileri geliştirilerek ilgili departmanın toplam ekipman etkinliğini tahmin etmektir. Geliştirilen model mimarileri yardımıyla ilgili departmanın içerisindeki varlıklara ilişkin göstergeler alınarak departmanın gelecekteki toplam ekipman etkinliği oranları tahmin edilmiştir. Tahminde kullanılan her bir optimizasyon algoritması ve derin öğrenme yöntemi çifti ile modellerin eğitilmesi, doğrulanması ve test edilmesi gerçekleştirilmiş, gerçekleştirilen işlemler neticesinde elde edilen performans değerleri karşılaştırılarak, her bir algoritma ve yöntem çiftinin avantaj ve dezavantajları belirlenmiştir.

Yapılan arařtırmayla toplam ekipman etkinliđi oranının ileriki dnemlerde ne dzeyde olacađı tahmin edilerek kullanılabilirlik, performans ve kalite başarısızlıklarının nlenmesine karřı daha sađlıklı eylem planlarının oluřturulabilmesine olanak sađlanmıřtır. Bu sayede beklenmedik aksama (downtime) sresinin azalması, hizmet programının iyileřtirilmesiyle bakım ziyaretlerinin azalması, kritik makine problemlerinin daha hızlı tanımlanması ve dzeltilmesiyle makine sađlıđının dođru ve gerek zamanlı durumunun izlenebilmesi gibi ideallere ulařılması ve neticede toplam ekipman etkinliđi lt deđerinde ykselme grlmesi hedeflenmektedir.

Modelin girdilerini oluřturan znelikler, zneliklerin seiminde kullanılan yntemler, modellerin oluřturulmasında faydalanılan yntemler ve algoritmalar, modellerin karřılařtırılmasında kullanılan metrikler gz nne alındıđında ve alan yazındaki alıřmalar ile karřılařtırıldıđında, alan yazında tez alıřmasının senaryosuna benzer bir senaryo mevcut deđerdir. Dolayısıyla bu problem alan yazında aık bir problem olup henz incelenmemiřtir. Bu tez alıřmasıyla alan yazındaki toplam ekipman etkinliđi tahmini alıřmalarına bir yenisini eklenmiřtir.

1.3. Arařtırmanın nemi

Toplam ekipman etkinliđi tahmini, kesin verilere dayanan geleneksel toplam ekipman etkinliđi hesaplamasına kıyasla durma sresi, retim hızı ve kalite kayıplarına iliřkin belirsizlikler dikkate alınarak yapılmaktadır. Toplam ekipman etkinliđi, bir ekipmanın etkinliđi iin nemli bir performans ls olduđundan, eřitli bileřenlerin toplam ekipman etkinliđi deđerini zerine olan etkisini bilmek iin dikkatli analizler yapmak gerekmektedir (Prasetyo ve Veroya, 2020, s. 345). Bu alıřma ile başarılı bir toplam ekipman etkinliđi deđerini tahmini gerekleřtirilerek, hattın iyileřtirme gerektiren kritik noktalarının tespit edilmesi hedeflenmektedir (Tsarouhas, 2019a, s. 88).

alıřmada yapılacak analiz, yneticilere ve mhendislere yararlı bir bakıř aısı sađlayacak ve yneticilerin ve mhendislerin hattın operasyon ynetimi hakkında daha iyi kararlar almasına yardımcı olacaktır. Bu sayede verimlilik ve rnlerin kalitesi artacak, ani arızalar ve bakım maliyeti ise azalacaktır (Tsarouhas, 2019b, s. 1009).

1.4. Arařtırmanın Varsayımları

Tez alıřmasında kullanılmak üzere kutu fabrikasından alınan veri setinin doęru ve güvenilir olduęu varsayılmaktadır.

1.5. Arařtırmanın Sınırlılıkları

Her arařtırma gibi bu alıřma da bazı sınırlamalara sahiptir. Ana sınırlamalardan biri, bu arařtırmanın bulgularını daraltan vaka alıřmasına dayalı arařtırmanın doęasıyla ilgilidir. Dolayısıyla, bulguların aktarılabilirlięini incelemek iin aynı alıřmanın dięer imalat organizasyonlarında da yapılması önerilmektedir (Dadashnejad ve Valmohammadi, 2019, s. 460).

Toplam ekipman etkinlięinin hesaplanması, üretim hızı ve ekipmanın durma ölçümlerini gerektirmektedir. Bununla birlikte, bu ölçümlerdeki belirsizlikler, özellikle operatörlerin verileri kaydettięi manuel veya yarı otomatik veri toplama sistemlerinde oldukça yaygındır. Belirsizlikler genellikle küçük kesintiler veya küçük hız kayıpları gibi rapor edilmemiş kayıplardan, insan faktöründen kaynaklanan hatalardan, ölçüm cihazlarının sınırlamalarından ve veri toplama süreçlerindeki kusurlardan kaynaklanmaktadır (Sonmez, Testik ve Testik, 2018, s. 121).

Tez alıřmasının gerek öznitelik seçimi gerek de tahmin kısmında belli bařlı tasarım hiperparametreleri üzerinden işlemler gerçekleştirilmiştir. Tez alıřmasında kurulabilecek ok büyük sayıda model mimarisi alternatifini olmasından dolayı bahsi geen hiperparametreler yardımıyla alıřma uzayı sınırlandırılmıştır. Bu sayede model sayısı belirli kořullara göre belirlenmiş ve kurulan modeller analizlere tabi tutulmuřtur.

Tez alıřmasında 2017-2020 yılları arasındaki 1204 iş gününe ait veriler yardımıyla toplam ekipman etkinlięi tahmini gerçekleştirilmiştir. Verilerin elde edildięi işletme, gizlilik politikası gereęi bu tarih aralıęının öncesinin ve sonrasının verilerini paylaşmamıştır.

1.6. Tanımlar

Arařtırmada sıklıkla geen önemli kavramların tanımları ařaęıda yer almaktadır.

Toplam Ekipman Etkinliđi: Kullanılabilirliđi, performansı ve kaliteyi birleřtirerek makine ve ekipmanların etkinliđini tanımlamak için kullanılan bir performans ölçüm aracıdır (Muchiri ve Pintelon, 2008, s. 3519).

Makine Öğrenmesi: Belirli bir görevi, açık talimatlar kullanmadan, verilerden tahmin edici bir model oluşturmak için kalıplara ve çıkarıma dayanarak gerçekleřtiren bir dizi istatistiksel ve hesaplama tekniđini ifade eder (Coorey vd., 2020, s. 4).

Öznelik Seçimi: Öznelik sayısından bağımsız olarak mümkün olan en iyi tahmin performansını elde etmek için en uygun öznelik kümesini belirlemeye öznelik seçimi adı verilir (Akman vd., 2023, s. 2).

Derin Öğrenme: Bir işlemleri tanımlanan örnekler aracılığıyla öğrenebilen ve çok katmanlı modellerden oluşan sinir ađlarının çalışma ilkelerine dayanan bir makine öğrenmesi yöntemidir (Bayraktarođlu ve Adıgüzel, 2020, s. 308).

2. İLGİLİ ALANYAZIN

2.1. Kuramsal Çerçeve

İlgili alan yazın bölümü; kuramsal çerçeve ve ilgili araştırmalar kısımlarından oluşmaktadır. Kuramsal çerçeve kısmında ilk olarak toplam ekipman etkinliği kavramından bahsedilmiştir. İkinci olarak makine öğrenmesi kavramı ele alınmıştır. Üçüncü olarak öznitelik seçimi kavramından, öznitelik seçimi yöntemlerinden ve öznitelik seçimi için izlenen işlem adımlarından bahsedilmiştir. Son olarak da derin öğrenme kavramı, derin öğrenme modelinin yapısal özellikleri ve derin öğrenmede kullanılan yöntemler mercek altına alınmıştır.

2.1.1. Toplam Ekipman Etkinliği

Pazarlar daha rekabetçi hale geldikçe ve üretim küreselleştikçe, her üretim tesisinin rekabetçi kalabilmek için süreçlerini iyileştirmesi gerekmektedir. Bu hedef doğrultusunda üretim tesislerinin makine ve ekipmanlarını etkin ve verimli bir şekilde kullanarak birim üretim maliyetini düşürmeleri ve kaliteyi optimal düzeye getirmeleri gerekmektedir. Bunun yolu da sürece hâkim olmaktan geçmektedir. Üretim tesisleri, performanslarını ve verimliliklerini artırmak için odaklanılacak alanları belirlemek amacıyla ölçüm sistemlerini kullanmaktadırlar. Bunun sebebi ölçülebilen tüm parametrelerin geliştirilebileceğinin varsayılmasıdır. Üretim tesisleri, bünyelerinde bulundurduğu makine ve ekipmanın etkin ve verimli bir şekilde kullanılıp kullanılmadığını belli başlı performans göstergelerini takip ederek tespit etmektedirler. Performans ölçümü, yönetim için her zaman önemlidir. Bunun sebebi performans ölçümünün mevcut performans ile istenen performans arasındaki boşluğu belirlemesi ve şirketin boşlukları kapatmaya yönelik ilerlemeyi başlatmasını sağlamasıdır (Puvanavarana, Teoh ve Ito, 2020, s. 2). Performans ölçümünün fonksiyonları Çizelge 1’de listelenmiştir (Schmitz ve Platts, 2004, s. 234).

Çizelge 1. Performans Ölçümünün Fonksiyonları

Kategori	Fonksiyonlar / Ölçüm Amacı
Strateji oluşturma ve açıklama	Operasyonelleştirilebilir hedefler ve eylemlerde vizyon ve stratejiyi değiştirir. Stratejiyi değiştirir. Üst yönetim arasındaki gizli anlaşmazlıkları ortaya çıkarmaya ve çözmeye yardımcı olur. Değerleri açıkça belirtir. Kuruluşlar için hedefleri ve performans beklentilerini tanımlamaya yardımcı olur.
Yönetim bilgileri	Yönetim bilgilerini sağlar. Gelişmiş kontrol için yönetim için geri bildirim sağlar. Planlama ve tahmin için bilgi sağlar. Performans açıklarını belirler.
Dikey iletişim	Stratejiyi organizasyon genelinde iletir. Kuruluşun tepesinden aşağıya doğru strateji iletişiminin netliğini sağlar. Eylemler, kararlar ve iyileştirme faaliyetleri için net hedefler aktarır. Performans beklentilerini iletir. Sorumlulukları ve hedefleri netleştirir. Çalışanlara nasıl katkıda bulunacakları konusunda kesinlik verir. Üstlerle ve çalışanlarla akılcı münazaralar için temel sağlar. İletişim için ortak bir dil sağlar.
Yatay iletişim	Stratejiyi organizasyon genelinde iletir. İletişim için ortak bir dil sağlar. Diğer departmanlarla akılcı münazaralar için temel sağlar. Sorumlulukları ve hedefleri netleştirir.
Karar verme ve önceliklendirme	Karar vermeyi destekler. Kaynak tahsis kararları için bilgi sağlar. Karar vermeye yardımcı olmak için eylemlerin verimliliğini ve etkililiğini ölçer ve bir kuruluşun performansını bir bütün olarak değerlendirir.
Koordinasyon ve uyum	Organizasyon genelinde hedeflerin ve eylemlerin uyumunu sağlar. Kontrolü elde tutulan eylemlerin ve kararların yetkilendirilmesini basitleştirir.
Motivasyon	Çalışanları motive eder. Çalışanların genel organizasyon performansına katkısını gösterir. Performansa dayalı ödemeler için temel sağlar. Başarılarını netleştirerek çalışanları motive eder.
Öğrenme	Yeteneklere ilişkin bilgileri geliştirir. İş süreçlerinin anlaşılabilirliğini geliştirir.
Diğer	Yönetimin dikkatini kritik konulara odaklar. Objektif değerlendirme için temel sağlar. Verilerin elde edilmesini, düzenlenmesini, analiz edilmesini, yorumlanmasını ve yayılmasını sağlar.

Kaynak: Taywade, P. and Ashtankar, K. M. (2016). Evaluation of overall equipment effectiveness (OEE), its optimization and analysis through design of experiment (DOE) *International Journal of Advance Engineering and Research Development*, 3 (4), 385-391.

Üretim sistemlerinin verimliliğini ölçmek ve analiz etmek için geçtiğimiz yarı asırda birçok farklı metrik incelenmiştir. Verimliliği ölçmek için kullanılan geleneksel ölçütler, üretim ekipmanının performansının yalnızca bir kısmını ölçen iş hacmi ve kullanım oranıdır. Ancak bu ölçütler verimliliği artırmak için temelde yatan sorunları ve bu sorunları gidermek için gereken iyileştirmeleri tanımlamak için çok yardımcı olamamışlardır. Son yıllarda ise işletmelerin iş hacmi ve kullanım oranı gibi parametrelerin yanı sıra kapasite, doygunluk, kullanılabilirlik, kalite gibi performans parametrelerine olan ilgileri artmaktadır. Bu artan ilgi, bir dizi önemli faktörü hesaba katmaya müsaade eden, daha titiz bir şekilde tanımlanmış ve kabul edilmiş verimlilik ölçütlerine olan ihtiyacı vurgulamaktadır. Bu ihtiyacın karşılanması amacıyla çeşitli yeni performans konseptleri geliştirilmiştir (Cesarotti, Giuiusa ve Introna, 2013, s. 51). Yeni performans konseptleri içerisindeki ana araçlardan biri işbirlikçileri, süreçleri ve makineleri içeren, üretim ve kalite sistemlerinin bütünlüğünü koruyarak ve geliştirerek bir kuruluşa iş değeri katmayı amaçlayan toplam verimli bakım sistemidir. Seiichi Nakajima tarafından 1971’de geliştirilen bu yöntemin amacı, tek bir imalat makinesinin veya entegre bir sistemin verimliliğini analiz etmek için en geniş performans ölçütleri seti olarak kabul edilen tesis makinesinin toplam ekipman etkinliğini iyileştirmektir (Becker, Borst ve van der Veen, 2015, s. 419; da Silva vd., 2017, s. 278).

Üretim varlıklarının performansının değerlendirilmesi, varlık yaşam döngüsü boyunca gerçekleştirilecek en iyi düzeltici ve önleyici eylemler hakkında bilinçli karar vermeyi destekleyen iyileştirme eylemlerinin temelini oluşturmaktadır (Roda ve Macchi, 2019, s. 226). Endüstriyel uygulamaya bakıldığında, üretim sistemlerinin performans değerlendirmesi için şirketler tarafından kullanılan en popüler yaklaşımlardan biri olan toplam ekipman etkinliği (TEE), ilk olarak Seiichi Nakajima tarafından 1980’lerin sonlarında bir Toyota tedarikçisi olan Nippondenso’da tanıtılmış ve daha sonra Toyota üretim sistemi sürekli iyileştirme stratejisinin temelini oluşturmuştur (Ng Corrales vd., 2020, s. 10; Schiraldi ve Varisco, 2020, s. 1).

Toplam ekipman etkinliđi, yüzde olarak ifade edilen üretim operasyonları performansının ve etkinliđinin bir ölçüsü olarak tanımlanmaktadır. Toplam ekipman etkinliđi, bir üretim sürecinin ne kadar etkin olduğunu gösterir ve bir şirketin üretim operasyonlarının ne kadar iyi performans gösterdiğinin genel ve kapsayıcı bir ölçümü olarak hizmet etmektedir. Toplam ekipman etkinliđi, ilgili performans fırsatlarını belirleyerek makine performansının artmasına öncülük edebilmektedir (Chikwendu, Chima ve Edith, 2020, s. 2).

Toplam ekipman etkinliđi, toplam varlık performansını ve güvenilirliğini artırmak amacıyla tek bir varlıkla (makine veya ekipman) ve/veya tek akışlı süreçle ilgili kayıpları tanımlamak için kullanılmaktadır. Ayrıca, iyileştirmenin ne düzeyde olduğunu gösteren bir makine kapasitesi ölçüsüdür. Üretim tesisinden toplanan istatistiksel veriler, iyileştirme alanı için yararlı bilgilere dönüşmektedir (Taywade ve Ashtankar, 2016, s. 385).

Toplam ekipman etkinliđinin ana hedefi verimliliđi artırmak, maliyeti azaltmak, makine verimliliđi ihtiyacına ilişkin farkındalıđı artırmak ve ekipman ömrünü uzatmaktır. Bu hedeflere ulaşıldığı takdirde işletmelerin karlılıđı artacak, rekabette mevcut düzeyleri korunacak veya daha rekabetçi hale gelmesi sağlanacak ve giderleri azalacaktır (Stamatis, 2017, s. 21).

Bir iş ölçütü olarak uygulanan toplam ekipman etkinliđi, şirketlerin operasyonlarını finansal terimlerle görüntülemelerini sağlayarak maliyet performansını iyileştirmek için kaynakları nereye dağıtacaklarını anlamalarına yardımcı olmaktadır. İş operasyonları açısından daha ayrıntılı maliyet bilinci ile donanmış şirketler, ürün son fiyatlandırmasını avantaj sağlayacak şekilde daha iyi optimize edebilir.

2.1.1.1. Altı Büyük Kayıp

Toplam ekipman etkinliđi kullanılabilirliđi, performansı ve kaliteyi birleştirerek üretim etkinliđini tanımladığı için üretimde yaygın olarak kullanılan bir metriktir. Toplam ekipman etkinliđi, kayıp türlerini hesaba katarak makine ve ekipmanların etkinliđini ve süreç iyileştirme alanlarını belirlemek için tasarlanan bir performans ölçüm aracıdır. Kayıplar, kaynakları emen ancak değer yaratmayan faaliyetlerdir. Kayıplar, kronik veya düzensiz olan üretim bozukluklarından

kaynaklanmaktadır. Kronik bozukluklar küçüktür ve gizlidir ve birkaç eşzamanlı nedenin sonucudur. Öte yandan düzensiz bozukluklar ise hızlı bir şekilde ortaya çıktıkları ve normal durumdan büyük sapmalara sahip oldukları için daha belirgindir (Muchiri ve Pintelon, 2008, s. 3519). Ekipmanın toplam performansını etkileyen potansiyel kayıplar altı ana kategoriye ayrılmıştır (Badiger ve Gandhinathan, 2008, s. 236). Bunlar kısaca aşağıda açıklanmıştır.

- **Ekipman arızası duruşları:** Ekipman arızaları/arıza kayıpları, hatalı ürünlerden kaynaklanan zaman kayıpları ve miktar kayıplarıdır.
- **Kurulum ve ayarlama duruşları:** Kurulum ve ayarlama kayıpları, bir ögenin üretimi sonrasında ekipman başka bir ögenin gereksinimlerini karşılayacak şekilde ayarlandığında ortaya çıkan kesinti ve kusurlu ürünlerden kaynaklanan zaman kayıplarıdır.
- **Küçük duruşlar:** Rölanti ve küçük duruş kayıpları, üretim geçici bir arıza nedeniyle kesintiye uğradığında veya bir makine rölantideyken meydana gelir.
- **Hız kayıpları:** Düşük hız kayıpları, ekipman tasarım hızı ile gerçek çalışma hızı arasındaki farkı ifade eder.
- **Başlangıç iskartaları:** Randıman kayıpları, üretimin erken aşamalarında makinenin çalıştırılmasından stabilizasyona kadar meydana gelen kayıplardır.
- **Üretim iskartaları:** Kalite kusurları ve yeniden işleme kayıpları, üretim ekipmanının arızalanmasından kaynaklanan kalite kayıplarıdır.

Toplam ekipman etkinliğinin amacı, burada bahsi geçen kayıpların teşhisidir. Bir üretim tesisi, altı büyük kaybı ortadan kaldırarak veya azaltarak toplam ekipman etkinliğini yükseltebilmektedir. Çizelge 2’de görüldüğü gibi, bu altı büyük kayıp, her biri iki öge olmak üzere üç kategoride sınıflandırılmaktadır (Mousavi-Nasab, Safari ve Hafezalkotob, 2020, s. 823). İlk iki kayıp, arıza zamanı kaybı olarak bilinir ve bir makinenin kullanılabilirliğini hesaplamak için kullanılır. Üçüncü ve dördüncü kayıp, performans verimliliğini belirleyen hız kayıplarıdır. Son iki kayıp ise, ürünlerdeki kusurlardan kaynaklanan kayıplar olarak kabul edilmektedir.

Çizelge 2. Altı Büyük Kayıp

Kayıp Kategorileri	Kayıp Tipleri	Örnekler
Kullanılabilirlik kayıpları	Ekipman arızaları	Takım arızaları, ekipman arızası, planlanmamış bakım, genel arızalar, güç kesintisi, vb.
	Kurulum ve ayarlama	Kurulum ve ayarlama, temizleme, ısınma süresi, planlı bakım, kalite denetimleri, ekipman-kalıp-aparat ve alet değişimleri, malzeme veya operatör eksikliği, iletişim toplantılarına harcanan süre, vb.
Performans kayıpları	Küçük duruşlar	Rölantide olma ve ufak duruşlar, yanlış beslemeler, malzeme sıkışmaları, tıkanmış ürün akışı, yanlış ayarlar, vb.
	Hız kayıpları	Düşük hız, operatör deneyimsizliği, başlatma ve kapatma, vb.
Kalite kayıpları	Başlangıç ıskartaları	Başlangıçtan stabil hale gelene kadar üretilen arızalı parçalar, vb.
	Üretim ıskartaları	Süreç hataları, hurdaya çıkarılmış ve yeniden işlenmiş parçalar, vb.

Kaynak: Mousavi-Nasab, S. H., Safari, J. and Hafezalkotob, A. (2020). Resource allocation based on overall equipment effectiveness using cooperative game. *Kybernetes*, 49 (3), 819-834. <https://doi.org/10.1108/K-09-2018-0491>

2.1.1.2. Toplam Ekipman Etkinliğinin Hesaplanması

Çizelge 3'te gösterildiği gibi, toplam ekipman etkinliğini hesaplamak için toplam ekipman çalışma süresini oluşturan unsurları kapsamlı bir şekilde tanımlamak gerekir. Toplam ekipman çalışma süresinin kapsamlı bir şekilde ayrıştırılması, üç temel endeksin; yani kullanılabilirlik, performans ve kalitenin türetilmesine ve ardından bu üç endeksi çarparak toplam ekipman etkinliğinin hesaplanmasına olanak tanır (Park ve Hur, 2020, s. 5).

Çizelge 3. Toplam Ekipman Etkinliği Yaklaşımına Göre Performans Ölçütlerinin Hesaplanması

Tanım	Açıklama	Toplam Ekipman Etkinliği Unsurları
A	Vardiya Süresi	Kullanılabilirlik $F = \frac{E}{C}$
B	Planlı Duruş Süresi	
C	Yükleme Süresi (A-B)	
D	Plansız Duruş Süresi	
E	Genel Çalışma Süresi (C-D)	
G	Üretim Miktarı	Performans $J = \frac{G}{I}$
H	Makine Kapasitesi (adet/dakika)	
I	Beklenen Üretim Miktarı (H*E)	
K	Hatalı Üretim Miktarı	Kalite $L = \frac{(G - K)}{G}$

Kaynak: Çelik, H. (2020). Ekipman etkinliğine farklı bir yaklaşım: Genel operasyon etkinliği. *Verimlilik Dergisi*, (4), 25-40. <https://doi.org/https://doi.org/10.51551/verimlilik.560600>

Ekipmanın kullanılabilirliğindeki kayıp, teknik veya diğer nedenlerle ekipman arızası durumunda ya da çalışma sırasında ekipmanın küçük kesintileri durumunda meydana gelen üretim kayıplarını içermektedir (Waqas vd., 2015, s. 213). Ekipmanın kullanılabilirliği Denklem 1 yardımıyla hesaplanmaktadır (Nakajima, 1988, s. 22). Yükleme süresi, vardiya süresinden planlı duruş süresinin çıkarılmasından sonra kalan süredir. Genel çalışma süresi ise vardiya süresinden plansız ve planlı duruş sürelerinin çıkarılması ile elde edilir.

$$\text{Ekipman Kullanılabilirliği} = \frac{\text{Genel Çalışma Süresi}}{\text{Yükleme Süresi}} \quad (1)$$

Performans, makinelerin günlük vardiyada parça üretim hızını gösterir. Bu ölçüt, ideal bir ortamda ekipmanın kapasitesine kıyasla üretilen gerçek parça miktarını dikkate alan nicel bir gösterge olarak tanımlanmaktadır (Hörmann, Bizubac ve Popa, 2019, s. 2). Ekipman performansındaki kayıp; standart altı malzeme, yol koşulları, operatörün verimsizliği, iş koşulları, eğitim koşulları ve bunun gibi nedenlerle çalışma sırasında ekipmanın hızındaki kaybı içermektedir (Waqas vd., 2015, s. 213). Ekipmanın performansı Denklem 2 yardımıyla hesaplanmaktadır (Nakajima, 1988, s. 24).

$$\text{Ekipman Performansı} = \frac{\text{Üretim Miktarı}}{\text{Beklenen Üretim Miktarı}} \quad (2)$$

Ekipman etkinliğinin kalite unsuru; hatalı ekipman kullanımı, ekipmanların uygun şekilde ayarlanamaması ve ekipman arızaları gibi faktörleri dikkate alarak, makine veya üretim hatları tarafından üretilen ürünlerin müşteri toleransları dahilinde ne sıklıkla kabul edilebilir seviyeleri karşıladığını değerlendirmek için kullanılmaktadır (Çelik, 2020, s. 31). Üretilen ürün şartnameye uygun olmadığında kalite kaybı olarak kabul edilmektedir. Ürünler standardı karşılamadığında eğer kusurlar giderilebilecekse bahsi geçen bu kusurları gidermek için yeniden işleme yapılır. Yeniden işleme için işgücü gerektiğinden işletmenin bu işlemi gerçekleştirebilmesi için ekstra bir maliyete katlanması gerekir. Eğer kusurlar giderilemeyecekse de üretilen ürün hurda kapsamına girmekte ve bahsi geçen bu malzemeler işletme için dezavantaj oluşturmaktadır (Sayuti vd., 2019, s. 3). Kalite oranı Denklem 3 yardımıyla hesaplanmaktadır (Nakajima, 1988, s. 25).

$$\text{Kalite Oranı} = \frac{(\text{Üretim miktarı} - \text{Hatalı üretim miktarı})}{\text{Üretim miktarı}} \quad (3)$$

Bu değerler hesap edildikten sonra, toplam ekipman etkinliği değeri Denklem 4 kullanılarak hesaplanabilir (Nakajima, 1988, s. 27).

$$\text{Toplam Ekipman Etkinliği} = \text{Kullanılabilirlik} * \text{Performans} * \text{Kalite Oranı} \quad (4)$$

Nakajima, toplam ekipman etkinliğinin hesaplanmasında kullanılan kullanılabilirlik, performans ve kalite endeklerine ilişkin dünya standartlarını belirlemiş ve kullanılabilirlik etkinliğinin %90'ın üzerinde, performans etkinliğinin %95'in üzerinde ve kalite etkinliğinin %99'un üzerinde olması gerektiğini ifade etmiştir. Bu üç alt kategorinin çarpılmasıyla toplam ekipman etkinliğinin dünya standartlarındaki performansının %85 olacağı hesaba katılabilir. Ancak toplam ekipman etkinliğinin dünya standartlarındaki performansının sektörlere bağlı olarak

değişiklik arz edeceği dikkatlerden kaçmamalıdır (Trattner, Hvam ve Haug, 2020, s. 2023).

Toplam ekipman etkinliği Çizelge 4'te gösterildiği gibi hesaplamadan elde edilen yüzdeye göre sınıflandırılarak açıklanabilir (Meidiana, Yakin ve Wijayanti, 2017, s. 14).

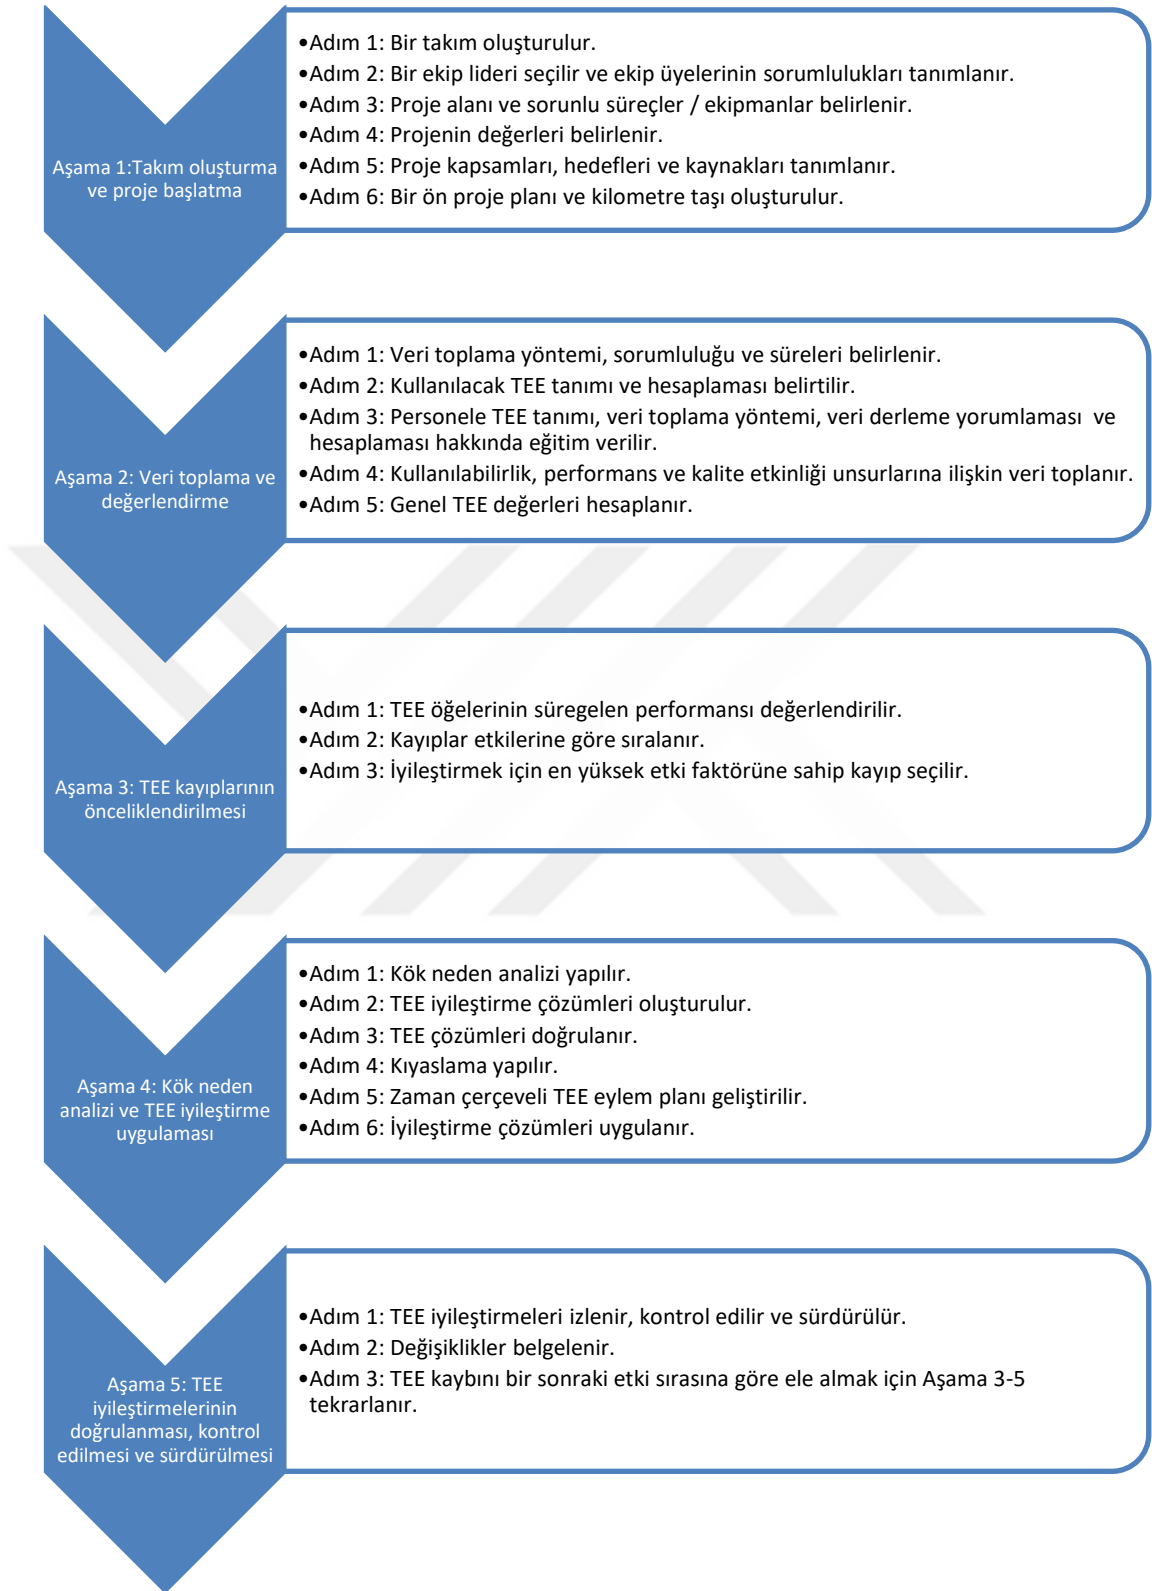
Çizelge 4. Toplam Ekipman Etkinliğinin Ölçümünde Kriterlerin Durumları

Toplam Ekipman Etkinliği Yüzdesi	Kriterler
%100'e eşit	İşletmenin toplam ekipman etkinliği mükemmeldir. Hizmet süresi oldukça hızlıdır ve üretimde duruş yoktur.
%85 - %100 aralığında	İşletmenin toplam ekipman etkinliği optimaldir ancak daha da iyileştirilebilir. Şirketler için uzun vadeli bir hedef olarak kullanılabilir.
%60 - %85 aralığında	İşletmenin toplam ekipman etkinliği orta düzeydedir. Daha fazla iyileştirme için işletmede geniş fırsatlar mevcuttur.
%40 - %60 aralığında	İşletmenin toplam ekipman etkinliği orta düzeydedir. Üretimde sık sık kesintiler meydana gelmektedir.
%40'ın altında	İşletmenin toplam ekipman etkinliği zayıftır. İşletmenin geliştirilmesi zordur. Kötü durumların nedenlerini bulmak için işletmede derinlemesine gözlem yapmak gerekmektedir.

Kaynak: Meidiana, C., Yakin, H. A. and Wijayanti, W. P. (2017). Household's willingness to accept waste separation for improvement of rural waste bank's effectivity. In F.-C. Mihai (Ed.), *Solid Waste Management in Rural Areas* (pp. 11-26). Rijeka, Croatia: InTech. <https://doi.org/10.5772/intechopen.69428>

Üreticiler, faaliyetlerinin hangi alanlarının en verimli olduğunu ve hangi alanlarında iyileştirmeler yapılması gerektiğini anlamak için makinalarının ve üretim hatlarının toplam ekipman etkinliği karşılaştırmalarını performans, kullanılabilirlik ve kalite ölçümleri yardımıyla yapabilirler. Bu değerlendirmeler aynı zamanda tüm tesisi kapsayacak şekilde genişletilebilir ve daha geniş ölçekte toplam ekipman etkinliği karşılaştırması yapılmasına olanak sağlar (Ercan, 2020, s. 29).

2.1.1.3. Toplam Ekipman Etkinliği Çerçevesi



Şekil 1. Entegre Bir Toplam Ekipman Etkinliği Çerçevesi

Kaynak: Cheah, C. K., Prakash, J. and Ong, K. S. (2020). An integrated OEE framework for structured productivity improvement in a semiconductor manufacturing facility. *International Journal of Productivity and Performance Management*, 69 (5), 1081-1105. <https://doi.org/10.1108/IJPPM-04-2019-0176>

Şekil 1’de entegre bir toplam ekipman etkinliği çerçevesi gösterilmiştir. Çerçeve, bir kıyaslama ve iyileştirme faktörü olarak toplam ekipman etkinliğinin temel özelliklerini içerecek şekilde tasarlanmıştır. Çerçevde beş aşama vardır. Her aşama, sırayla birbirine bağlanan iyileştirme adımlarından oluşmaktadır. Bu adımlar, uygulayıcıların toplam ekipman etkinliği projelerini yürütmeleri için sistematik bir rehber işlevi görmektedir (Cheah, Prakash ve Ong, 2020, s. 1088).

Toplam ekipman etkinliği uygulamasındaki önemli görevlerden biri veri toplamadır. Toplam ekipman etkinliği uygulamasının başarı oranı, elde edilen verilerin doğruluğuna bağlıdır. Bundan dolayı toplam ekipman etkinliğinin önceliğini doğru veri toplamak oluşturmaktadır. Olası bir hatalı veriye ilişkin veri analizi ve bu analiz üzerine alınacak karar, kaynak israfı ve verimsiz yatırımlar gibi istenmeyen sonuçlara yol açabilecektir. Veri toplama stratejileri, manuel ve otomatik yöntemler arasında geniş bir yelpazede değişmektedir. Günümüzde modernize edilmiş işletmeler haricindeki birçok küçük ve orta büyüklükteki işletmede kullanılan makineler veri toplamak için bir ara yüze sahip olmadığından dolayı veri toplama işlemi kâğıt formlar aracılığıyla manuel olarak gerçekleştirilebilmektedir. Manuel veri toplama yöntemi düşük teknoloji bir yaklaşımdır. Formlar aracılığıyla toplanan veri, analiz ve raporlama için elektronik tablolara aktarılmaktadır. Ancak bilinmelidir ki manuel olarak toplanan verilerle yapılacak analiz ve raporlama hem oldukça fazla zaman almakta hem de doğruluğu tartışılabilir olmaktadır. Bu nedenle, bu tür ekipmanlara sahip işletmelerde otomatik veri toplama sistemlerinin geliştirilmesi, bu tür zayıflıkların üstesinden gelmeye yardımcı olabilmektedir (Zhou, Wang ve Chua, 2020, s. 1413).

Ekipmanlara bağlı sensörler ile gerçekleştirilen otomatik veri toplama faaliyeti, yüksek teknoloji bir yöntemdir. Bu tip sistemler, bir duruşun başlangıç zamanını ve süresini otomatik olarak kaydeder ve operatörü sisteme kesinti nedeni hakkında bilgi sağlamaya yönlendirir. Otomatik veri toplama yöntemi, genellikle kesinti nedenleri listelerini oluşturmak, mevcut çalışma süresini programlamak ve belirli bir süre için otomatik bir toplam ekipman etkinliği değerinin hesaplamasını yapmak için fırsatlar sağlamaktadır. Sistemden çeşitli üretim performansı raporları ve performans sonuçlarının görselleştirilmesi de sağlanabilmektedir (Iannone ve Nenni, 2013, s. 42).

Toplam ekipman etkinliği, imalatçıların üretim sırasında işlemlerin sorunsuz ve verimli bir şekilde ilerlemesini sağlamak için kullanabilecekleri olağanüstü bir

araçtır. İnsan gözü, tek seferde sınırlı bir miktarda bilgiyi işleyebildiği için, toplam ekipman etkinliğini iyileştirmenin yollarını belirlemek zor olabilir. Bu zorluğu aşmak için günümüzde makine öğrenmesi yöntemleri kullanılmaya başlanmıştır (http-1). Varlığa göre, verim oranlarını, önleyici bakım doğruluğunu ve iş yüklerini iyileştirmek, artık makine öğrenmesi ile toplam ekipman etkinliğini birleştirerek mümkündür. Diğer metriklerle birleştirildiğinde, üretim performansını en çok ve en az etkileyen faktörleri bulmak mümkündür. Toplam ekipman etkinliği ve diğer veri kümelerini, yineleme yoluyla hızlı bir şekilde öğrenen makine öğrenmesi modellerine entegre etmek, günümüzde üretim zekası ve analitiğinin en hızlı büyüyen alanlarından biridir (Columbus, 2018). Bu veriler makine öğrenmesi modellerine entegre edilirse, etki hakkında hızlı bir şekilde bilgi edinmek ve gerekli önlemleri almak kolay olacaktır (Pariyani, 2018). Makine öğrenmesi yöntemlerini uygulayarak, süreçler sürekli olarak optimize edilebilmekte ve makine ve ekipman arızaları önceden tahmin edilebilmektedir.

2.1.1.4. Toplam Ekipman Etkinliğinden Türetilen Göstergeler

Orijinal toplam ekipman etkinliği yaklaşımına dayalı olarak, üretim ve montaj alanlarında Toplam Tesis Etkinliği (Overall Plant Effectiveness, OPE), Toplam Fabrika Etkinliği (Overall Factory Effectiveness, OFE), Genel Verim Etkinliği (Overall Throughput Effectiveness, OTE), Toplam Kaynak Etkinliği (Overall Resource Effectiveness, ORE), Toplam Hat Etkinliği (Overall Line Effectiveness, OLE), İmalat Hattının Toplam Ekipman Etkinliği (Overall Equipment Efficiency of a Manufacturing Line, OEEML), Üretim Ekipman Etkinliği (Production Equipment Effectiveness, PEE), Toplam Varlık Etkinliği (Overall Asset Effectiveness, OAE), Toplam Etkin Ekipman Performansı (Total Equipment Effectiveness Performance, TEEP) ve Küresel Süreç Etkinliği (Global Process Effectiveness, GPE) gibi çeşitli etkinlik ölçümleri kullanılmaktadır (Dobra ve Jósvai, 2022b, s. 143).

2.1.1.4.1. Toplam Tesis Etkinliği

Toplam tesis etkinliği, bir üretim sürecini etkileyen tüm değişkenleri ve adımları hesaba katar. Değer akışının uçtan uca bir hesabıdır. Toplam tesis etkinliğinin makine verilerini, makinelerin çevresinde olup bitenlere ilişkin bir açıklamayla

bütünleştirmesi çok önemlidir. Makine performansının yanı sıra insan eyleminin de bir temsilidir. Toplam tesis etkinliği ile toplam ekipman etkinliği arasındaki en büyük fark, toplam tesis etkinliğinin toplam ekipman etkinliği hesaplamalarına dahil edilmeyebilecek bağlantısız unsurları içermesidir. Bu, toplam tesis etkinliğinin bir üretim çalışmasındaki her ürün için geçerli olmayabilecek seçmeli prosedürler ve manuel süreçler gibi faaliyetleri içerdiği anlamına gelmektedir (Raj vd., 2021, s. 844). Toplam tesis etkinliği, basitçe Denklem 5'teki gibi hesaplanmaktadır (Muchiri ve Pintelon, 2008, s. 3528).

$$OPE = \frac{\text{Değerli çalışma süresi}}{\text{Toplam kullanılabilir süre}} \quad (5)$$

2.1.1.4.2. Toplam Fabrika Etkinliği

Toplam fabrika etkinliği, bir üretim sürecini oluşturmak için kurulan çeşitli üretim adımlarının veya makinelerin fabrika düzeyindeki etkinliğini ölçmek için kullanılmaktadır. Toplam ekipman etkinliği tek tek ekipmanlarda mükemmelliğe ulaşmakla ilgiliyken, toplam fabrika etkinliği farklı makineler ve süreçler arasındaki ilişkilerle ilgilidir. Toplam fabrika etkinliği, üretim sürecinin gerektirdiği birçok faaliyeti ve bilgi sistemini entegre etmeyi amaçlamaktadır. Bu nedenle toplam fabrika etkinliği, faaliyetleri, farklı makineler ve süreçler arasındaki ilişkileri birleştirmek, birçok bağımsız sistem ve alt sistemdeki bilgileri, kararları ve eylemleri entegre etmekle ilgili bir terimdir. Bununla birlikte, toplam fabrika etkinliği metriğinin geliştirme aşamasında olduğu ve simülasyon analizinin üretim sistemlerinin dinamik performansının incelenmesinde bugüne kadarki en güvenilir yöntem olarak kabul edildiği belirtilmektedir (Muchiri ve Pintelon, 2008, ss. 3523-3524).

2.1.1.4.3. Genel Verim Etkinliği

Genel verim etkinliği, fabrika düzeyindeki performansı ölçmede ve darboğaz tespiti ve gizli kapasitenin belirlenmesi gibi fabrika düzeyinde tanılamaların gerçekleştirilmesinde kullanılmaktadır. Genel verim etkinliği, fabrika düzeyindeki performans teşhislerinin tamamını otomatikleştirme ve dolayısıyla niceliksel olarak sürekli üretkenlik iyileştirmesi sağlama potansiyeline sahiptir (Muthiah ve Huang,

2007, s. 4753). Fabrika düzeyinde performans izleme ve teşhis, tüm üretim sistemi düzeninin "seri", "paralel", "montaj" ve "genişletme" dahil olmak üzere benzersiz alt sistemlere sınıflandırılmasıyla kolaylaştırılabilir. Çünkü birçok üretim süreci bu dört alt sistemin bileşiminden oluşmaktadır. Daha sonra bu alt sistemlerin her biri için genel üretim etkinliği ölçüsü türetilir (Muthiah, Huang ve Mahadevan, 2008, s. 811). Seri, paralel, montaj ve genişletme sistemleri için genel verim etkinliği ölçütü sırasıyla Denklem 6, Denklem 7, Denklem 8 ve Denklem 9 yardımıyla hesaplanmaktadır (Koçak, 2015).

$$OTE_{seri} = \frac{\min \left\{ \min_{i=1,2,\dots,n-1} \{ TEE_{(i)} * R_{th(i)} * \prod_{j=i+1}^n Q_{eff(j)} \}, TEE_{(n)} * R_{th(n)} \right\}}{\min_{i=1,2,\dots,n} \{ R_{th(i)} \}} \quad (6)$$

$$OTE_{paralel} = \frac{\sum_{i=1}^n (TEE_{(i)} * R_{th(i)})}{\sum_{i=1}^n R_{th(i)}} \quad (7)$$

$$OTE_{montaj} = \frac{\min \left\{ \min_{i=1,2,\dots,n} \left\{ TEE_{(i)} * \frac{R_{th(i)}}{k_{A(i)}} * Q_{eff(a)} \right\}, R_{th(a)} * TEE_{(a)} \right\}}{\min \left\{ \min_{i=1,2,\dots,n} \left\{ \frac{R_{th(i)}}{k_{A(i)}} \right\}, R_{th(a)} \right\}} \quad (8)$$

$$OTE_{genişletme} = \frac{\sum_{i=1}^n \min \left\{ R_{th(e)} * TEE_{(e)} * k_{E(i)} * Q_{eff(i)}, R_{th(i)} * TEE_{(i)} \right\}}{\sum_{i=1}^n \min \left\{ R_{th(e)} * k_{E(i)}, R_{th(i)} \right\}} \quad (9)$$

Denklemlerde n her bir alt süreçteki ekipman sayısını ifade etmektedir. $TEE_{(i)}$, i ekipmanının toplam ekipman etkinliği oranını, $TEE_{(a)}$, montaj tipi alt süreç içerisindeki ekipmanın toplam ekipman etkinliği oranını, $TEE_{(e)}$ genişleyen tip alt süreç içerisindeki ekipmanın toplam ekipman etkinliği oranını ve $TEE_{(n)}$ ise seri tip alt süreçteki en sonda bulunan ekipmanın toplam ekipman etkinliği oranını ifade etmektedir. $R_{th(i)}$ i ekipmanın birim zamandaki imalat miktarını; $R_{th(a)}$ montaj tipi alt süreç içerisindeki ekipmanın birim zamandaki imalat miktarını; $R_{th(e)}$ genişleyen tip alt süreç içerisindeki ekipmanın birim zamandaki imalat miktarını ve $R_{th(n)}$ ise seri tip alt süreçteki en sonda bulunan ekipmanın birim zamandaki imalat miktarını belirtmektedir. $Q_{eff(i)}$ i ekipmanın kalite oranını; $Q_{eff(a)}$ montaj tip alt sürecin kalite

oranını ifade etmektedir. $k_{A(i)}$ montaj tip alt süreçte i ekipmanından birleşilecek ekipmana giden parça sayısıdır. $k_{E(i)}$ ise ayrılan tip alt süreçte genişleyen durumdaki ekipmandan i ekipmanına giden parça sayısıdır.

2.1.1.4.4. Toplam Kaynak Etkinliği

Toplam kaynak etkinliği, bir makine veya süreç performansının toplam ekipman etkinliğinden daha kapsayıcı bir değerlendirmesini sağlamak amacıyla geliştirilmiş bir üretim performansı ölçüm sistemidir. Toplam kaynak etkinliği ile toplam ekipman etkinliği arasındaki temel fark, toplam kaynak etkinliğinin bir makine veya sürecin genel performansını sadece kullanılabilirlik, performans ve kaliteye dayalı olarak değil, aynı zamanda malzeme verimliliği, süreç maliyeti ve malzeme maliyeti değişimleri olmak üzere üç unsur açısından daha değerlendirmesidir. Bu üç unsurun toplam etkinlik değerlendirmesine entegre edilmesi, makine veya sürecin performansı üzerinde önemli bir etkiye sahip olabilecek diğer faktörlerin de izlenmesine yardımcı olmaktadır. Sonuç olarak, üretim veya süreç yöneticileri, süreçleri hakkında daha derin bir bilgi edinebilir ve buna dayanarak süreçlerinin yönetimi ve iyileştirilmesi için gereken eylemler hakkında daha iyi kararlar alabilirler. Toplam kaynak etkinliği basitçe Denklem 10'daki gibi hesaplanmaktadır (Garza-Reyes, 2015, ss. 510,511).

$$ORE = \frac{\text{Geri kazanılan yatırım tutarı}}{\text{Toplam yatırım tutarı}} \quad (10)$$

2.1.1.4.5. Toplam Hat Etkinliği

Bu yaklaşımda üretim sistemi, ürünün tamamlanmasına kadar geçen çeşitli süreç adımlarının bütünü olarak tanımlanmaktadır. Dolayısıyla hesaplama sırasında makinelerin doğrudan birbirine bağımlı olduğu dikkate alınmaktadır. (Lanza vd., 2013, s. 33).

2.1.1.4.6. İmalat Hattının Toplam Ekipman Etkinliği

İmalat hattının toplam ekipman etkinliği, makinelerin ayrı ayrı çalışmadığı ancak birbirlerinin performansını etkilediği bir üretim hattının gerçek verimliliğini tahmin etmeye yönelik bir yöntemdir. İmalat hattının toplam ekipman etkinliği, teorik ve fiili darboğazların konumuna ilişkin verimsizliklerin yerinin belirlenmesine olanak tanımaktadır (Franzini vd., 2021). İmalat hattının toplam ekipman etkinliği, bir üretim hattında süreç aşamaları arasında stokların bulunduğunu ve üretim değerinin bu stokların seviyesine bağlı olduğunu düşünmektedir. Bir üretim hattında imalat hattının toplam ekipman etkinliği ne kadar düşük olursa, hattaki darboğaz makinenin önünde o kadar fazla stok birikme eğilimi meydana gelir. Bununla birlikte, imalat hattının toplam ekipman etkinliği yüksek olduğunda, süreç daha iyi akar, malzemeler daha iyi akar ve hattaki stok düşük olma eğilimindedir (Rabelo, Batocchio ve Sato, 2020, s. 37). İmalat hattının toplam ekipman etkinliği basitçe Denklem 11'deki gibi hesaplanmaktadır.

$$OEEML = \frac{\text{Son Makinenin Çıktı Miktarı}}{(\text{Hat Yükleme Süresi} / \text{Darboğaz Makinesinin İdeal Çevrim Süresi})} \quad (11)$$

2.1.1.4.7. Üretim Ekipman Etkinliği

Üretim ekipman etkinliği, yapı itibarı ile toplam ekipman etkinliği ile benzerlik göstermektedir. Her iki ölçüt arasındaki temel fark, toplam etkinlikte yer alan öğelere ağırlıkların tahsis edilmesidir. Toplam ekipman etkinliğindeki üç unsurun aynı ağırlığa sahip olduğu temel varsayımının aksine, üretim ekipman etkinliği bu üç unsurun ağırlıklarının birbirinden farklı olduğunu ifade etmektedir. Üretim ekipman etkinliği kesikli üretim ve sürekli üretim operasyonları için farklı bir şekilde hesaplanmaktadır.

Kesikli tip üretim operasyonları için üretim ekipman etkinliği ölçütü Denklem 12'deki gibi hesaplanmaktadır. Denklemde A kullanılabilirliği, E performans etkinliğini, Q kalite etkinliğini ve k_i üretim ekipman etkinliği unsurlarının ağırlıklarını ifade etmektedir. $i = 1 \dots 3$ için unsurlara ilişkin k_i sıfırdan farklı olmak üzere sıfır ile bir aralığında bir değer almaktadır ($0 < k_i \leq 1$) ve unsurların ağırlıklarının toplamı bire eşittir ($\sum_{i=1}^3 k_i = 1$).

$$PEE_{kesikli} = (A^{k_1}) * (E^{k_2}) * (Q^{k_3}) \quad (12)$$

Sürekli üretim operasyonları için üretim ekipman etkinliği ölçütü Denklem 13'teki gibi hesaplanmaktadır. Denklemde A_1 kullanılabilirliği, A_2 kazanım oranını, E performans etkinliğini, QR kalite oranlarını, PSE ürün destek etkinliğini, OU işletme kullanımını ve k_i üretim ekipman etkinliği unsurlarının ağırlıklarını ifade etmektedir. $i = 1 \dots 6$ için unsurlara ilişkin k_i sıfırdan farklı olmak üzere sıfır ile bir aralığında bir değer almaktadır ($0 < k_i \leq 1$) ve unsurların ağırlıklarının toplamı bire eşittir ($\sum_{i=1}^6 k_i = 1$). Toplam etkin ekipman performansı metodolojisine göre karşılaştırma yapılacak olursa; A_1 kullanım oranına, A_2 kullanılabilirliğe, E performansa, QR kalite oranına karşılık gelmektedir. PSE işlem kayıplarını dikkate alır ve kaliteli işlem süresi ile işlem kaybı süresi arasındaki farkın kaliteli işlem süresine oranlanması ile elde edilir. OU ise talepten kaynaklanan kayıpları dikkate alır ve kaliteli işlem süresi ile talebin olmadığı zaman arasındaki farkın kaliteli işlem süresine oranlanması ile elde edilir (Muchiri ve Pintelon, 2008, ss. 3522-3523; Raouf, 1994, ss. 50-51).

$$PEE_{sürekli} = (A_1)^{k_1} * (A_2)^{k_1} * (E)^{k_3} * (QR)^{k_4} * (PSE)^{k_5} * (OU)^{k_6} \quad (13)$$

2.1.1.4.8. Toplam Varlık Etkinliği

Toplam varlık etkinliği, toplam ekipman etkinliği aracından geliştirilmiş bir ölçüm aracıdır. Terimin alan yazındaki uygulamaları sınırlı olmasına rağmen, endüstrilerde yaygın olarak uygulanmaktadır. Genel üretim süreciyle ilişkili tüm kayıpları tanımlamak ve ölçmek için uygulanır. Toplam varlık etkinliği üretim kayıplarını çıktıya göre ölçmektedir (Muchiri ve Pintelon, 2008, ss. 3524-3525). Toplam varlık etkinliği basitçe Denklem 14'teki gibi hesaplanmaktadır.

$$OAE = \frac{Mevcut\ tonaj}{Teorik\ tonaj} \quad (14)$$

2.1.1.4.9. Toplam Etkin Ekipman Performansı

Toplam ekipman etkinliği ve toplam etkin ekipman performansı arasındaki fark, üretimin gerçek kapasitesi hakkında bir fikir veren kullanım oranıdır. Toplam etkin ekipman performansı, kapasite kullanımında tesisin dolu olmasından ve üretimin çizelgelenmemesinden kaynaklanan çizelgeleme kayıplarını kabul etmektedir. Dolayısıyla bu iki kayıp altı büyük kayba eklenerek sekiz büyük kayıp haline gelmiştir (Hung, Li ve Cheng, 2022, s. 4). Toplam etkin ekipman performansı, fabrikanın açıldığı dönemde bir üretim biriminin ne kadar iyi performans gösterdiğini ortaya koymaktadır. Toplam etkin ekipman performansı aracı toplam ekipman etkinliği aracını kapsamakta ve planlı bakımın ekipman verimliliği üzerindeki etkisi hakkında bilgi sağlamaktadır. Toplam ekipman etkinliği atölye düzeyinde kullanılırken, toplam etkin ekipman performansı üretim yöneticileri tarafından bakım stratejilerini tasarlamak için kullanılmaktadır (Hatipoğlu ve Akar, 2022, s. 503). Toplam etkin ekipman performansı Denklem 15'teki gibi hesaplanmaktadır. Kullanım oranı yükleme süresinin vardiya süresine oranlanmasıyla elde edilmektedir.

$$TEEP = \text{Kullanım Oranı} \times TEE \quad (15)$$

2.1.1.4.10. Küresel Süreç Etkinliği

Küresel süreç etkinliği, ekipmanın kullanılabilirliği, üretim hızı (performansı), kalite düzeyi ve önceden tanımlanmış bir üretim çizelgesine uyma becerisine dayalı olarak süreç etkinliği performansını değerlendirmeyi amaçlamaktadır. Küresel süreç etkinliği Denklem 16'daki gibi hesaplanmaktadır. Çizelgeye uyum oranı, üretim çizelgesinin ne kadarının etkin bir şekilde yapıldığı hakkında bilgi vermektedir (Oliveira vd., 2019, ss. 1618-1619).

$$GPE = \text{Kullanılabilirlik} * \text{Performans} * \text{Kalite} * \text{Çizelgeye Uyum Oranı} \quad (16)$$

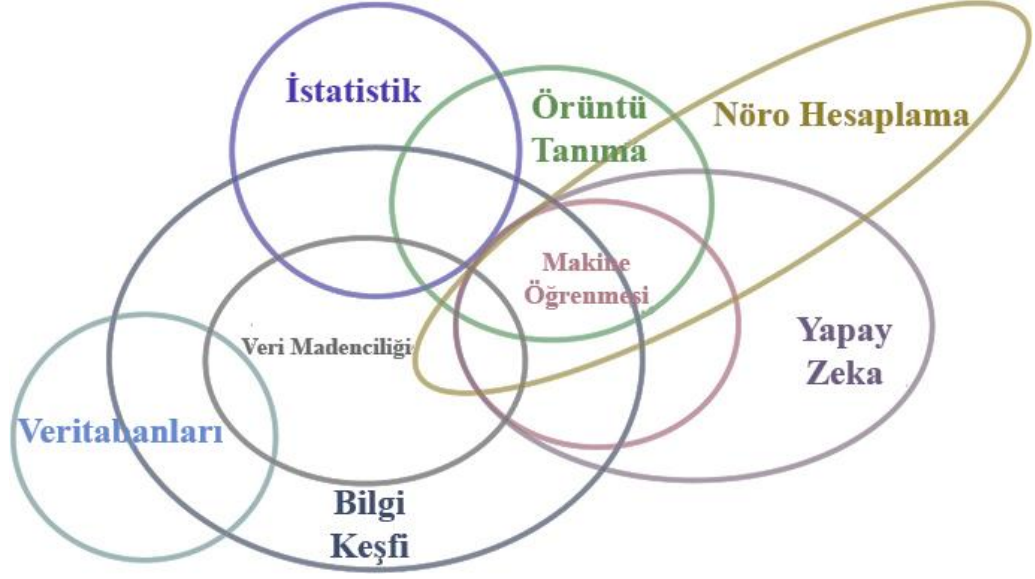
2.1.2. Makine Öğrenmesi

Bir problemi çözen basit ve iyi tanımlanmış bir denkleme sahip olmak çok idealdir. Ancak, çoğu gerçek hayat problemi için bunu yapmak genellikle zordur. Bu tür zorluklar, hesaplamanın insan aklının nasıl olduğunu simüle etme yönünde ilerlemesinin temel nedenidir. Bilgi teknolojilerinin hızlı gelişimi işletme, sağlık, bilim ve benzeri çeşitli disiplinlerde büyük veri kümelerinin oluşmasına yol açmıştır. Bu veri kümeleri, bilinçli kararlar vermek ve bilinçli tahminler yapmak için insanlar tarafından makul bir zaman aralığında işlenemeyecek kadar büyüktür. Bu nedenle, kalıpları belirlemek ve modeller oluşturmak için çeşitli algoritmalar ve araçlar geliştirilmiştir. Bunların başında makine öğrenmesi yaklaşımı gelmektedir (Selvaratnam ve Koodali, 2020, s. 1).

Arthur Samuel, oyun ve örüntü tanıma algoritmalarına yapay zekâ katarak, bilgisayarın deneyimlerden öğrenmesini sağlamak için 1959'da makine öğrenmesi terimini ortaya atmıştır. Makine öğrenmesinin temel hedefleri, veriler tarafından yönlendirilen tahminler veya kararlardır. Makine öğrenmesi, doğru şekilde iletişim kurması güç olan zorluklar için güçlü bir modelleme aracı haline gelmiştir (Houssein vd., 2020, s. 5).

İnsanlar ve bilgisayarlar arasındaki temel farklardan biri, insanların geçmiş deneyimlerden öğrenmeleri gerçeğinde yatmaktadır. Buna karşın bilgisayarlar, ne yapacakları belirtilip programlandıktan sonra talimatları takip etmek üzere işlev görürler. Günümüzde makine öğrenmesi ile bilgisayarların deneyimlerden öğrenmesi sağlanabilmektedir. Bilgisayarlar için deneyimler veri olarak ifade edilmektedir. Makine öğrenmesi, tüm bu verilerden anlam çıkarma faaliyetini yerine getirmektedir (Smiti, 2020, s. 2).

Makine öğrenmesi, gerçek dünya verilerindeki kalıpları ortaya çıkarmak için makinelerin öğrenme yeteneklerini geliştirmektedir (Aydın, 2022). İlk makine öğrenmesi seminerinin 1980 yazında Amerika Birleşik Devletleri Carnegie Mellon Üniversitesi'nde yapılmasından bu yana, makine öğrenmesi bağımsız bir disiplin haline gelmiş ve hızla şekillenmeye başlamıştır. Şekil 2'de gösterildiği gibi, makine öğrenmesi aynı zamanda bilgisayar bilimindeki güncel gündem konuları ile yakın ilişkileri olan bir çapraz disiplindir (Y. Liu vd., 2020, s. 437).



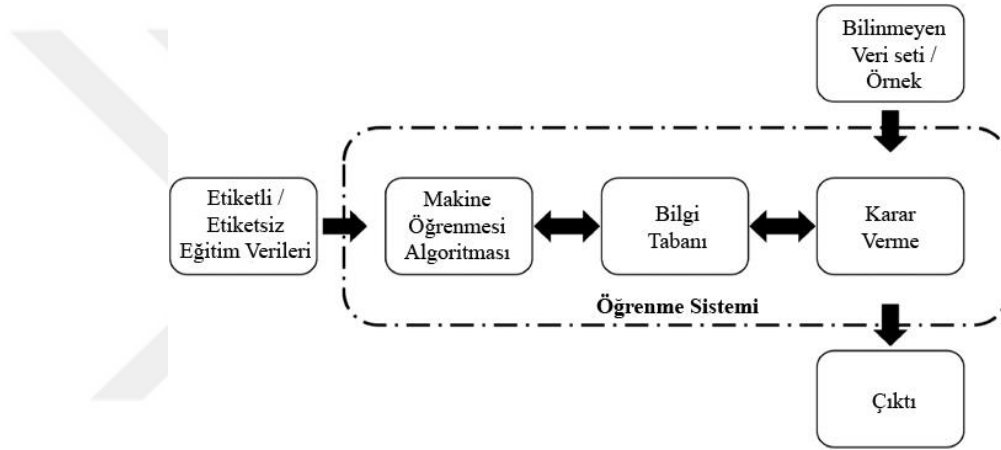
Şekil 2. Makine Öğrenmesi ve Bilgisayar Bilimindeki Güncel Gündem Konuları Arasındaki İlişkiler

Kaynak: Liu, Y., Guo, B., Zou, X., Li, Y. and Shi, S. (2020). Machine learning assisted materials design and discovery for rechargeable batteries. *Energy Storage Materials*, 31, 434-450. <https://doi.org/10.1016/j.ensm.2020.06.033>

Makine öğrenmesi ve yapay zekâ birbirinin yerine kullanılsa da makine öğrenmesi yapay zekanın bir alt kümesidir. Yapay zekâ, bilgisayarların ve makinelerin karar alma ve insan gibi davranma becerisiyle ilgilenir. Ancak, bu kararlardan bazıları öğrenmeyi gerektirmeyebilir (Osarogiagbon vd., 2021, s. 368). Makine öğrenmesi ise, belirli bir görevi, açık talimatlar kullanmadan, verilerden tahmin edici bir model oluşturmak için kalıplara ve çıkarıma dayanarak gerçekleştiren bir dizi istatistiksel ve hesaplama tekniğini ifade eder (Coorey vd., 2020, s. 4). Genellikle, verilerden otomatik ve doğrudan öğrenebilen algoritmalar geliştirmeyi amaçlayan makine öğrenmesi, büyük ve dağınık veri kümeleri arasında model eşleştirmeye ve korelasyona odaklanan bir yapay zekâ alt kümesidir. Stokastik olarak hareket eden bu yaklaşım, çeşitli öğrenme görevlerini tanımlayarak veriler aracılığıyla ilişkiler kurmaya çalışan çok sayıda algoritma tarafından temsil edilir (Sacco vd., 2020, s. 2).

Makine öğrenmesi algoritmaları, karar kurallarını bilinen girdi-çıkı ilişkileri örnekleriyle eğiterek türetmenin aşamalı ve uyarlamalı süreci olarak tanımlanabilir (Wen vd., 2020, s. 464). Özetle bu modeller, sağlanan girdi-çıkı örneklerinden temeldeki sistem dinamiklerini öğrenir ve yeni parametrelerin sonucunu tahmin eder (Zimmerling vd., 2019, s. 2). Makine öğrenmesi sisteminin genel bir konfigürasyonu

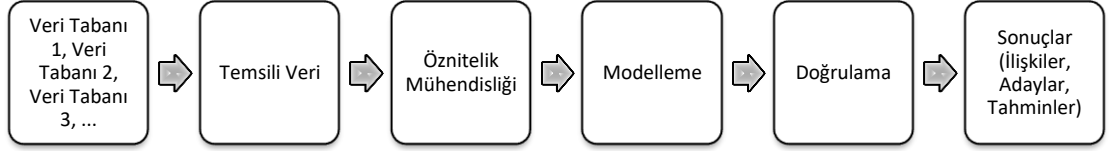
Şekil 3'te gösterilmiştir. Etiketlenmiş veya etiketlenmemiş eğitim verileri, farklı kaynaklardan toplanarak makine öğrenmesi sistemine girdi olarak verilir. Öğrenme sisteminin bilgi tabanı, organizasyon tarafından alınacak kararları dikkate alarak uygun bir makine öğrenmesi algoritmasının kullanılmasına karar verir (Sharma vd., 2020, s. 3). Makine öğrenmesi çalışmalarında eldeki problemi çözmek için doğru algoritmaları seçmek çok önemlidir (van Klompenburg, Kassahun ve Catal, 2020, s. 1). Sonuçları yorumlamanın hızı ve zorluğu gibi birçok faktörden dolayı, uygun makine öğrenmesi algoritmasını belirlemek oldukça kritik bir süreçtir (Alkinani, Al-Hameedi ve Dunn-Norman, 2020, s. 7).



Şekil 3. Bir Makine Öğrenmesi Sistem Konfigürasyonu

Kaynak: Sharma, R., Kamble, S. S., Gunasekaran, A., Kumar, V. and Kumar, A. (2020). A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. *Computers and Operations Research*, 104926. <https://doi.org/10.1016/j.cor.2020.104926>

Makine öğrenmesinin bir probleme başarılı bir şekilde uygulanması, birçok kapsamlı adımı içermektedir. Makine öğrenmesi yaklaşımlarını kullanmak için temel prosedürler arasında veri toplama, öznitelik mühendisliği, modelleme, doğrulama ve nihai sonuçların üretilmesi yer alır. Makine öğrenmesi yaklaşımlarını kullanmak için temel prosedürler Şekil 4'te gösterilmiştir.



Şekil 4. Makine Öğrenmesi Yaklaşımlarını Kullanmak için Temel Prosedürler

Kaynak: Zhang, L., He, M. and Shao, S. (2020). Machine learning for halide perovskite materials. *Nano Energy*, 78, 105380. <https://doi.org/10.1016/j.nanoen.2020.105380>

Makine öğrenmesi sürecinin ilk adımı, veri toplama ve ön işlemedir. Veri toplama aşamasında, araştırmacılar deneylerden, hesaplamalardan ve çeşitli mevcut veri tabanlarından faydalı bilgiler çıkarır ve bunları veri optimizasyonu sonrasında birleşik bir formatta temsil eder. Veri kümesi kalitesini ve sonraki makine öğrenmesi sonuçlarını iyileştirmek için veri temizliği gereklidir. Bir veri kümesindeki eksik değerler kaldırılmalı veya düzeltilmelidir. Makine öğrenmesi sonuçlarını iyileştirmek için aykırı değerler ve gürültü uygun bir şekilde ele alınmalıdır. Veri ön işleminin bir diğer önemli yönü, öznetelik mühendisliğidir. Öznetelik mühendisliği, gereksiz öznetelikleri kaldırmak ve uygun yapı-öznetelik ilişkilerinin kurulmasına yardımcı olmak için gereklidir. Bir araştırmacı, ele aldığı çalışmada fazlalık öznetelikler mevcutsa korunacak bir öznetelik alt kümesine karar vermelidir. Modelleme prosedürü, uygun algoritmaların seçimini, verilerin eğitimini ve testini ve müteakip doğru tahminleri içerir (Zhang, He ve Shao, 2020, s. 3; Q. Zhang vd., 2020, s. 3).

Üretim sürecinin sorunsuz bir şekilde ilerlediğinden ve ürünlerin hedeflenen kalite standardına ulaştığından emin olmak için üretim hatlarının düzenli olarak izlenmesi son derece önemlidir. Makine öğrenmesi yaklaşımında yüksek doğruluk elde etmek, bazen elde edilmesi zor, pahalı veya pratik olmayan büyük miktarda veri gerektirmektedir. Artan dijitalleşme ile birlikte, imalat sanayinde her gün muazzam miktarlarda ham veri üretilmektedir. Bu bağlamda, üretilen veri setleri, kaliteyi artırmak, riskleri değerlendirmek ve maliyetten tasarruf etmek amacıyla makine öğrenimi teknikleri tarafından kullanılır (Dogan ve Birant, 2021, s. 1; Kang, Catal ve Tekinerdogan, 2020, s. 1).

Makine öğrenmesinin temel yeteneği, büyük ölçekli bir veri kümesinden girdi ve çıktı değişkenlerinin karmaşık dahili korelasyonlarını algılayıp yeniden yapılandırabilmesidir. Bu nedenle, prensip olarak, bir yapının şekli ile yapının performansı arasındaki korelasyonlar da makine öğrenmesi ile elde edilebilir. Ayrıca,

korelasyonlar oluşturulduktan sonra yapının şekline karşılık gelen optimizasyon kolaylıkla gerçekleştirilebilir. Bu fikir, araştırmacılara makine öğrenmesini farklı fiziksel sistemlerdeki çeşitli optimizasyon problemlerine uygulama konusunda ilham vermiştir (F. Liu vd., 2020, s. 1).

Kontrollü bir şekilde toplanan verilerden ve yeni bilgi işlem teknolojilerinden yararlanan makine öğrenmesi, neredeyse tüm alanlarda birçok dikkat çekici uygulamayla ayrı bir alan bulmuştur (Chebila, 2020, s. 1). Veri yoğun makine öğrenmesi yöntemleri, özellikle bilim, teknoloji ve ticaret alanlarında yoğun bir şekilde kullanılmaktadır. Makine öğrenmesi yöntemleri, sağlık hizmetleri, üretim, eğitim, finansal modelleme, güvenlik ve pazarlama gibi birçok alanda kanıta dayalı karar alma imkanı sunmaktadır (Jordan ve Mitchell, 2015, s. 255).

2.1.2.1. Makine Öğrenmesi Türleri

Bir makine öğrenmesi modeli, araştırma problemine ve araştırma sorularına bağlı olarak betimleyici veya tahmine dayalı olabilir. Toplanan verilerden bilgi elde etmek ve neler olduğunu açıklamak için betimleyici modeller kullanılırken, geleceğe ilişkin tahminlerde bulunmak için tahmine dayalı modeller kullanılır (van Klompenburg, Kassahun ve Catal, 2020, s. 1). Makine öğrenmesinde pek çok algoritma vardır. Bunlar, öğrenme türlerine göre denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme olmak üzere dört farklı kategoriye ayrılmaktadır. Yapılan tez çalışması kapsamında bu öğrenme türlerinden denetimli öğrenme algoritmaları öznitelik seçimi ve toplam ekipman etkinliği oranının tahmininde kullanılmıştır.

Çizelge 5, makine öğrenmesi kategorilerinin temel kavramlarını özetlemekte ve aralarındaki farkları açıklamaktadır (Messaoud vd., 2020, s. 11).

Çizelge 5. Makine Öğrenmesi Kategorileri Arasındaki Farklar

Makine Öğrenmesi Kategorisi	Girdi / Çıktı	Amaç	Avantajlar	Dezavantajlar
Denetimli Öğrenme	Etiketli veri / Bilinen çıktı	Tahminde bulunmak için parametreleri öğrenmek.	Daha fazla doğruluğa sahiptir. Sınıf sayısını belirleyebilme yeteneğine sahiptir.	Eğitim aşamasında daha fazla hesaplama süresine gereksinim duyar. Gerçek zamanlı olarak gerçekleşmez.
Denetimsiz Öğrenme	Etiketlenmemiş veri / Bilinmeyen çıktı	Gözlenen değişkenler ve tahmin edilecek değişkenler arasında ayırım yapmadan verilerin dağılımını göstermek.	Daha az karmaşıklığa sahiptir. Gerçek zamanlı olarak gerçekleşir.	Daha az doğruluğa sahiptir. Analiz sonuçları kesinleştirilemez.
Yarı Denetimli Öğrenme	Az sayıda etiketli veri ile daha fazla sayıda etiketlenmemiş veri / Az sayıda bilinen çıktı	Tahminde bulunmak için parametreleri öğrenmek. Gözlenen değişkenler ve tahmin edilecek değişkenler arasında ayırım yapmadan verilerin dağılımını göstermek.	Büyük boyutlu bir etiketli veri seti gerektirmez. Yüksek düzeyde doğruluğa sahiptir.	Etiketli verileri elde etmek zordur. Eğitim aşamasında daha fazla hesaplama süresine gereksinim duyar.
Pekiştirmeli Öğrenme	Ödüller / Eylemler	Geri bildirim eylemler olduğu durumlarda ödülleri kullanarak sıralı karar almaya yönlendiren deneyimlere odaklanmayı öğrenmek.	İnsan müdahalesi yoktur. Yüksek düzeyde doğruluğa sahiptir.	Eğitim aşamasında daha fazla hesaplama süresine gereksinim duyar.

Kaynak: Messaoud, S., Bradai, A., Bukhari, S. H. R., Qung, P. T. A., Ahmed, O. B. and Atri, M. (2020). A survey on machine learning in internet of things: Algorithms, strategies, and applications. *Internet of Things*, 100314. <https://doi.org/10.1016/j.iot.2020.100314>

Şekil 5'te ise makine öğrenmesi algoritmalarının kategorilerine göre kullanım alanları gösterilmiştir (Sigamani, 2020, s. 399).



Şekil 5. Makine Öğrenmesi

Kaynak: Sigamani, R. M. S. (2020). Adoption of machine learning with adaptive approach for securing CPS. In P. Ganapathi and D. Shanmugapriya (Eds.), *Handbook of research on machine and deep learning applications for cyber security* (pp. 388-415). Hershey PA, USA: IGI Global. <https://doi.org/10.4018/978-1-5225-9611-0.ch018>

2.1.2.1.1. Denetimli Öğrenme

Denetimli öğrenme, verilen bir bilgi kümesinden (özniteliklerden) gelen cevabı (veya makine öğrenmesindeki etiketi) tahmin etmenin bir yöntemidir (Nakaura vd., 2020, s. 1). Denetimli öğrenmede, bir dizi girdi (öznitelik)/hedef çifti sağlanır ve görev, her girdi için, sağlanan hedefe mümkün olduğunca yakın tahmini bir çıktıya sahip olan bir fonksiyon bulmaktır. Böyle bir fonksiyonu bulmaya öğrenme denir ve bir fonksiyon ailesi üzerinden yapılan bir optimizasyon problemi ile çözülür (Bengio, Lodi ve Prouvost, 2020, s. 3). Tahmine dayalı modelleme çalışmalarının birçoğu, denetimli makine öğrenmesini içerir. Denetimli öğrenme sınıflandırma ve regresyon problemleri olmak üzere iki alt başlıkta değerlendirilebilir (Cox vd., 2020, s. 11). Sınıflandırma algoritmaları yeni girdi verilerinin hangi kategoriye ait olduğunu belirlemeye çalışırken, regresyon algoritmaları ise değişkenler arasındaki modellemeyi ele almaktadır (Y. Zhang vd., 2020, s. 5).

2.1.2.1.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, bir cevabın verilmediği ve belirli bir veri kümesi için benzer nesnelere bir araya getirme işlemidir (Nakaura vd., 2020, s. 1). Denetimsiz makine öğrenmesi hangi veri noktalarının girdilere, hangilerinin çıktılara atıfta bulunduğu bilinmeyen veri kümeleri için kullanılmaktadır. Denetimsiz öğrenmenin görevi, veri noktalarını gruplamanın en iyi yolunu bulmak ve bunların nasıl ilişkilendirilebileceğine dair kurallar geliştirmektir (Canhoto, 2020, s. 3). Denetimsiz öğrenmede gerçekleştirilmesi istenen görevler için hedefler yoktur, bunun yerine gözlemlenen rastgele değişkenlerin ortak dağılımının bazı özellikleri yakalanmaya çalışılır. Bu görevler arasında boyutsallık azaltma ve kümeleme bulunmaktadır (Bengio, Lodi ve Prouvost, 2020, s. 4). Kümeleme algoritmaları, sınıflandırmaya benzer girdi verileri için benzer özelliklere sahip kümeyi bulmayı hedefler. Aralarındaki fark ise, sınıflandırma algoritmalarında kategori sayısı bilinirken kümelemede kategori sayısının bilinmemesidir. Boyutsallık azaltma algoritmalarının amacı, özelliklerin fazlalığını ortadan kaldırmak için orijinal yüksek boyutlu özellik uzayını temsil etmek için daha düşük boyutlu bir alt uzay kullanmaktır (Y. Zhang vd., 2020, s. 5).

2.1.2.1.3. Yarı Denetimli Öğrenme

Yarı denetimli öğrenme tekniğinin adı, denetimli ve denetimsiz yöntemlerin sakıncalarının üstesinden gelmek için hem etiketli hem de etiketlenmemiş verilerin öğrenme sürecinde kullanılması gerçeğinden gelmektedir. Bu teknik, etiketli bir eğitim seti üzerinde eğitilecek denetimli bir öğrenme algoritmasına ihtiyaç duyar, ardından denetimli öğrenme için eski etiketli eğitim setine eklenen yeni etiketli örnekler oluşturmak için denetimsiz bir öğrenme algoritması uygulanır (Smiti, 2020, s. 4).

2.1.2.1.4. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, belirsizlik altında karar verme aşamasında nasıl hareket edileceği veya nasıl davranılacağı hakkında bilgi edinmek için kullanılmaktadır (Sun, Burton ve Huang, 2021, s. 1). Pekiştirmeli öğrenme, belirli eylem türlerinin diğerlerinden daha iyi sonuçlar ürettiği problemlere uygulanmaktadır. Analist, bilgisayara bir veri seti, bir hedef ve ayrıca aldığı eylemler için ödüller (veya cezalar)

verir. Algoritmanın görevi, bu hedefe ulaşmak için en iyi eylem kombinasyonunu bulmaktır. Bunu başarmak için, algoritma olası veri kombinasyonlarını sıralar ve genel hedefi en üst düzeye çıkaran modelleri bulmak için farklı kombinasyonların ödülleri analiz eder (Canhoto, 2020, s. 3).

2.1.2.2. Makine Öğrenmesi Programlama Dilleri

Makine öğrenmesi, bilim ve mühendislikte birçok alanda gelişimi yönlendirmektedir. Basit ve verimli bir programlama dili, makine öğrenmesinin çeşitli alanlardaki uygulamalarına hız kazandırabilir. Günümüzde, makine öğrenmesi algoritmalarını geliştirmek için en yaygın olarak kullanılan programlama dilleri aşağıdaki gibi sıralanabilir (Gao vd., 2020, ss. 1-2).

- **MATLAB:** MATLAB, sayısal analiz, matris hesaplama ve bilimsel veri görselleştirme fonksiyonlarını, kullanımı kolay bir şekilde birleştirmektedir. Tez çalışmasında MATLAB programlama dili kullanılmıştır. MATLAB, MathWorks tarafından geliştirilen bir programlama dilidir. MathWorks, makine öğrenmesi için çeşitli paketler satmakta ve bu ürünler veri analizi için yüksek kaliteli algoritmalar sağlamaktadır. Bu paketlerin tümü, makine öğrenmesi için güçlü sistemler üretmek üzere birbirleriyle ve diğer MATLAB fonksiyonlarıyla entegre edilebilir (Paluszek ve Thomas, 2020, s. 25). Bu programlama dilinin büyük ölçekli görevleri yavaş bir hızda çözebilme, yüksek bellek ve hesaplama gücü gereksinimlerine sahip olma ve ticari olma gibi dezavantajları bulunmaktadır.
- **Python:** Python etkili bir programlama dilidir ve birçok bilimsel hesaplama uygulamasında kullanılmaktadır. Python programlama dilinde kullanılan algoritmalar paketler halinde sunulmakta ve çoğunlukla öğrenme süreci gerektirmemektedir. Bu programlama dilinin büyük ölçekli görevleri yavaş bir hızda çözebilme ve yüksek bellek ve hesaplama gücü gereksinimlerine sahip olma gibi dezavantajları bulunmaktadır.
- **C / C++:** C / C ++, makine öğrenmesindeki ana programlama dillerinden biridir. Yüksek verimlilik ve güçlü taşınabilirliğe sahiptir. Bununla birlikte, C / C ++ ile makine öğrenmesi algoritmalarının geliştirilmesi ve uygulanması, C / C ++ öğrenme ve kullanmadaki zorluklar nedeniyle kolay değildir.

- **Go:** Go, basit, güvenilir ve verimli yazılım oluşturmayı kolaylaştıran açık kaynaklı bir programlama dilidir. Go sözdizimsel olarak C'ye benzemektedir. Geliştiriciler, başka dillerde yazılmış kütüphanelerden faydalanmak yerine, doğrudan Go'da yazılmış makine öğrenmesi kütüphaneleri çalışabilir. Ancak, Go'da yazılmış mevcut makine öğrenmesi kütüphaneleri yeterince kapsamlı değildir.
- **R:** R, istatistiksel hesaplamalar gerçekleştirmek ve grafikler oluşturmak için kullanılan bir dil ve ortamdır. R, çok çeşitli istatistiksel ve grafiksel teknikler sağlar ve oldukça genişletilebilirdir. R'nin avantajlarından biri, kolayca yüksek kaliteli çizimler üretebilmesidir. Buna karşın, R, büyük verileri analiz ederken verileri kısıtlı bir sistem belleğinde (RAM) depolar.
- **Julia:** Julia basit, hızlı ve açık kaynaklı bir programlama dilidir. Julia'nın verimliliği, neredeyse C / C ++ gibi statik programlama dilleriyle karşılaştırılabilir seviyededir. Julia'nın kullanımı R, Python ve MATLAB kadar kolaydır.

2.1.3. Öznitelik Seçimi

İşletmelerin ekipmanlarından ve operasyonlarından gelen verilerin artan kullanılabilirliği, veri analitiğinin kullanılmasını sağlamaktadır. Teknoloji ve bilgi biliminin gelişmesiyle birlikte veriler hem sayısal olarak hızla büyümekte hem de artan bir boyuta sahip olmaktadır. Bu devasa veriler, insanlık için birçok yararlı bilgi içermekte ve geçmişi ortaya çıkarmak ve geleceğe bakmak için olanak sağlamaktadır (Qu vd., 2023, s. 1). Yüksek boyut, yüksek hesaplama maliyetine ve model yorumlama zorluğuna neden olmakta ve tahmin modellerinin genelleme yeteneğini bozmaktadır. Bu nedenle, model eğitilmeden önce öznitelik seçimi yapmak gerekir (Wang, Hu ve Liu, 2023, s. 1).

Makine öğrenmesinin temel bir konusu olan öznitelik seçimi, özellikle tahmin uygulamalarında yoğun olarak kullanılmaktadır. Katkıda bulunan ve bilgilendirici özniteliklerin seçimi, makine öğrenmesi tekniklerinin çalışma verimliliğini artırmak için gereklidir (Pasha ve Mohamed, 2022, s. 2). Öznitelik seçimi yardımıyla, etkili bir öznitelik alt kümesi belirlemek için tüm özniteliklerin içerisinde gereksiz, ilgisiz ve gürültülü öznitelikler çıkarılmaktadır (Wu vd., 2023, s. 1). Öznitelik seçiminde genel

amaç, öznitelik sayısından bağımsız olarak mümkün olan en iyi tahmin performansı elde etmek için en uygun öznitelik kümesini belirlemektir (Akman vd., 2023, s. 2).

2.1.3.1. Öznitelik Seçim Yöntemleri

Veri analizinde, her birinin güçlü ve zayıf yönleri olan çeşitli öznitelik seçim yöntemleri kullanılabilir. Bir öznitelik seçiciyi karakterize eden temel yönlerden biri, eğitim verilerine örnek ekleyerek veya çıkararak meydana gelen bozulmalara karşı gösterdikleri kararlılıktır (da Costa, de Lima ve Barbosa, 2022, s. 1).

Öznitelik seçim yöntemleri genellikle filtreler, gömülü yöntemler ve sarmalayıcılar olmak üzere üç kategoriye ayrılmaktadır. Filtreler, özniteliklerin önemini bağımlılığa, mesafe ölçümüne veya öznitelik puanına göre sıralar ve ardından en iyiye yakın öznitelik alt kümesi olarak daha yüksek sıralamaya sahip öznitelikleri seçer. Filtreler, öğrenme algoritmalarından bağımsızdır ve hızlı çalışır. Gömülü yöntemler, modelin kendisini oluştururken istatistiksel öğrenme modelinin performansına en iyi katkıda bulunan öznitelik alt kümesini belirler. Sarmalayıcılar ise regresör gibi bir istatistiksel öğrenci içerir ve istatistiksel öğrencinin performansını kullanarak öznitelik alt kümesi uzayını arar (Tsanas, 2022, s. 2; Yao, Hu ve Wang, 2022, s. 3).

Çalışmada öznitelik seçim yöntemi olarak geriye doğru eleme, ileri doğru seçim, adımsal seçim, korelasyon tabanlı öznitelik seçim, genetik algoritma, rastgele orman, ekstra ağaç, ridge regresyon, lasso regresyon ve elastik net yöntemlerinden faydalanılmıştır.

2.1.3.1.1. Geriye Doğru Eleme

Geriye doğru eleme, tüm aday özniteliklerden oluşan tam bir modelle başlar. Önceden belirlenmiş bir durdurma kuralı yerine getirilene kadar öznitelikler sırayla modelden elenir. Eleme sürecinin belirli bir adımında, özet ölçütte elenmesi en küçük düşüşe neden olan değişken elenir. Olası özet ölçütler sapma veya R^2 'dir. En yaygın durdurma kuralı, modelde kalan tüm özniteliklerin önceden belirlenmiş bir anlamlılık düzeyini karşılamasıdır (Austin ve Tu, 2004, s. 1139).

2.1.3.1.2. İleriye Doğru Seçim

İleriye doğru seçimde model başlangıçta hiçbir öznitelik içermez. Önceden tanımlanmış bir durdurma kuralı yerine getirilene kadar öznitelikler sırayla modele eklenir. Seçim sürecinin belirli bir adımında, eklenmesi özet ölçütte en büyük artışa neden olan öznitelik modele eklenir. Tipik bir durdurma kuralı, eklenen herhangi bir özneliğin önceden tanımlanmış bir anlamlılık düzeyini karşılamaması durumunda modele başka bir değişken eklenmemesidir (Austin ve Tu, 2004, s. 1139).

2.1.3.1.3. Adımsal Seçim

Adımsal seçim, ileriye doğru seçim ile geriye doğru eleme yöntemlerinin bir kombinasyonudur. Temel olarak ileriye doğru çalışır, ancak öznitelik seçim sürecinin her adımında bir öznitelik modele eklendikten sonra, bir geriye doğru bir eleme sürecinden geçebilir. Geriye doğru eleme işlemi, halihazırda seçilmiş olan özniteliklerden herhangi birinin gereksiz hale geldiği tespit edilirse gerçekleştirilir (Petersson, Klingvall ve Holmberg, 2009, s. 436).

2.1.3.1.4. Korelasyon Tabanlı Öznitelik Seçim Algoritması

Korelasyon tabanlı öznitelik seçim algoritması, öznitelik alt kümelerinin değerini değerlendirmek için korelasyon tabanlı bir ölçüm kullanır. Bu yöntemle göre iyi öznitelik alt kümeleri, sınıfla yüksek oranda korelasyon gösteren ancak birbirleriyle korelasyon göstermeyen öznitelikler içerir. Yöntem, sınıfla yüksek korelasyona sahip ve birbirleriyle düşük korelasyona sahip öznitelikleri içeren alt kümelere yüksek değerler atar. Bu şekilde, alakasız ve gereksiz öznitelikler içeren alt kümeler kötü öznitelik alt kümeleri olarak değerlendirilir (Liu ve Schumann, 2005, s. 1101).

2.1.3.1.5. Genetik Algoritma

Genetik algoritma, kromozomlar olarak adlandırılan bireysel çözüm yapılarından oluşan bir popülasyon üretir. Uyum, çaprazlama ve mutasyona bağlı olarak ebeveynleri seçerek, daha yüksek uyumluluğa sahip yavrular yinelemeli olarak üretilir. Bu yöntem, öznitelik seçim sürecini yönlendirmek için tahmin edici performansını amaç fonksiyonu olarak kullanır (Sun vd., 2023, s. 5). Özetle genetik

algoritmanın temel amacı, herhangi bir problemin çözümünde uygulanabilecek tüm çözüm alternatiflerinin arasından en iyisini seçmektir (Çifçi, Kaleli ve Günal, 2018, s. 426).

2.1.3.1.6. Rastgele Orman

Rastgele orman, özniteliklerin önem puanına dayalı olarak öznitelik sayısını azaltır. Rastgele orman, rastgele gözlemler ve rastgele değişkenler seçip bunları birleştirerek çeşitli karar ağaçları oluşturan bir topluluk tekniğidir. Ardından, her bir karar ağacı tarafından üretilen oylar toplanır ve böylece değişkenlerin tahmin edilen olasılığı ve özniteliklerin önem puanı hesaplanır. En yüksek önem puanına sahip öznitelikler genellikle seçilen öznitelikler olarak kabul edilir ve diğer öznitelikler göz ardı edilir (Naseri vd., 2022, s. 12).

2.1.3.1.7. Ekstra Ağaç Algoritması

Ekstra ağaç algoritmasında, her ağaç bir alt veri kümesini temsil edene kadar veri kümesi üzerinde yinelemeli olarak bir ağaç kümesi oluşturulur. Ağaçlardaki düğümler veri kümesinin öznitelikleri, yapraklar ise belirli bir sınıfa ait örnekleri temsil eder. Ağaçlar, düğümlerin bölünmesiyle oluşturulur ve bilgi kazanımı teorisine dayanarak hedefle en çok ilgili olan öznitelikler önce bölünür. Bu şekilde, ağaçlar oluşturulduktan sonra, kökten yapraklara doğru düğümler sıralanarak (yaprak düğümleri hariç tutularak) hedef için önem sırasına göre sıralanmış öznitelik dizisi elde edilir. Öznitelikler sıralandıktan sonra, tüm veri setinde bir düğüme ulaşan örneklerin oranı düğümün saflığı ile ağırlıklandırılarak özelliğin önemi hesaplanır (Xing vd., 2019, s. 9).

2.1.3.1.8. Ridge Regresyonu

Ridge regresyonu, regresyon katsayılarının tahminini gerçek durumla daha tutarlı ve daha güvenilir hale getirmek için en küçük kareler yönteminin yanlılığını ve bilgilerin bir kısmını tanıtan, geliştirilmiş bir en küçük kareler tahmin yöntemidir (Zhao vd., 2022, s. 7). Ridge regresyonu, verileri çok değişkenli neden-sonuç ilişkisine

dayalı olarak analiz eden istatistiksel tabanlı bir öznitelik seçim yöntemidir (Toğaçar, Ergen ve Cömert, 2020a, s. 4; 2020b, s. 3).

2.1.3.1.9. Lasso Regresyonu

Lasso regresyonu, en iyi öznitelikleri belirlemek için maliyet fonksiyonunda cezalandırılmış bir faktör olarak ağırlık katsayısının mutlak değerini kullanır. Alakasız girdi özniteliklerine sıfır ağırlık ve ilgili özniteliklere sıfır olmayan bir ağırlık atayarak en iyi öznitelikleri seçer (Fathima vd., 2022, s. 995).

2.1.3.1.10. Elastik Net

Elastik net, yüksek boyutlu öznitelik seçim problemlerini çözmek için tasarlanan ve bünyesinde ridge regresyon ve lasso regresyon modellerini birleştiren doğrusal bir regresyon modelidir. Elastik net, ridge ve lasso cezaları arasında bir uzlaşmayı temsil etmektedir. Elastik net cezası, bu iki cezanın doğrusal bir kombinasyonu olarak yazılır. Lasso ceza terimi, ortaya çıkan modelin parametre tahminlerinde seyrekliği teşvik etme görevi görürken, ridge terimi, bir gruplama etkisi uygulayan ilişkili özniteliklerin parametre tahminlerinin ortalamasını alma fonksiyonu görür. Bu nedenle elastik net hem büzülme hem de otomatik öznitelik seçimini gerçekleştirir. Kullanıcıların tercihlerine ve altta yatan problemin özniteliklerine bağlı olarak, elastik net cezası, lasso veya ridge cezalarına daha fazla ağırlık verecek şekilde sorunsuz bir şekilde ayarlanabilir. Ceza 0 ile 1 arasında değer almaktadır. Ceza sıfıra eşitse elastik net ridge fonksiyonu, bire eşit ise de lasso fonksiyonu görür (Amini ve Hu, 2021, s. 3; Bai vd., 2023, s. 1; Marafino, John Boscardin ve Adams Dudley, 2015, s. 115).

2.1.3.2. Doğrulama Yöntemi

Çapraz doğrulama prosedürü, makine öğrenmesi modelleriyle kullanılan örnek bir bölümlenme stratejisidir. Çapraz doğrulama, aşırı uydurma problemini önler ve bias ve/veya varyansa göre tahmini iyileştirir (Almaghrabi, Xu ve Yang, 2021, s. 7). Sınırlı bir veri kümesine sahip bir ağın başarısını değerlendirmek için çapraz doğrulama kullanılır. Amaç, modelin pratikte çalışacağı doğruluğu belirlemektir. Çapraz

doğrulama, eğitim sırasında kullanılmayan verileri kullanarak model performansını tahmin etme yeteneği sağlar. K-kat çapraz doğrulama yöntemi, çapraz doğrulama için yaygın olarak kullanılır (Gunes vd., 2022, s. 5).

K-kat çapraz doğrulama, veri setini rastgele iki alt bölüme, yani eğitim ve test veri setine bölen bir yöntemdir. Çapraz doğrulamada veri seti K gruba ayrılır. Bu gruplardan biri test seti olarak ayrılırken geriye kalan gruplar (K-1 adet grup) ise eğitim seti olarak kullanılır. K-kat çapraz doğrulama yönteminde, eğitim ve test veri setleri değiştirilerek tüm süreç K kez tekrarlanır ve ayrıca çeşitli hata tahmin istatistiksel araçlarına dayalı olarak minimum hata elde edilerek en iyi model seçilir (Saud vd., 2020, s. 6). Böylece, tüm eğitim setinin her örneği bir kez test edilerek, genel çapraz doğrulama doğruluğu, tüm veri setinin ortalaması olur (Keskin vd., 2022, s. 169). Bir regresyon modeli için geleneksel bir K-kat doğrulama prosedüründe, regresyon modelinin tahmin hatası, çapraz doğrulama yinelemelerinin tüm katlarının tahmin hatalarının ortalaması alınarak değerlendirilir (Wang vd., 2022, s. 4).

2.1.3.3. Eğitim Yöntemi

Çalışmada regresyon modelinin eğitilmesi için çoklu doğrusal regresyon yönteminden faydalanılmıştır. Yöntem, hedef değişken ile bir veya daha fazla öngörücü değişken arasındaki doğrusal ilişkiyi çıkaran bir tür doğrusal regresyondur. Bu yöntem, bağımlı değişkeni etkileyen her değişkenin girdisini değerlendirir (Lap vd., 2023, s. 4).

2.1.3.4. Performans Değerlendirme Ölçütleri

Geliştirilen modellerin tahmin performansını değerlendirmek için birçok performans değerlendirme ölçütü kullanılmaktadır. Çalışmada, test aşamasında model performansını değerlendirmek için ortalama karesel hata (Mean Squared Error-MSE) ve belirlilik katsayısı (R^2) performans ölçütlerinden faydalanılmıştır.

MSE, tahmin edilen ve gerçek değerler arasındaki farkların karelerinin ortalaması olarak ifade edilir (Fletcher vd., 2022, s. 4). MSE değerinin sıfıra yakın olması, modelin performansının iyi olduğunu gösterir (Adak ve Duralioğlu, 2023, s. 46).

R^2 değeri, [0,1] aralığında değerlere sahip bir regresyon modelinde bağımlı değişken için bağımsız değişken(ler) tarafından açıklanan varyans oranını ölçen bir uyum iyiliği ölçüsüdür ve bu nedenle modelin görülmeyen veri örneklerini ne kadar iyi tahmin ettiğini gösterir. Burada 0 gözlenen varyansın olmadığını, 1 ise bağımsız değişken(ler)in hareketiyle bağımlı değişkendeki varyansın %100 olduğunu ifade eder (Verma vd., 2022, s. 7).

2.1.4. Derin Öğrenme

Son yıllarda oldukça popüler hale gelen derin öğrenme, hemen hemen her alanda yüksek başarı elde eden etkili bir yöntemdir. Derin öğrenme, zaman serisi analizi, doğal dil işleme ve görüntü sınıflandırma gibi birçok veri işleme alanında önemli adımlar atılmasına olanak sağlamaktadır (Calp, 2021, s. 252; Savian, Elahi ve Tillo, 2020, s. 259). Derin öğrenme, süreci hızlandırmak ve işlem adımlarındaki doğruluğu sağlamak amacıyla, verilerdeki karmaşık kalıpları ve veriler arasındaki etkileşimleri otomatik olarak algılayıp analiz edebilmektedir (Sakarya ve Yılmaz, 2019, s. 106).

Son yıllarda, derin öğrenme büyük veri setlerini daha soyut bir temsile indirgeme potansiyelini göstermiş ve birçok akıllı teknoloji sisteminin kalbi olan tahmin uygulamaları için oldukça uygun hale gelmiştir. Çoğu derin öğrenme algoritması, verilerin bir bloktan diğerine aktığı bir dizi gömülü blok üzerinde çalışır. Bu şekilde, veri setindeki bilgilerin daha yoğun bir temsilini öğrenir ve nihayetinde karar verme sürecine katkıda bulunur. Algoritmalar, genellikle doğrusal veya doğrusal olmayan işlemlerle gömülü blok dizilerinden oluşur (Kumar ve Jayadev, 2020, ss. 79-80).

Derin öğrenme, bir işlemi tanımlan örnekler aracılığıyla öğrenebilen ve çok katmanlı modellerden oluşan sinir ağlarının çalışma ilkelerine dayanan bir makine öğrenmesi yöntemidir (Bayraktaroğlu ve Adıgüzel, 2020, s. 308). Derin öğrenme, verilere tamamen bağlı olmayıp, eksik, düzensiz, kısmen hatalı veya gürültülü veriyi başarıyla değerlendirebilmektedir. Derin öğrenme, karmaşık ilişkileri öğrenebilmekte, genelledebilmekte ve bu sayede daha önce hiç karşılaşmadığı sorulara kabul edilebilir bir hata düzeyiyle cevap bulabilmektedir (Önder ve Hasgül Kuvat, 2009, s. 63). Buradan hareketle derin öğrenme, karmaşık problemler için yüksek boyutlu verileri

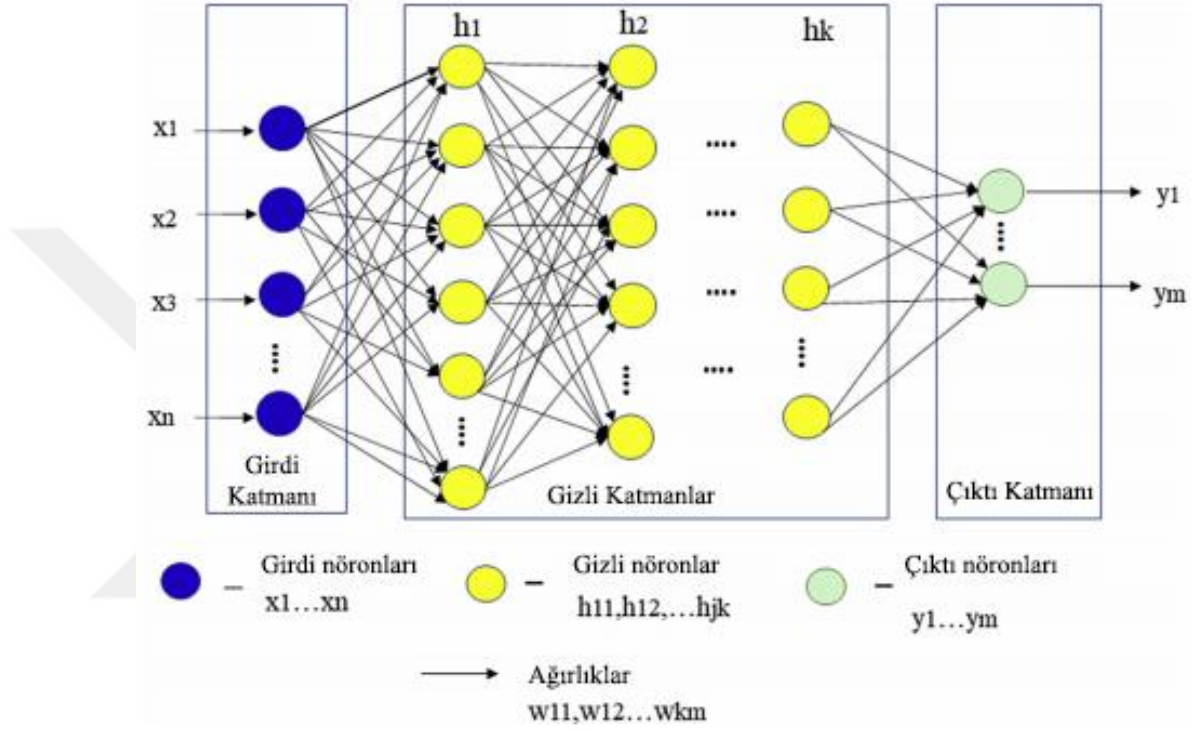
işlemede insan beyninin mekanizmasını taklit eden bir makine öğrenmesi fonksiyonu olarak ifade edilebilir. İnsan beyni, daha düşük seviyelerde basit özelliklere ve daha yüksek seviyelerde daha soyut özelliklere sahip çoklu temsil seviyelerine sahiptir. Benzer şekilde derin öğrenme, alt düzeylerdeki bilgileri temsil eden ilk katmanlara ve soyut bir formatta bilgiyi temsil eden son katmanlara sahip birden çok gizli katmandan oluşur. Derin öğrenme modelleri birbirini takip eden hiyerarşik katmanlar biçimindedir. Bu yapılarda, alt düzey tabakalar için çıktı, üst düzey tabakalar için girdi oluşturur. Sinir ağı, ne kadar derinlemesine olursa, nöronlar tarafından daha karmaşık özellikleri tanıma kapasitesine sahip olabilir. Çünkü bu ağlar, bir önceki katmandaki özellikleri tekrar tekrar yeniden birleştirerek karmaşık özellikleri ortaya çıkarabilir (Akgün vd., 2020, s. 292; Potluri, Ahmed ve Diedrich, 2020, s. 206).

Derin öğrenmenin en önemli avantajı, karmaşık özellikleri doğrudan ham verilerden öğrenme yeteneğidir. Bu, makine öğrenmesi teknikleri gibi manuel olarak çıkarılan özelliklere bağlı olmayan bir sistem inşa etme özgürlüğü verir. Derin öğrenme, makine öğrenmesi için derin sinir ağı modellerinin oluşturulmasına odaklanan bir alanı ifade eder. Büyük veri üzerinde karmaşık problemleri çözebilmek için güçlü hesaplamalı donanım gücüne sahip olmak gerekir. Teknoloji alanındaki hızlı değişim ve dönüşüm, donanım sektöründe birçok yeniliğe yol açmış ve derin öğrenme, zaman içinde artan doğrulukla giderek daha karmaşık problemleri çözebilir hale gelmiştir (Akgün vd., 2020, s. 292; Mohapatra, Swarnkar ve Das, 2021, s. 27).

Derin öğrenme, doğrusal olmayan işlem birimi katmanlarının avantajlarını takip etmektedir. Derin öğrenmede sonraki katman, önceki katmanın çıktısını girdi olarak almaktadır. Derin öğrenme tekniğinde, veriler, birden fazla özellik seviyesinde öğrenilebilir. En üst düzey özellikler, düşük düzeyli özelliklerden türetilir, böylece hiyerarşik bir temsil oluşturulur. Derin öğrenme yöntemleri genel olarak yapay sinir ağlarına yönelik olarak geliştirilmesine rağmen yapay sinir ağlarına kıyasla daha fazla gizli nöron ve katmana sahiptir (Calp, 2021, s. 252).

İleri beslemeli sinir ağları, üçten fazla gizli katmana sahip olduğunda derin sinir ağı olarak adlandırılmaktadır (Guo vd., 2019, s. 158). Derin terimi, sinir ağındaki gizli katmanların sayısını ifade etmek için kullanılır. Derin sinir ağının mimarisi Şekil 6'da gösterilmiştir (Nisha ve Meeral, 2021, s. 248). Şekilde görülebileceği gibi, derin sinir ağlarının temel model oluşumu sırasıyla bir girdi katmanı, çoklu gizli katmanlar ve bir çıktı katmanı içerir. Girdi verileri derin sinir ağlarına aktarıldığında, çıktı

değerleri ağ katmanları boyunca sıralı olarak hesaplanır. Her katmanda, bir sonraki katmandaki her birimin çıktı değerlerini içeren giriş vektörü, ağırlıklı katmanı elde etmek için mevcut katmandaki her bir birimin ağırlık vektörü ile çarpılır. Daha sonra, katmana karşılık gelen çıktı değerlerini hesaplamak için bir aktivasyon fonksiyonu kullanılır (Kose vd., 2021, s. 22).



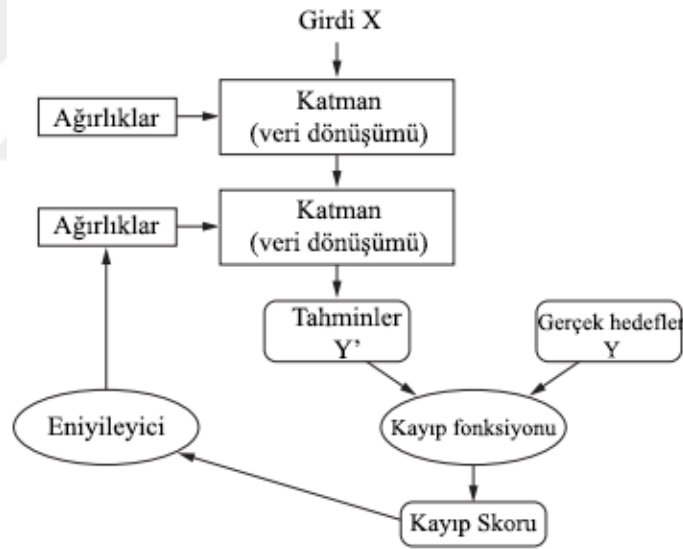
Şekil 6. Derin Sinir Ağlarının Temel Yapısı

Kaynak: Nisha, S. S. and Meeral, M. N. (2021). Applications of deep learning in biomedical engineering. In V. E. Balas, B. K. Mishra and R. Kumar (Eds.), *Handbook of deep learning in biomedical engineering* (pp. 245-270). London, UK: Elsevier. <https://doi.org/10.1016/B978-0-12-823014-5.00008-9>

Derin bir sinir ağı modelini, deneysel bilgileri öğrenip depolayabilen devasa bir paralel dağıtılmış işlemci olarak görmek mümkündür. Bilgi derin sinir ağları sistemi tarafından alınır ve ardından makinenin kendi kendine öğrenme yetenekleri olarak adlandırılan bir öğrenme süreci bağlamında modelin yapısı aracılığıyla gönderilir. Ağ sistemi ve mimarisinde ağırlıklar olarak da bilinen internöron bağlantı kuvvetleri, bilgileri depolamak için kullanılır. Eğitim sırasında, ağdaki tüm nöron birimlerindeki aktivasyon fonksiyonlarının ağırlıklarını değiştirmek için bir öğrenme algoritması kullanılır. Diğer bir deyişle, öğrenme algoritması, her eğitim

iterasyonunda, tüm ağırlıkları girdi ve çıktı verilerine göre ayarlayarak en iyi veya daha iyi performansı elde etmeye çalışır (Kose vd., 2021, s. 23).

Derin sinir ağları, bir veya birden fazla algılayıcıyı birbirine bağlayarak etkileşimlerini beynin bileşenlerini (nöronlar) taklit etmeyi amaçlayan bir öğrenme algoritmasıdır. Nöronlar, birbirine bağlı yığılmış katmanlar halinde düzenlenir, parametreleri geri yayılım yoluyla mevcut verilere dayanarak öğrenir. Katman sayısı ve nöron sayısı, bir modelin karmaşıklığını belirler. Bu bağlamda, model seçimi aşamasında ağırlık doğruluğu ile karmaşıklığı arasında en iyi dengeyi bulmak önemlidir. Son zamanlarda, karmaşık ve derin ağların aşırı öğrenme eğilimini azaltmak amacıyla yeni aktivasyon fonksiyonları, optimizasyon teknikleri ve düzenleme yöntemleri geliştirilerek bu araştırma alanında birçok ilerleme kaydedilmiştir. Bu gelişmeler, bu yöntemlerin giderek farklılaşan ve zorlaşan gerçek dünya problemlerine başarıyla uygulanmasına imkân vermektedir (Ponta vd., 2019, s. 174).



Şekil 7. Derin Öğrenme

Kaynak: Chollet, F. (2019). *Python ile derin öğrenme*. Ankara: Buzdağı Yayınevi.

Derin sinir ağları; katmanlar, girdi ve hedef veriler, kayıp fonksiyonu ve eniyileme algoritmasından oluşmakta olup bahsi geçen bileşenler arasındaki ilişki Şekil 7’de gösterilmiştir. Sinir ağlarının çıktısını denetlemek için beklenen çıktı ile ağırlık çıktısının arasındaki farkı ölçmek gerekir. Bu işlem, ağırlık kayıp fonksiyonu tarafınca yapılır. Kayıp fonksiyonu ağırlık çıktısı ile beklenen çıktı arasındaki farkı

puanlar ve bir girdi için ağı performansının ne kadar iyi olduğunu saptar. Derin öğrenmenin kritik noktası, bu puanı geri bildirim sinyali olarak kullanarak mevcut girdi için kaybı azaltacak yönde ağırlık matrisini güncellemektir. Bu güncelleme işlemi geriye yayılım diye adlandırılan ve derin öğrenmenin ana algoritmasını kullanan eniyileme algoritmalarının görevidir. Ağırlık matrisine başlangıçta rastgele değerler atandığından, sinir ağıları küçük ayarlamalar yapmak durumundadır. Bunun sonucunda çıktı beklenene çok uzak olacağından kayıp puanı görece çok yüksek olacaktır. Ağ, her örneği işlediğinde ağırlıklar güncellenecek ve kayıp puanı azalacaktır. Öğrenme döngüsü olarak adlandırılan bu süreç defalarca kez tekrar edildiğinde kayıp fonksiyonu en düşük değerine ulaşacaktır (Chollet, 2019, ss. 10-12).

Kayıp fonksiyonu, bir derin öğrenme modelinin doğru bir şekilde öğrenip öğrenmediğini anlamak için kullanılan bir ölçüttür. Yani bir derin öğrenme modelinde gerçekleştirilen her yinelemede öğrenme sürecinin iyileşip iyileşmediğini anlamak için kayıp fonksiyonu değerine bakılır. Bir derin sinir ağıının kayıp fonksiyonu, ağı çıktısını temel gerçeğe karşılaştırmaktadır. Yani kayıp fonksiyonu hedeften gelen kaybı ölçmekte olup Denklem 17'deki gibi gösterilebilir. Denklemde e_i hatayı, y_i hedef (ölçülen) değeri, \hat{y}_i ise eğitilmiş modelin tahmini değerini ifade etmektedir (El-Amir ve Hamdy, 2020, ss. 316-318).

$$e_i = y_i - \hat{y}_i \quad (17)$$

Tez çalışmasında kurulacak derin öğrenme modellerinin etkinliğini değerlendirmek için Ortalama Karesel Hata (MSE), Ortalama Hata Kare Kökü (RMSE), Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hatası (MAPE), Korelasyon Katsayısı (R) ve Belirlilik Katsayısı (R^2) performans ölçütlerinden faydalanılmıştır. MSE, RMSE, MAE, MAPE, R ve R^2 performans ölçütleri sırasıyla Denklem 18, Denklem 19, Denklem 20, Denklem 21, Denklem 22 ve Denklem 23'te gösterilen formüllerle hesaplanmaktadır (Fagundez vd., 2021, s. 5; Hosseinzadeh vd., 2018, s. 265; Pauletto vd., 2020, s. 724; Shehadeh vd., 2021, s. 14).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (18)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (19)$$

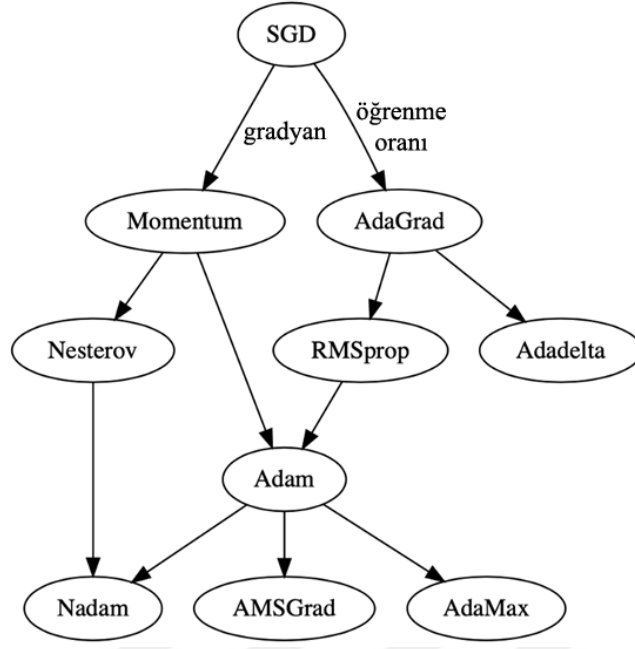
$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (20)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \quad (21)$$

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y}_i)(\hat{y}_i - \bar{\hat{y}}_i)}{\sqrt{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)^2}} \quad (22)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (23)$$

Derin öğrenme uygulamalarında öğrenme işleminin sağlıklı bir şekilde sonuçlanması için kayıp fonksiyonunun minimize edilmesi gerekir. Kayıp fonksiyonunun minimizasyonu işlemi eniyileme algoritmaları kullanılarak gerçekleştirilmektedir. Buradan hareketle eniyileme algoritmaları, ağıın ürettiği çıktı değeri ile gerçek değer arasındaki farkı minimize etmek amacıyla kullanılan yöntemlerdir (Ser ve Bati, 2019, s. 410). Derin öğrenmede kullanılan gradyan inişi eniyileme algoritmalarının evrimsel haritası Şekil 8'de gösterilmiştir (Seyyarer vd., 2020, s. 12). Bunlardan en çok kullanılanlar ise Adam eniyileyicisi ile RMSprop eniyileyicisidir (Yalçın, 2021, ss. 72-73).



Şekil 8. Eniyileme Algoritmalarının Evrimsel Haritası

Kaynak: Seyyarer, E., Ayata, F., Uçkan, T. ve Karcı, A. (2020). Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması. *Anatolian Journal of Computer Sciences*, 5 (2), 90-98.

Yapay sinir ağı ile derin öğrenme arasında kavramsal ve mimari açıdan farklılıklar bulunmaktadır. Kavramsal açıdan bakıldığında yapay sinir ağı biyolojik organizmaların öğrenme mekanizmasından ilham alan ve nöronların biyolojik fonksiyonlarını taklit eden düğümlerden oluşan bir bilgi işleme modelidir. Derin öğrenme ise yapay sinir ağlarından daha geniş bir kavramdır ve bilgisayar sistemlerinin deneyim ve verilerle gelişmesini sağlayan bir tekniktir. Mimari açıdan bakıldığında ise yapay sinir ağları, sinir sisteminin nasıl çalıştığına dayanan basit mimari modellerdir. Derin öğrenme mimarisi ise yapay sinir ağlarına dayanmaktadır (Pala, 2020, s. 245).

Derin öğrenme katmanları aşağıdaki gibi sıralanabilir:

- **Girdi katmanı:** Girdi katmanı ağın ilk katmanıdır ve modelin girişinden sorumludur (Thongsuwan vd., 2021, s. 524). Derin öğrenme ismini ortaya çıkaran, birçok katman olması gerçeğidir. Girdi katmanı, verilerin ağa girdiği yerdir (Risum ve Bro, 2019, s. 256).
- **Aktivasyon fonksiyonu katmanı:** Derin sinir ağının yapısının bir diğer önemli bileşeni de aktivasyon fonksiyonudur. Bu katmanda her bir nörona bir

aktivasyon fonksiyonu uygulanmaktadır (Niu vd., 2020, s. 5). Aktivasyon fonksiyonu, derin sinir ağlarını eğitmenin çok önemli bir parçasıdır. Aktivasyon fonksiyonu, karmaşık verileri öğrenmek ve girdiler ile çıktılar arasındaki doğrusal olmayan fonksiyonel eşlemeleri temsil etmek için ağı daha güçlü hale getirir. Bir aktivasyon fonksiyonunun diğer bir önemli özelliği ise, geri yayılım eniyileme stratejisini gerçekleştirmek için farklılaştırılabilir olması gerektiğidir (S. J. Narayanan vd., 2020, ss. 274-276). Derin öğrenme modelleri için yoğun şekilde kullanılan aktivasyon fonksiyonları aşağıdaki gibi sıralanabilir:

- *Sigmoid*: Sigmoid aktivasyon fonksiyonu matematiksel olarak Denklem 24'te gösterilmiştir.

$$\text{Sigmoid}(x) = \sigma(x) = \frac{1}{1 + e^{-x}} \quad (24)$$

- *Softmax*: Softmax aktivasyon fonksiyonu matematiksel olarak Denklem 25'te gösterilmiştir.

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (25)$$

- *Hiperbolik Tanjant (Tanh)*: Tanh aktivasyon fonksiyonu matematiksel olarak Denklem 26'da gösterilmiştir.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (26)$$

- *Rectified Linear Unit (ReLU)*: ReLU aktivasyon fonksiyonu matematiksel olarak Denklem 27'de gösterilmiştir.

$$\text{ReLU}(x) = \max(0, x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (27)$$

- *Leaky ReLU (LReLU)*: LReLU aktivasyon fonksiyonu matematiksel olarak Denklem 28’de gösterilmiştir.

$$LReLU(x) = \begin{cases} 0.01x, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (28)$$

- *Parametrik ReLU – PReLU (Parametric ReLU)*: PReLU aktivasyon fonksiyonu matematiksel olarak Denklem 29’da gösterilmiştir.

$$PReLU(x) = \begin{cases} \alpha x, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (29)$$

- *ELU (Exponential Linear Unit)*: ELU aktivasyon fonksiyonu matematiksel olarak Denklem 30’da gösterilmiştir.

$$ELU(x) = \begin{cases} \alpha(e^x - 1), & x \leq 0 \\ x, & x > 0 \end{cases} \quad (30)$$

- *SELU (Scaled Exponential Linear Unit)*: SELU aktivasyon fonksiyonu matematiksel olarak Denklem 31’de gösterilmiştir.

$$SELU(x) = f(x) = \begin{cases} \lambda \alpha(e^x - 1), & x \leq 0 \\ \lambda x, & x > 0 \end{cases} \quad (31)$$

- *Softplus*: Softplus aktivasyon fonksiyonu matematiksel olarak Denklem 32’de gösterilmiştir.

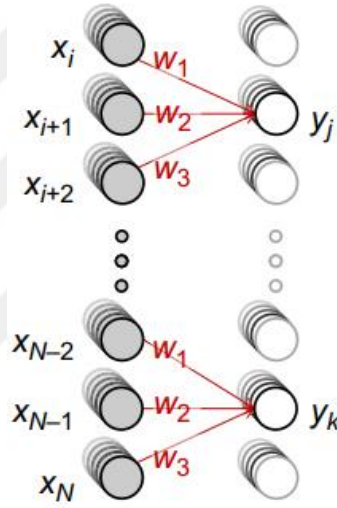
$$Softplus(x) = \log(1 + e^x) \quad (32)$$

- *Maxout*: Maxout aktivasyon fonksiyonu matematiksel olarak Denklem 33’te gösterilmiştir.

$$Maxout(x) = \max(W_1^T x + b_1, W_2^T x + b_2, \dots, W_i^T x + b_i) \quad (33)$$

- **Evrişimli katman**: Evrişimli katman, girdi verilerinden üst düzey özellikleri çıkarmaktadır (Gopika vd., 2020, s. 24). Evrişimli katmanın rolü, önceki

katmandaki özelliğin benzerliklerini tespit etmek ve girdinin özellik temsilini öğrenmektir (Siddique ve Chow, 2020, s. 661). Evrişimli katmanlar, bir önceki katmandan gelen girdiyi bir dizi ağırlık kullanarak saran ve genellikle bir özellik haritası olarak adlandırılan çıktıyı oluşturan filtreleri içerir. Her filtrede, nöronlar doğrudan girdi veri noktalarına bağlanır ve veri noktalarını ağırlıklarla çarpar. Aynı filtredeki tüm nöronlar ağırlıklarını paylaşır, bu da ağın optimizasyon süresini ve komplikasyonunu azaltır (Jing vd., 2017, s. 3). Şekil 9’da evrişimli katman yapısı görülmektedir (P. Narayanan vd., 2020, s. 332).




Şekil 9. Evrişimli Katman

Kaynak: Narayanan, P., Ambrogio, S., Tsai, H., Mackin, C., Shelby, R. M. and Burr, G. W. (2020). Analog acceleration of deep learning using phase-change memory. In S. Spiga, A. Sebastian, D. Querlioz and B. Rajendran (Eds.), *Memristive devices for brain-inspired computing* (pp. 329-362). Duxford, UK: Woodhead Publishing. <https://doi.org/10.1016/B978-0-08-102782-0.00013-7>

- **Havuzlama katmanı:** Genellikle birbirini izleyen evrişim katmanları arasında yerleştirilen havuzlama katmanı, veri hesaplamasını azaltmayı ve önemli özellikleri seçmeyi amaçlar. Bu katman, girdinin boyutunu azaltarak eğitim hızını artırır ve aşırı öğrenme olasılığını azaltır. Girdiyi ölçeklendirirken sonraki katman için önemli bilgileri tutar (Toprak ve Toygar, 2021, s. 3; Z. Zhang vd., 2021, s. 3). Global havuzlama, maksimum havuzlama ve ortalama

havuzlama gibi çeşitli havuzlama yöntemleri vardır (Shamshirband vd., 2021, s. 3).

- **Tam bağlı katman:** Tam bağlantılı katman, bir matris-vektör çarpımı sonucunda elde edilen vektöre bir aktivasyon fonksiyonunun uygulanması ve buna bağlı veri transfer sürecinden oluşur (Malița, Popescu ve Ştefan, 2020, s. 311). Tam bağlı terimi, önceki katmandaki her nöronun bir sonraki katmandaki her nörona bağlı olduğunu ifade etmektedir (Potluri, Ahmed ve Diedrich, 2020, s. 207). Şekil 10'da tam bağlı katman yapısı görülmektedir (Doğan ve Türkoğlu, 2019, s. 418).

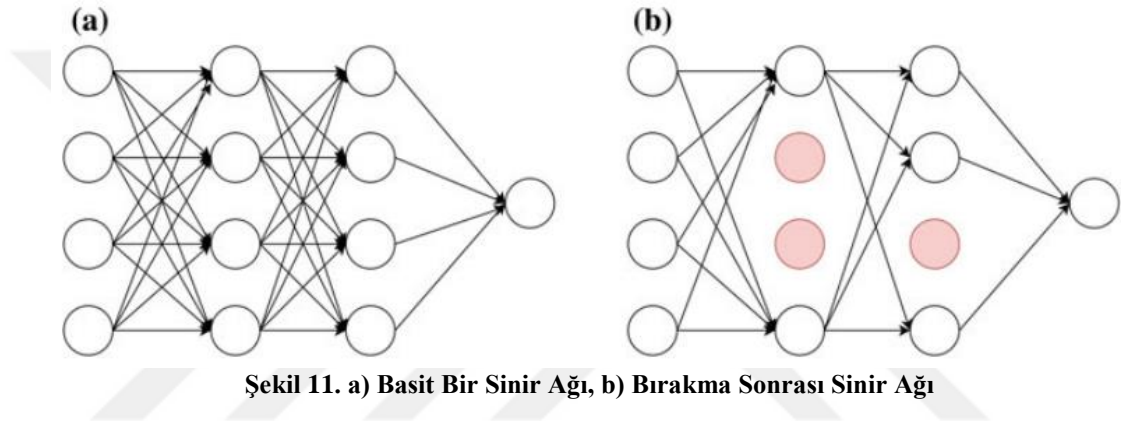


Şekil 10. Tam Bağlı Katman

Kaynak: Doğan, F. ve Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *DÜMF Mühendislik Dergisi*, 10 (2), 409-445. <https://doi.org/10.24012/dumf.411130>

- **Bırakma (Dropout) Katmanı:** Derin sinir ağları, çok karmaşık özelliklerin öğrenilmesini sağlayan çok sayıda gizli katmandan oluşmaktadır. Bunu, karar verme sürecinde tam bağlantılı katmanlar bu katmanları takip etmektedir. Tam bağlantılı bir katman tüm özelliklere tamamen bağlı olup aşırı öğrenmeye eğilimlidir. Aşırı öğrenme, bir modelin eğitildiğinde ortaya çıkan bir problemdir. Model, eğitim verileri üzerinde o kadar iyi çalışır ki, yeni veriler üzerindeki performansını olumsuz yönde etkileyebilir. Aşırı öğrenme problemiyle başa çıkmak için, model eğitimi sırasında bazı nöron

bağlantılarıyla birlikte rastgele ağıdan atılabilen bir bırakma katmanı eklenmesi düşünülebilir. Bu aşamadaki veriler üzerinde yalnızca indirgenmiş bir ağ eğitilir. Kaldırılan düğümler daha sonra orijinal ağırlıklarıyla ağa yeniden yerleştirilir. Bırakma işlemi, aşırı öğrenmeyi önemli ölçüde azaltır ve modelin genelleştirilmesini iyileştirir. Şekil 11’de bırakma işlemi öncesi ve sonrası basit bir sinir ağı gösterilmiştir (Wani vd., 2020, s. 27). Bırakma parametresi 0 ile 1 arasında bir değer almaktadır. Yaygın olarak 0,10 ile 0,50 arasında ayarlanır (Hull, 2021, s. 173).



Şekil 11. a) Basit Bir Sinir Ağı, b) Bırakma Sonrası Sinir Ağı

Kaynak: Wani, M. A., Bhat, F. A., Afzal, S. and Khan, A. I. (2020). *Advances in deep learning* (Vol. 57). Singapore: Springer. <https://doi.org/10.1007/978-981-13-6794-6>

- **Yığın Normalizasyon katmanı:** Derin sinir ağlarının eğitilmesi ciddi bir süre almaktadır. Eğitim süresinin azaltılmasının yolu normalizasyondan geçmektedir (Doğan ve Türkoğlu, 2019, s. 419). Yığın normalizasyon katmanı, derin sinir ağlarının eğitiminin yakınsamasını tutarlı bir şekilde hızlandırmak için kullanılan popüler ve etkili bir tekniktir (Long vd., 2021, s. 4). Yığın normalizasyonu, ağı daha derin olmasına yardımcı olur ve eğitim sürecindeki yineleme sayısını azaltır (Nasiri vd., 2019, s. 4).

Yığın normalizasyonu, her bir mini yığındaki gözlemlerin ortalamasını ve varyansını normalleştirerek işlem görür. Yığın normalizasyonu, bir katmanın girdilerini ortalaması 0 ve varyansı 1 olacak şekilde normalleştirir. Bu da sinir ağlarının performansını ve eğitim kararlılığını iyileştirebilir. Birçok uygulama

için yığın normalizasyonu eğitim süresini azaltmaktadır. Spesifik olarak, eğitim sırasında, yığın normalleştirme katmanı, hareketli bir ortalama kullanarak parti girdilerinin ortalamasını ve varyansını tahmin eder. Ardından, yığın girdileri normalleştirmek için hareketli ortalama ve varyans güncellenir. Test sırasında, hareketli ortalama ve varyans sabitlenir ve girdileri normalleştirmek için uygulanır (Hull, 2021, s. 174).


- **Çıktı katmanı:** Girdi verilerine dayanarak çalıştırılan ağ modelinin çıktılarını belirleyen katmana çıktı katmanı adı verilir (Jia vd., 2018, s. 622). Çıktı katmanı nihai sonucun üretilmesinden sorumludur.

Tez çalışmasında MATLAB programında yer alan derin öğrenme araç kutusu kullanılmıştır. Derin öğrenme araç kutusu, kullanıcıların derin sinir ağlarını tasarlamasına, oluşturmasına ve görselleştirmesine olanak tanımaktadır.

Regresyona dayalı tahminlerde yoğun bir şekilde kullanılan en popüler derin sinir ağları mimarileri; tekrarlayan sinir ağları (Recurrent Neural Network, RNN), uzun kısa süreli bellek (Long Short Term Memory, LSTM), çift yönlü uzun kısa süreli bellek (Bi-directional Long Short Term Memory, Bi-LSTM) ve geçitlendirilmiş özyinelemeli birimler (Gated Recurrent Units, GRU) şeklinde sıralanabilir. Bunlar kısaca aşağıda açıklanmıştır.

2.1.4.1. Tekrarlayan Sinir Ağları

Tekrarlayan sinir ağları, günümüzde sıkça kullanılan ağ mimarilerinden biridir. Tekrarlayan sinir ağları genel olarak dizileri (sıralı verileri) analiz etmek, sınıflandırmak ve işlemek için kullanılmaktadır. Tekrarlayan sinir ağlarının ileri beslemeli diğer ağlardan temel farkı, ağ içindeki önceki katmanlardan veya aynı katmandan geri bildirim bağlantılarına sahip olmasıdır. Böylece, içinde birçok döngüler bulunan ve bilginin sürekli olmasına izin veren bir ağ mimarisi oluşmuş olmaktadır. Tekrarlayan sinir ağları, geri yayılım algoritması ile eğitilmektedir (Elmas, 2018, s. 231). Şekil 12’de temel bir tekrarlayan sinir ağı gösterilmiştir (Sinaei ve Daneshtalab, 2020, s. 30).



Şekil 12. Temel Bir Tekrarlayan Sinir Ağı Hücresi

Kaynak: Sinaei, S. and Daneshtalab, M. (2020). Hardware acceleration for recurrent neural networks. In M. Daneshtalab and M. Modarressi (Eds.), *Hardware architectures for deep learning* (pp. 27-51). London, United Kingdom: The Institution of Engineering and Technology.

Basit bir tekrarlayan hücre, tekrarlayan bağlantılarla güçlendirilmiş standart bir nörondur ve bu durum, geçmiş durumdaki ağlardan (tekrarlayan bağlantı yoluyla) ve aldığı akım girişlerinden (ileri beslemeli bağlantı yoluyla) etkilenmesine neden olur. Başka bir deyişle, tekrarlayan bir bağlantı, tekrarlayan bir nöronun çıktısını aynı katmandaki tekrarlayan nöronlara bir girdi olarak bağlar. Basit bir tekrarlayan hücrenin matematiksel ifadesi Denklem 34'te verilmiştir (Noman, 2020, s. 46).

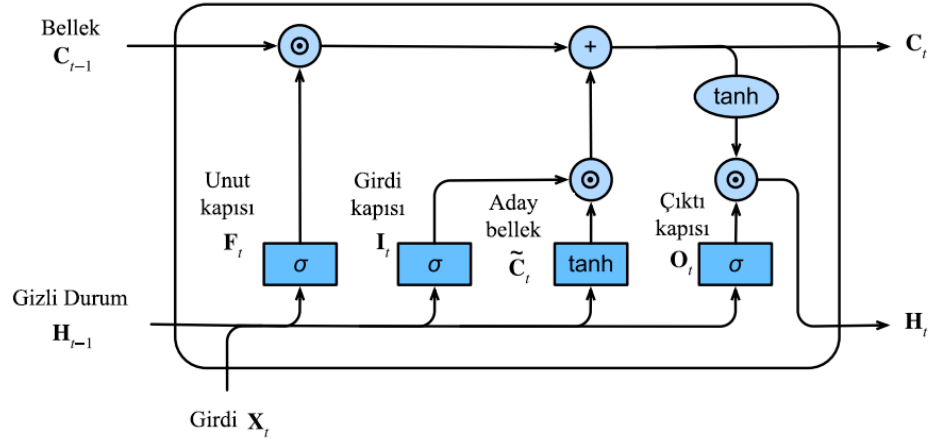
$$\begin{aligned} \mathbf{H}_t &= \phi(\mathbf{X}_t \mathbf{W}_{xh} + \mathbf{H}_{t-1} \mathbf{W}_{hh} + \mathbf{b}_h) \\ \mathbf{Y}_t &= \mathbf{H}_t \end{aligned} \quad (34)$$

Denklemden \mathbf{X}_t , \mathbf{H}_t ve \mathbf{Y}_t sırasıyla girişi, tekrarlayan bilgileri ve t zamanında hücre çıkışını belirtmektedir. \mathbf{W}_{xh} giriş ile gizli katman arasındaki ağırlık matrisini, \mathbf{W}_{hh} ise gizli katman ile kendisi arasındaki tekrarlayan ağırlık matrisini temsil etmektedir. \mathbf{b}_h ise bias vektörüdür.

2.1.4.2. Uzun Kısa Süreli Bellek

Uzun kısa süreli bellek, yapay nöronlar arasında doğrudan tek yönlü bağlantılar yerine geri besleme bağlantılarını içerecek şekilde tekrarlayan bir sinir ağı mimarisi türüdür. Tipik bir derin öğrenme tekniği olarak uzun kısa süreli bellek, veri dizileri ile olan çalışmalar için biçilmiş bir kaftandır (Kose vd., 2021, s. 131). Uzun kısa süreli bellek, tekrarlayan sinir ağlarının eksikliğini gidermek için oluşturulan bir tekrarlayan

sinir ağıları varyantıdır. Uzun vadeli bağımlılık sorununu çözmek için özel olarak oluşturulduklarından dolayı uzun süre bilgileri hatırlama kabiliyetine sahiptir (Onyekpe vd., 2021, s. 235).



Şekil 13. Uzun Kısa Süreli Bellek Mimari Yapısı

Kaynak: Zhang, A., Lipton, Z. C., Li, M. and Smola, A. J. (2021). *Dive into Deep Learning*.

Uzun kısa süreli bellek mimarisi, Şekil 13'te gösterildiği gibi birbirini tekrar eden sıralı bloklardan oluşmaktadır (A. Zhang vd., 2021, s. 353). Genel olarak uzun kısa süreli bellek yapısı unut, girdi ve çıktı kapıları olmak üzere 3 farklı katmandan oluşmaktadır. Uzun kısa süreli bellek mimarisinde öncelikle girdi olarak X_t ve H_{t-1} verileri kullanılarak hangi verilerin silineceğine karar verilir. Bu işlemler unut kapısında (F_t) Denklem 35 kullanılarak yapılır ve aktivasyon fonksiyonu olarak sigmoid kullanılır.

$$F_t = \sigma(X_t W_{xf} + H_{t-1} W_{hf} + b_f) \quad (35)$$

İkinci adımda yeni bilgilerin belirleneceği girdi kapısı (I_t) devreye girer ve öncelikle Denklem 36 kullanılarak sigmoid fonksiyonu ile veriler güncellenir. Ardından Denklem 37 ile yeni veriyi oluşturacak aday veriler tanh fonksiyonu tarafından belirlenir.

$$\mathbf{I}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xi} + \mathbf{H}_{t-1} \mathbf{W}_{hi} + \mathbf{b}_i) \quad (36)$$

$$\tilde{\mathbf{C}}_t = \tan h(\mathbf{X}_t \mathbf{W}_{xc} + \mathbf{H}_{t-1} \mathbf{W}_{hc} + \mathbf{b}_c) \quad (37)$$

Denklem 38 ile yeni veriler oluşturulur.

$$\mathbf{C}_t = \mathbf{F}_t \odot \mathbf{C}_{t-1} + \mathbf{I}_t \odot \tilde{\mathbf{C}}_t \quad (38)$$

Son olarak çıktı kapısında Denklem 39 ve Denklem 40 kullanılarak çıktı verileri elde edilir.

$$\mathbf{O}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xo} + \mathbf{H}_{t-1} \mathbf{W}_{ho} + \mathbf{b}_o) \quad (39)$$

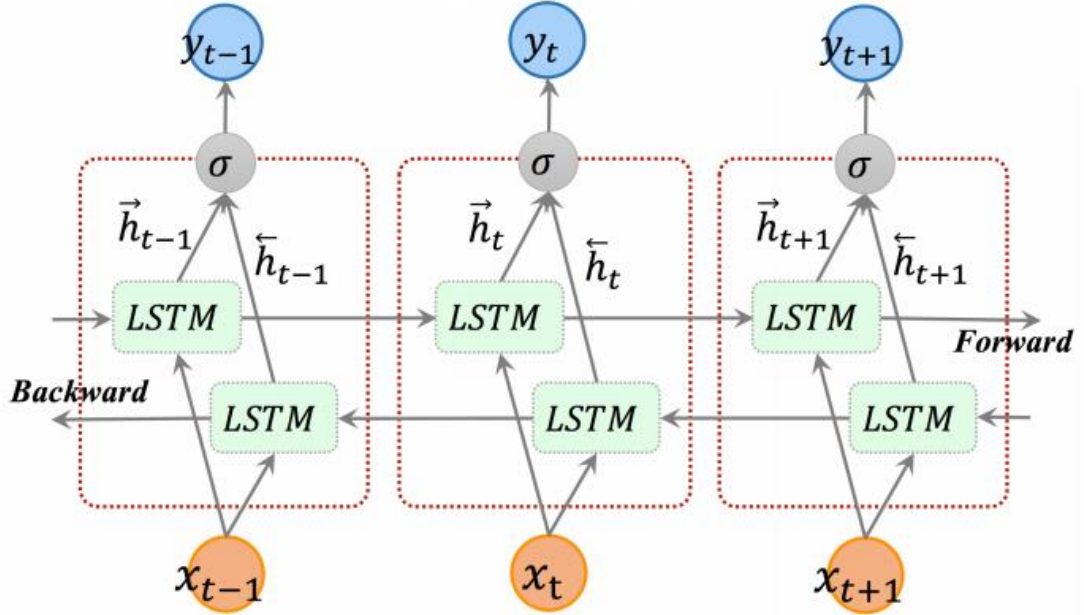
$$\mathbf{H}_t = \mathbf{O}_t \odot \tan h(\mathbf{C}_t) \quad (40)$$

Yukarıda ifade edilen süreç tekrarlanarak devam eder. Ağırlık parametreleri (\mathbf{W}) ve bias parametreleri (\mathbf{b}) gerçek eğitim değerleri ile uzun kısa süreli bellek çıktı değerleri arasındaki farkı minimize edecek şekilde model tarafından öğrenilmektedir (Kara, 2019, s. 885; A. Zhang vd., 2021, ss. 353-355).

2.1.4.3. Çift Yönlü Uzun Kısa Süreli Bellek

Sırasıyla hem geçmiş hem de gelecek bağlamları yakalamak için uzun kısa süreli belleği hem ileri hem de geri yönde kullanmak günümüz çalışmalarında yaygın bir uygulama haline gelmiştir. İlk olarak, uzun kısa süreli bellek gizli durumlarını giriş dizisinin ileri yönünde hesaplar ve sonra aynı işlemi geri yönde yapar. İki uzun kısa süreli bellek kullanmanın bu yolu, çift yönlü uzun kısa süreli bellek veya basitçe Bi-LSTM olarak adlandırılmaktadır ve mimarisi Şekil 14'te gösterilmiştir (Cui vd., 2020, s. 6). İleri uzun kısa süreli bellek katmanı ve geri uzun kısa süreli bellek katmanı aracılığıyla, zıt zaman dizilerine sahip iki gizli katman durumu elde edilir. Ardından,

aynı çıktıyı elde etmek için iki gizli katman durumu birbirine bağlanır. İleri uzun kısa süreli bellek ve geri uzun kısa süreli bellek katmanları sırasıyla giriş dizisinin geçmiş bilgilerini ve gelecekteki bilgilerini elde edebilir. Çift yönlü uzun kısa süreli belleğin t zamanında nihai çıktısı Denklem 41’de gösterilmiştir (Peng vd., 2021, s. 5; Sahu ve Anand, 2020, s. 4).



Şekil 14. Çift Yönlü Uzun Kısa Süreli Bellek Mimarisi

Kaynak: Cui, Z., Ke, R., Pu, Z. and Wang, Y. (2020). Stacked bidirectional and unidirectional LSTM recurrent neural network for forecasting network-wide traffic state with missing values. *Transportation Research Part C: Emerging Technologies*, 118, 102674. <https://doi.org/10.1016/j.trc.2020.102674>

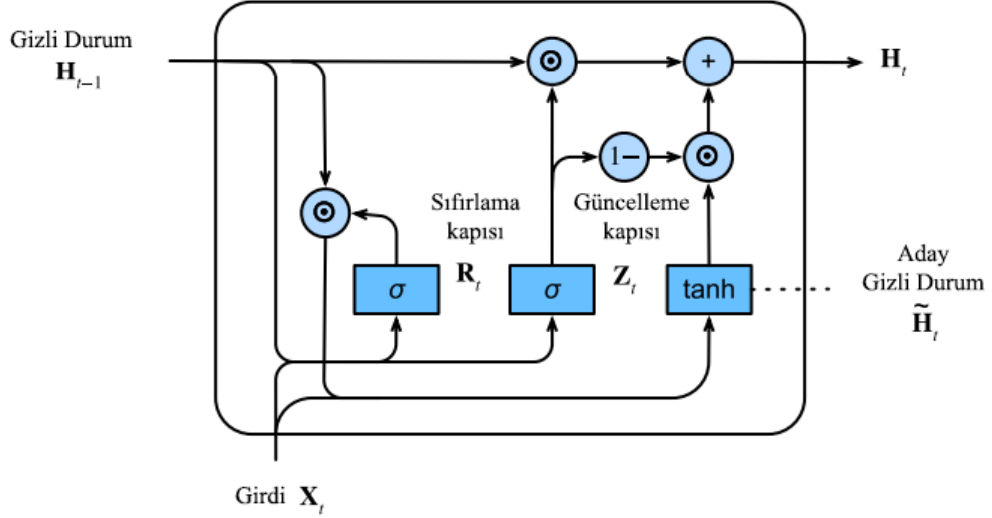
$$H_t = \vec{H}_t \oplus \overleftarrow{H}_t \quad (41)$$

Denklemden \oplus birleştirme işlemini, \vec{H}_t ve \overleftarrow{H}_t ise t zamanında ileri uzun kısa süreli bellek ve geri uzun kısa süreli belleğin gizli durumlarını temsil etmektedir.

2.1.4.4. Geçitlendirilmiş Özyinelemeli Birimler

Geçitlendirilmiş özyinelemeli birimler, hesaplamaları azaltmak için uzun kısa süreli bellek ağlarına alternatif olarak geliştirilen bir derin öğrenme yöntemidir. Geçitlendirilmiş özyinelemeli birimler, güncelleme kapısı olarak adlandırılan yeni bir

kapı oluşturmak için girdi kapısı ve unut kapısını birleştirdiği için uzun kısa süreli belleğe göre daha basit bir yapıya sahiptir. Güncelleme kapısı, önceki aktivasyon ile aday aktivasyonu arasındaki durumu herhangi bir çıktı aktivasyonu olmaksızın dengelemektedir. Unut kapısı ise önceki durumu sıfırlamaktadır. Geçitlendirilmiş özyinelemeli birimler, belleğindeki bilgi akışını düzenleyen geçitleme birimlerine sahiptir, ancak uzun kısa süreli bellekten farklı olarak, ayrı bellek hücrelerine sahip değildir. Geçitlendirilmiş özyinelemeli birimlerin bellek tüketimi ve hesaplama maliyeti, uzun kısa süreli bellekten çok daha düşüktür (Swapna, Soman ve Vinayakumar, 2020, s. 317). Şekil 15, geçitlendirilmiş özyinelemeli birimler mimarisini temsil etmektedir (A. Zhang vd., 2021, s. 358).



Şekil 15. Geçitlendirilmiş Özyinelemeli Birim

Kaynak: Zhang, A., Lipton, Z. C., Li, M. and Smola, A. J. (2021). *Dive into Deep Learning*.

Güncelleme kapısı, önceki zaman adımlarından ne kadar geçmiş bilginin geleceğe aktarılacağını belirler. Zaman adımı t için güncelleme kapısı değeri Z_t Denklem 42'deki formül kullanılarak hesaplanır.

$$Z_t = \sigma(X_t W_{xz} + H_{t-1} W_{hz} + b_z) \quad (42)$$

Sıfırlama kapısı, modelden geçmiş bilginin ne kadarının oluşturulacağına karar vermek için kullanılır ve Denklem 43'te görüldüğü şekilde hesaplanır.

$$\mathbf{R}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xr} + \mathbf{H}_{t-1} \mathbf{W}_{hr} + \mathbf{b}_r) \quad (43)$$

Nihai bellek içeriği iki adımda hesaplanır. İlk olarak, geçmişten gelen ilgili bilgiler, sıfırlama kapısı kullanılarak mevcut bellek içeriği adı verilen bir değişkende saklanır. Mevcut bellek içeriği $\tilde{\mathbf{H}}_t$ Denklem 44'deki formül yardımıyla hesaplanır.

$$\tilde{\mathbf{H}}_t = \tan h(\mathbf{X}_t \mathbf{W}_{xh} + (\mathbf{R}_t \odot \mathbf{H}_{t-1}) \mathbf{W}_{hh} + \mathbf{b}_h) \quad (44)$$

Son olarak, ağdan geçirilecek bilgileri tutan \mathbf{H}_t vektörü hesaplanır. Güncelleme kapısı bunun için kullanılır. $\tilde{\mathbf{H}}_t$ ve \mathbf{H}_{t-1} 'den toplanacak bilgiler Denklem 45'te olduğu gibi belirlenir (Khedkar vd., 2020, ss. 136-137; A. Zhang vd., 2021, ss. 347-349).

$$\mathbf{H}_t = \mathbf{Z}_t \odot \mathbf{H}_{t-1} + (1 - \mathbf{Z}_t) \odot \tilde{\mathbf{H}}_t \quad (45)$$

2.2. İlgili Araştırmalar

Bu başlık altında ele alınacak probleme benzer problemlerin ele alındığı çalışmalara ilişkin bir ön literatür araştırması yapılmıştır.

Kuo ve Lin (2010, ss. 1243, 1246, 1250) çalışmalarında toplam ekipman etkinliği ile ilgili bir endeks olan tesis kullanılabilirliğini tahmin ederek, toplam ekipman etkinliğinin tahminine yönelik ilk adımı atmışlardır. Çalışmada tesis kullanılabilirliğini tahmin etmek için dört tahmin yöntemi önerilmiştir. Bunlardan birinci yöntem saf bir sinir ağını, ikinci yöntem özel düğümlere sahip bir sinir ağını, üçüncü yöntem bir karar ağacı ile birlikte bir sinir ağını ve dördüncü yöntem de bir karar ağacı ile birlikte özel düğümlere sahip bir sinir ağını kullanmaktadır. Yazarlar

araştırma sonucunda ortalama tahmin hatasına göre yöntem 1, 2 ve 3'ün benzer doğruluğa sahip olduğunu ve bu yöntemlerin yöntem 4'ten daha iyi performans gösterdiğini belirtmişlerdir. Bununla birlikte, yöntem 1 ve 2 tarafından tahmin edilen değerlerin yalnızca küçük varyasyonları olduğu tespit edilmiştir. Gelecekteki kullanılabilirlik etkinliği değerlerini tahmin etmek için yöntem 1 veya 2 uygulanırsa, tahmin edilen değerlerin yöneticilere herhangi bir yararlı bilgi sağlayamayacağı yorumu yapılmıştır. Buna karşın yöntem 3'ün kullanılabilirlik etkinliğindeki düşüş eğilimini doğru bir şekilde öngörebilmesinden dolayı tahmin edilen değerlerin pratikteki değerlere daha yakın olduğu ifade edilmiştir.

Rodríguez-Padial, Marín ve Domingo (2017, ss. 1, 5, 9, 10, 13) tarafından ele alınan çalışmada, orta vadeli gelecekte güvenilirlik davranışını projelendirmek amacıyla temel bileşenler analizi ve yapay sinir ağları yöntemleri kullanılmıştır. Bu yeni fonksiyon, denge puan kartına entegre edilerek mevcut durumu daha iyi bir seviyeye getirmeyi mümkün kılmaktadır. Bu sayede daha iyi bilgi ve tahminler elde etmek amaçlanmıştır. Çalışmada ayrıca, toplam ekipman etkinliği ve arızaya kadar ortalama süre göstergelerine yönelik tahminler yapılmıştır. Çalışmada iki tip kâğıt üretim makinesi için, 3 girdi değişkeninden oluşan girdi katmanına, 10 nörondan oluşan gizli katmana ve 2 çıktı değişkeninden oluşan çıktı katmanına sahip bir yapay sinir ağları regresyon modeli geliştirilmiştir. Çalışmada faydalanılan girdi değişkenleri günlük ton cinsinden kâğıt üretim miktarı, gram cinsinden metrekaşe başına ortalama kâğıt ağırlığı ve saniyede metre cinsinden ortalama hızdır. Hedef çıktı değişkenleri ise her bir makine için yılın 12 ayı boyunca ölçülen toplam ekipman etkinliği ve arızaya kadar ortalama süre değerleridir. Ağ, bayes düzenleme geri yayılım algoritması kullanılarak %70'i eğitim, %15'i doğrulama ve %15'i test için ayrılmış veri seti ile eğitilmiştir. Sonuçlar incelendiğinde, tahmin başarı oranı %91,67 olarak gözlemlenmiştir.

Liao vd. (2018, ss. 1, 4), çalışmalarında tahmini toplam ekipman etkinliğini hesaplamak için önceden kestirilebilir öğeleri tahmin etmek amacıyla bir tekrarlayan pekiştirmeli öğrenme modeli geliştirmişlerdir. Bu model, üretim ve kalite alanında stokastik dinamiklerin tahmin edilmesinde kullanılan bir melez algoritmayı içermektedir. Bu algoritma, denetimli uzun kısa süreli bellek ve Derin Q Ağı tekniklerini birleştirmektedir. Derin Q Ağı, Q değerlerini tahmin etmek için 3 evrişimli katmana ve 2 tam bağlı katmana sahiptir. Geliştirilen model ilk olarak, arıza

tespiti ve sınıflandırmasına ilişkin süreç ve ekipman verileri, bağlam parametreleri ve fiziksel metroloji sonuçları dahil olmak üzere mevcut geçmiş veriler üzerinde eğitilmiş ve daha sonra, hedef sonucu tahmin etmek için mevcut üretimden elde edilen girdi verilerine uygulanmıştır. Yani ilk olarak, uzun kısa süreli bellek sonraki gözlemler ve anlık ödüller dahil olmak üzere sinyallerden gizli durumları öğrenir. Daha sonra öğrenilen gizli durumlar, optimuma yakın bir politikanın Q fonksiyonunu öğrenen Derin Q Ağının girdisini oluşturmaktadır. Çalışmada çıktı lot sayısı ve yeniden işleme hurda lot sayısı tahmin edilerek, tahmini toplam etkinlik değerine ulaşılmaya çalışılmıştır. Tahmini toplam ekipman etkinliğinin hesaplanmasını göstermek için örnek olarak bir kimyasal buhar biriktirme aracına ait veriler dikkate alınmıştır. Veriler, geliştirilen tekrarlayan pekiştirmeli öğrenme modelinin eğitimi, doğrulanması ve test edilmesi için kullanılmıştır. Toplam 100 veri seti vardır. Her bir veri seti, bir kimyasal buhar biriktirme aracı sürecini temsil eder. Her bir veri seti, 240 saniye boyunca alet sensörü tarafından toplanan gaz akışı, güç, basınç, akım, voltaj, sıcaklık ve buna benzer verileri içerir.

Brunelli vd. (2019) çalışmalarında, taze ürün paketleme makineleri için toplam ekipman etkinliği ve makine mekanik verimliliği ölçütlerinin gelecekteki değerlerini tahmin etmek amacıyla derin öğrenme yöntemlerinden LSTM ve zamansal evrişimli ağ mimarilerinden faydalanmışlardır. Geçmiş günlük toplam ekipman etkinliği değerleri, makine mekanik verimliliği değerleri, dahili alarm sayıları, harici alarm sayıları, üretim süreleri, temizlik süreleri ve arıza süreleri ölçümleri, tasarlanan modellerin bileşik girdisini oluşturmaktadır. Yapılan çalışma sonucunda, belirtilen ölçütlerin gelecekteki değerlerinin tahmin edilmesinde zamansal evrişimli ağa sahip model mimarisinin, LSTM'ye sahip model mimarisine kıyasla daha iyi performans sergilediği tespit edilmiştir.

El Mazgualdi vd. (2019, ss. 750, 751, 757-759, 761, 762) çalışmalarında, bir otomotiv kablo üretim endüstrisinden sağladıkları veriler yardımıyla toplam ekipman etkinliği değerini tahmin etmek için destek vektör makineleri, genetik algoritma kullanarak optimize edilmiş destek vektör makineleri, rastgele orman, ekstrem gradyan arttırma ve derin öğrenme algoritmalarını kullanmışlardır. Ele alınan vaka çalışmasında, veri seti 7 öznitelik, 1917 gözlem ve 1 hedeften oluşmaktadır. Çalışmanın girdi değişkenleri; kurulumlar, arıza, iş emri sayısı, ortalama tel uzunluğu, terminal sayısı, mühür sayısı ve hedeftir. Kurulum değişkeni, tüm kurulum

değerlerinin toplamını temsil etmektedir. Her siparişin kurulumu üretime başlamadan önce bilindiğinden, bu değişken bir girdi olarak kullanılmıştır. Arıza değişkeni, planlı ve plansız bakımı işaret etmektedir. plansız bakım önceden bilinemediğinden çalışmada arıza değişkeni olarak sadece planlı bakımdan faydalanılmıştır. İş emri sayısı değişkeni, her bir makinede vardiya başına günde kaç sipariş gerçekleştirdiğini belirtmektedir. Ortalama tel uzunluğu değişkeni, bir makinede tek vardiyada üretilen toplam tel uzunluğu değerlerinin ortalamasını temsil etmektedir. Terminal sayısı değişkeni, bir vardiyada aynı makine için tüm siparişlerdeki toplam terminal sayısını temsil etmektedir. Mühür sayısı değişkeni, bir vardiyada aynı makine için tüm siparişlerdeki toplam mühür sayısını temsil etmektedir. Çıktı ise toplam ekipman etkinliği değeridir. Çalışmanın sonuç kısmında toplam ekipman etkinliğinin tahmini için derin öğrenme ve rastgele orman algoritmalarının daha iyi performans gösterdiği ifade edilmiştir. Yazarlar, gelecekteki çalışmalarda gerçek zamanlı durumda tahminin doğrulanması, yöneticilere karar destek araçları sağlamak için optimizasyon tekniklerinin geliştirilmiş modellerle birleştirilmesi ve genetik algoritmaları makine öğrenmesiyle ilişkilendiren hibrit yaklaşımların faydasının daha ayrıntılı bir şekilde araştırılması gerektiğini belirtmişlerdir.

El Mazgualdi vd. (2020, ss. 2892, 2899, 2908) çalışmalarında, bir otomotiv kablo üretim endüstrisinden sağladıkları veriler yardımıyla tahmini toplam ekipman etkinliği değerini tahmin etmek için farklı konfigürasyonlar altında destek vektör regresyonu, genetik algoritma kullanarak optimize edilmiş destek vektör regresyonu, rastgele orman, ekstrem gradyan arttırma ve derin öğrenme algoritmalarını kullanmışlardır. Ele alınan vaka çalışmasında, veri seti 7 özellik, 1917 gözlem ve 1 hedeften oluşmaktadır. Birinci konfigürasyon; 1877 gözlem içeren bir eğitim seti ve 40 gözlem içeren bir test seti kullanırken, ikinci konfigürasyon; modellerin daha büyük bir veri seti üzerinde test edilmesini içerir, bu test seti tüm veri setinin % 15'ine eşdeğer olup 288 gözlemden oluşmaktadır. Çalışmanın girdi değişkenleri; kurulumlar, arıza, iş emri sayısı, ortalama tel uzunluğu, terminal sayısı, mühür sayısı ve hedeftir. Çıktı ise toplam ekipman etkinliği değeridir. Yazarlar, kıyaslama amacıyla, ilk olarak, basit bir veri kesiti kullanarak dört makine öğrenmesi tekniğini uygulamışlardır. Ardından, aşırı öğrenme sorununu çözmek için, K-kat çapraz doğrulama tekniğini kullanarak aynı yöntemleri uygulamışlardır. Sonuç, çapraz doğrulama tekniğinin kullanıldığı ve

verilerin usulüne uygun şekilde bölüştürüldüğü konfigürasyonun, daha iyi performanslara sahip tahminci modeller sağladığını göstermektedir.

Bonada vd. (2020, s. 1), eserlerinde yapay zekâ ve makine öğrenmesi çözümleri aracılığıyla mevcut süreç verilerinden yararlanmanın toplam ekipman etkinliğini nasıl etkileyebileceği üzerine odaklanmışlardır. Çalışmada, farklı deneysel örnekler kullanılarak, yapay zekâ çözümlerinin toplam ekipman etkinliği bileşenleri olan kullanılabilirlik, kalite ve performans üzerindeki etkileri incelenmiştir. Bunun yanı sıra, kestirimci bakım ve sanal sensör çözümlerinin istenmeyen üretim arızalarını azaltarak ekipman kullanılabilirliğini artırma konusunda nasıl yardımcı olabileceği gösterilmiştir. Ek olarak, tahmin doğruluğunu artırmak için, gerçek zamanlı döngü verileri veya toplu veriler için denetimli algoritmalara dayalı tahmini kalite çözümleri açıklanmıştır. Son olarak, döngü süresine odaklanan ekipman performansı, geçmiş deneyimlerden yararlanmak ve en yüksek verimle çalışacak süreç ayarlama türlerini sağlamak için vaka bazlı muhakeme yöntemi tarafından işleme alınmıştır. Kullanılabilirlik bileşeni için ekstrem gradyan artırma, K-en yakın komşuluk ve rastgele orman; kalite bileşeni için, K-en yakın komşuluk ve destek vektör makineleri sınıflandırıcıları; performans bileşeni içinse vaka bazlı muhakeme algoritmalarından faydalanılmıştır.

Dobra ve Jósvai (2022a, s. 12) tarafından gerçekleştirilen çalışmada, bir otomotiv firmasının yarı otomatik montaj hatlarının toplam ekipman etkinliği değerlerini tahmin etmek için makine öğrenmesi yöntemlerinden biri olan takt zamanına dayalı karar ağacından faydalanılmıştır. Çalışmada, geçmiş dönemde gerçekleşen toplam ekipman etkinliği bilgileri, karar ağacına dayanarak geliştirilen modelin girdilerini oluşturmak için kullanılmıştır. Elde edilen tahminler, uzun yıllardır firmada çalışan dört makine ayarlayıcısının toplam ekipman etkinliği tahminleri ile kıyaslanmıştır. Sonuçlar, geliştirilen modelin tahmin başarısının uzman personel tahminlerine kıyasla çok daha iyi olduğunu ve geliştirilen modelin kısa vadeli tahminler için oldukça başarılı olduğunu göstermektedir.

Dobra ve Jósvai (2023, s. 10) çalışmalarında, bir otomotiv firmasının yarı otomatik montaj hattının toplam ekipman etkinliğini tahmin etmek için çoklu doğrusal regresyon, basit polinom regresyonu, karmaşık polinom regresyonu, lasso regresyonu, ridge regresyonu, rastgele orman, gradyan artırma regresyonu ve otomatik düzgünlük tahminine sahip karma gam hesaplama aracı makine öğrenmesi yöntemlerinden

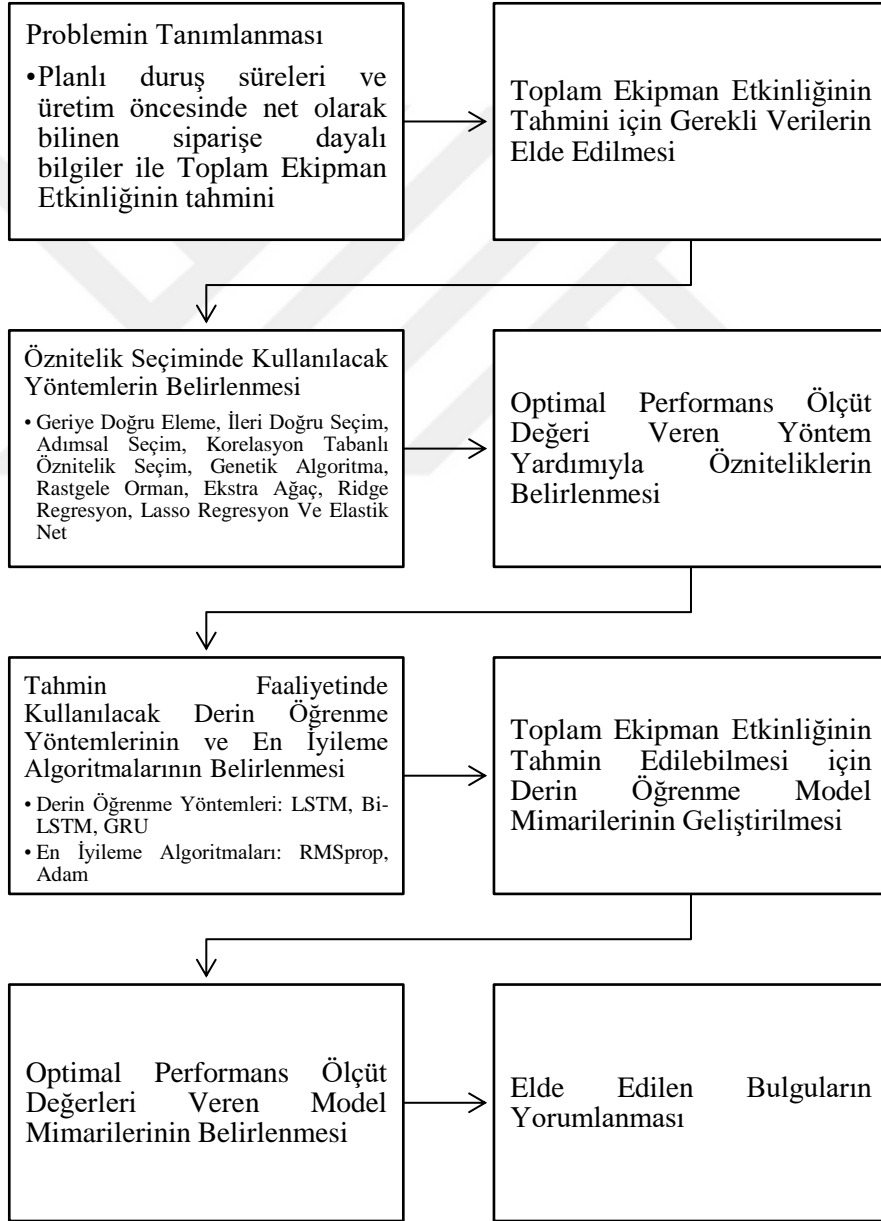
faýdalanmıřlardır. alıřmanın girdilerini sre arızası duruř sresi, mola duruř sresi, teknik duruř sresi, deęiřim duruř sresi, kalite nedeniyle duruř sresi, lojistik nedeniyle duruř sresi, planlanmamıř duruř sresi, dięer duruř nedeni sreleri, deęiřim sayısı, ortalama dng sresi, montajı yapılmıř birim sayısı ve hurda birimi sayısıdır. alıřmanın ıktıları ise toplam ekipman etkinlięi oranı, kullanılabilirlik oranı, performans oranı ve kalite oranıdır. alıřmada eřitli senaryolar ele alındıktan sonra gradyan artırma regresyonu ynteminin dięer yntemlere kıyasla daha dřk hata tahminine sahip olduęu sonucuna varılmıřtır.



3. YÖNTEM

3.1. Araştırmanın Modeli

Tez çalışmasında gerçekleştirilen işlem adımları Şekil 16’da özetlenmiştir.



Şekil 16. Toplam Ekipman Etkinliğinin Tahmin Edilmesi için Gerçekleştirilen İşlem Adımları

Bu tez çalışmasının amacı, Türkiye’de faaliyet gösteren bir kutu fabrikasının oluklu mukavva departmanından elde edilen veri setini kullanarak ve makine öğrenmesi tekniklerinden olan derin öğrenme yöntemleriyle model mimarileri geliştirerek ilgili departmanın toplam ekipman etkinliğini tahmin etmektir. Geliştirilen model mimarileri kullanılarak, ilgili departmandaki varlıkların performans göstergeleri alınarak departmanın toplam ekipman etkinliği tahmin edilmiş ve model mimarileri birbirleri ile karşılaştırılmıştır.

3.2. Evren ve Örneklem

Araştırmada, bir kutu fabrikasından elde edilen verilerden yararlanılmıştır. Fabrikada gıda, dayanıklı tüketim ürünleri, endüstriyel ürünler, kimyasallar, kozmetik ürünler ve temizlik malzemeleri için oluklu mukavva kutu üretimi gerçekleştirilmektedir. Ele alınan fabrikada siparişe dayalı üretim yapılmaktadır.

Oluklu mukavva; hafiflik, basınç ve gerilme direnci ve kolay işleme gibi iyi mekanik özelliklere sahiptir. Ek olarak, kirliliğe sebep olmaması, düşük maliyet ve geri dönüşüm gibi birçok avantajı vardır. Bu nedenle oluklu mukavva, modern ambalaj sanayisinde en yaygın kullanılan ambalaj kutusu haline gelmiştir. Ambalaj sektörünün hızla gelişmesiyle birlikte oluklu mukavva üretim ünitesi, baskı ünitesi, oluk açma ünitesi, kırma ünitesi, kalıp kesme ünitesi, katlama ünitesi ve yapıştırma ünitesinden oluşan üretim hattında oluklu mukavva üretilmektedir (Ge, Wu ve Wang, 2016, s. 707). Ele alınan fabrikada imalat süreci, oluklu mukavva üretimi ve dönüştürme (konfeksiyon) olarak ikiye ayrılmaktadır.

Fabrikanın oluklu mukavva üretim departmanında bir adet oluklu mukavva makinesi bulunmaktadır. Oluklu mukavva üretim işlemi, üretimi yapılacak mukavvaya uygun cins ve miktarda kâğıt bobinlerinin oluklu mukavva makinasına bağlanmasıyla başlamaktadır. Makinanın yaş kısmında siparişe göre farklı dalga cinslerinde oluklu mukavva üretilirken, kuru kısmında ise oluklu mukavvanın kenar ıskartası kesilir, planlandığı şekildeki hat sayısında boyuna kesim yapılır ve istenirse oluklara dik gelen rilleri atılır. Bu işlemin ardından, oluklu mukavvanın enine kesimi yapılarak bazen aynı, bazen de farklı boyutlarda oluklu mukavva levhaları elde edilir. Üretilen levhalar, istenilen nem seviyesine ulaşması için bir süre bekleme alanlarında


bekletilmekte ve sonrasında planlama departmanı tarafından siparişe göre rotalandığı dönüştürme makinesine sevk edilmektedir.

Dönüştürme departmanında ise flekso katlama yapıştırma, rotary kalıp kesimli flekso katlama yapıştırma, düz yatak kalıp kesme, baskı ve rotary kalıp kesme ve katlama ve yapıştırma makineleri bulunmaktadır.

Flekso katlama yapıştırma makineleri, geçmişte ayrı makinalar tarafından yapılan fleksografik baskı, puanlama, oluk açma, katlama ve yapıştırma işlemlerini bünyesinde birleştirmektedir (Twede vd., 2014, s. 494). Hızlı kuruyan, temizlenmesi kolay mürekkeplerin kullanıldığı fleksografik baskının hayata geçirilmesi, baskı işleminin katlama ve yapıştırma faaliyetleri ile entegrasyonunu mümkün kılmıştır (Paine, 1996, ss. 448-449).

Kalıp kesimi, üretim hattında önemli bir baskı sonrası işlemdir. Kalıp kesimi sırasında, öncelikle karton tasarım çizimine göre bir kontrplak üzerine monte edilen ve istenilen şekle bükülmüş bıçaklar kullanılarak kesme kalıbı oluşturulur. Sonrasında, oluklu mukavva kesme kalıbına bastırılır ve makaslanarak işaretlenir (Ge, Wu ve Wang, 2016, ss. 707-708). Kalıp kesme işlemi, gereksinime göre rotary kalıp kesme ve düz yatak kalıp kesme makineleri kullanılarak gerçekleştirilir (Griffin, 2012, s. 106). Her iki türün en yaygın uygulaması oluklu kutu ve katlanır karton üretimidir.


Düz yatak kalıp kesme makineleri, kalıbın düz bir yatağa monte edildiği ve kalıp kesiminin ileri geri hareketle gerçekleştirildiği makinelerdir. Platen kalıp kesici olarak da bilinirler (Soroka, 2008, s. 64). Düz yataklı kalıp kesicilerin doğruluğu daha yüksek olmasına rağmen, rotary kalıp kesiciler kadar hızlı değildir. Düz yataklı kalıp kesme, rotary kalıp kesmeye göre küçük sipariş ve kısa süreli üretim için daha uygun maliyetlidir. Düz yatak kalıp kesme ve kırma (katlama) ilkeleri Şekil 17'de gösterilmiştir (Hägglund ve Carlsson, 2012, s. 34).



Şekil 17. Düz Yatak Kalıp Kesme ve Kıрма

Kaynak: Hägglund, R. and Carlsson, L. A. (2012). Packaging performace. In K. Niskanen (Ed.), *Mechanics of paper products* (ss. 29-52). Berlin: Walter de Gruyter.

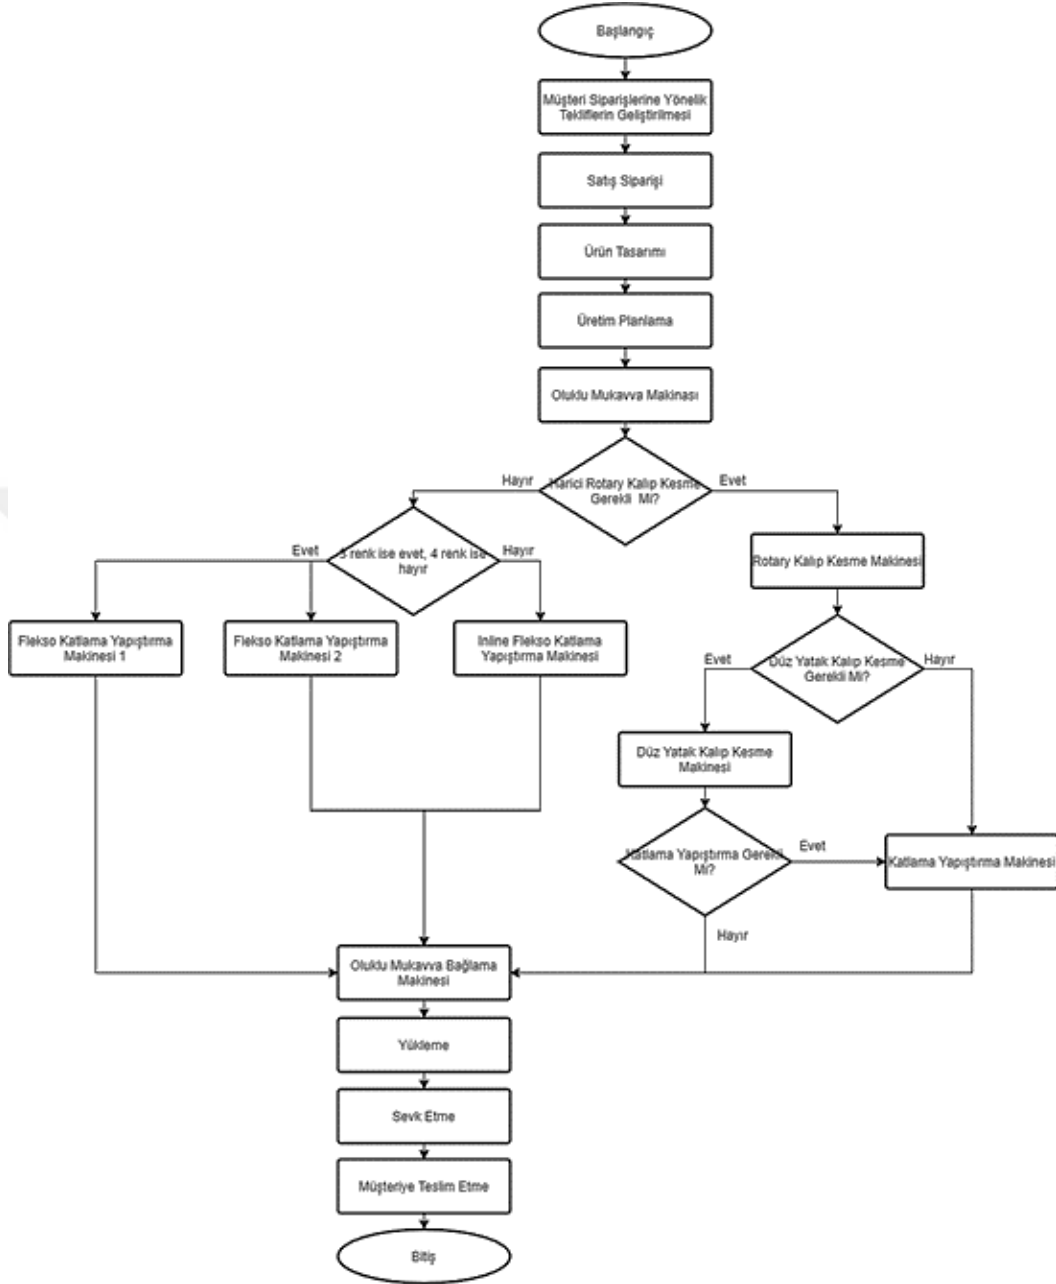
Oluklu kutu veya katlanır karton gibi malzemelerin üretiminde kullanılan, silindirik bir ruloya monte edilen kesme kalıbına sahip makinelere rotary kalıp kesme makinesi denir (Soroka, 2008, s. 64). Rotary kalıp kesme makineleri, tabakaları iki silindir arasından besleyerek dairesel ve sürekli bir hareket kullanmaktadır. Rotary kesme ve kırma (katlama) ilkeleri Şekil 18’de gösterilmiştir (Hägglund ve Carlsson, 2012, s. 34). Rotary kalıp kesme işlemi inline yapılabildiği gibi baskı sonrasında ayrı bir işlemde de yapılabilmektedir. Inline rotary kalıp kesiciler, bir flekso katlama yapıştırma makinesindeki baskı istasyonlarını takip edebilir ve puanlama bölümünden önce veya sonra konumlandırılabilir.



Şekil 18. Rotary Kesme ve Kıрма

Kaynak: Hägglund, R. and Carlsson, L. A. (2012). Packaging performace. In K. Niskanen (Ed.), *Mechanics of paper products* (pp. 29-52). Berlin: Walter de Gruyter.

İşletmeye ait iş akış şeması Şekil 19'da gösterilmiştir.



Şekil 19. İşletme İş Akış Şeması

3.3. Veri Toplama Araçları ve Teknikleri

Endüstrideki dijitalleşmenin artışı, üretim verilerinin otomatik olarak toplanması ve analiz edilmesi için araçlar sağlamaktadır (Hedman, Subramaniyan ve Almström, 2016, s. 128). Çalışmada kullanılan veriler, üretim veri toplama sisteminden elde edilmiştir. Üretim veri toplama sistemleri, kurulum, çalışma ve arıza

sürelerini ve üretime ilişkin girdi, fire ve çıktı verilerini otomatik olarak kaydetmektedir. Bu sistemlerde birçok veri otomatik olarak toplanmakta, aynı zamanda ara yüzleri sayesinde operatörler manuel olarak da veri girişi sağlayabilmektedir. Üretim veri toplama sistemleri, makine çalışma durumunu ve üretim verilerini gerçek zamanlı olarak izlemeye olanak tanır ve istenilen zaman aralığı için gerçekleştirilmesi istenen temel veri analizlerinde kullanılmak üzere standart raporlar oluşturabilir. Özetle, bu sistemler sahadan gerçek zamanlı veri toplar ve bunları tüm işletme genelinde toplu bir şekilde kullanılabilir hale getirerek çalışır (Caselli, Pattera ve Ricci, 2012, s. 554).

Üretim yürütme sistemleri, üretim veri toplama sistemlerini içerisinde barındırır ve sipariş başlangıcından bitmiş ürüne kadar olan üretim faaliyetlerinin optimizasyonunu sağlayan bilgileri sunar. Üretim yürütme sistemlerinin temel fonksiyonları aşağıdaki gibidir (Chen ve Voigt, 2020, ss. 2-3):

- **Kaynak tahsisi ve kontrolü:** Üretim yürütme sistemleri, üretim ve kontrolle doğrudan ilişkili kaynakları yönetmektedir. İşin başlaması ve tamamlanması için gereken makineler, araçlar, işgücü, malzemeler, diğer ekipmanlar ve belgeler, kaynaklara örnek olarak gösterilebilir.
- **Üretimin sevk edilmesi:** Üretim yürütme sistemleri, üretimi belirli ekipman ve personele sevk ederek işler ve üretim akışını siparişler, yığınlar, lotlar ve iş emirleri şeklinde yönetir.
- **Veri toplama ve edinme:** Üretim yürütme sistemleri, üretim ekipmanı ve üretim süreçleriyle ilgili parametrik verileri toplamaktadır.
- **Kalite yönetimi:** Üretim yürütme sistemleri, uygun ürün kalite kontrolünü sağlamak ve dikkat gerektiren sorunları tespit etmek amacıyla gerçek zamanlı ölçümler sağlamaktadır.
- **Süreç yönetimi:** Üretim yürütme sistemleri, üretimi gerçek zamanlı olarak takip ettiği için operatörlere süreç içi fonksiyonları düzeltme ve iyileştirme konusunda yönlendirme hizmeti ve karar desteği sağlamaktadır.
- **Üretim takibi:** Üretim yürütme sistemleri, üretim durumunu kontrol ederek iş düzenini sağlar.

- **Performans analizi:** Üretim yürütme sistemleri, geçmiş tarihli sonuçlarla beklenen sonuçları karşılaştırmakla birlikte aynı zamanda fiili üretim operasyonlarının en güncel raporlarını sunmaktadır.
- **Operasyonlar ve detaylı çizelgeleme:** Üretim yürütme sistemleri, belirli üretim ekipmanı ve belirli ürün özellikleriyle ilişkili öncelikler, nitelikler, özellikler ve üretim kurallarına dayalı olarak işlemlerin sıralı ve zamanında işlenmesini sağlar.
- **Doküman kontrolü:** Üretim yürütme sistemleri, üretim birimi tarafından sağlanan kayıt ve formları kontrol eder.
- **İşgücü yönetimi:** Üretim yürütme sistemleri, personele ait verileri içeren zaman ve katılım raporlaması gibi bilgiler sağlar.
- **Bakım yönetimi:** Üretim yürütme sistemleri, ekipmanların ve araçların bakım yönetimini sağlar.
- **Malzemelerin nakliyesi, depolanması ve takibi:** Üretim yürütme sistemleri; malzemelerin, süreç içi ürünlerin ve nihai ürünlerin taşınması, depolanması, tesisler arasındaki ve tesis içindeki transferlerin yönetimi ve takibi ile ilgilenir.

3.4. Veri Toplama Süreci

Araştırmada, bir kutu fabrikasının oluklu mukavva departmanından elde edilen veriler kullanılmıştır. Tahminde kullanılan veriler, 2017-2020 yılları arasındaki 4 yıllık dönemi (1204 iş günü) kapsamaktadır. Veri seti, 23 öznitelik ve bir çıktıdan oluşmaktadır. Öznitelikler, planlanan duruşlar ve gerçekleştirilecek faaliyetlere ilişkin önceden bilinen verilerden oluşmaktadır. Çıktı ise toplam ekipman etkinliği yüzdesidir. İlgili departmandan elde edilen veri seti, doğrudan kurumsal kaynak planlaması sisteminden alınmıştır. Veri setinde eksik veya yanlış veri bulunmamakta olup, herhangi bir tutarsızlık tespit edilmemiştir.

3.5. Verilerin Analizi

Günümüzde, imalatçılar makine öğrenmesi teknolojileriyle toplam ekipman etkinliğini otomatikleştirebilmektedir. Makine öğrenmesi çözümlerini üretim

sürecinin bir parçası olarak benimsemek, problemleri proaktif bir şekilde tanımlamaya, söz konusu problemlerden kaçınmaya ve düzeltici önlem almaya yardımcı olur. Bunun yanı sıra, makine öğrenmesi geçmiş ve mevcut verilere dayalı sonuçların tahminini de kolaylaştırabilmektedir. Bu yaklaşım verimliliği artırabilir ve israfi ortadan kaldırabilir ([http-2](#)).

Öngörüler ile sonuçlar arasındaki ilişkilerin doğası ve istatistiksel önemi hakkında yorumlanabilir tahminler elde etmek ve bu hipotezi test etmek için geleneksel istatistiksel yöntemler kullanılabilir. Ancak, büyük ve karmaşık veri yapılarında tahmin optimizasyonu amaçlanıyorsa, geleneksel istatistiksel yöntemler yerine makine öğrenmesi tercih edilebilir. Çünkü bu tür yöntemler, geleneksel parametrik yöntemlere kıyasla daha az kısıtlayıcı istatistiksel varsayımlara sahiptir. Bir tahminin amacı, tahmin doğruluğuna en güçlü şekilde katkıda bulunan değişkenleri belirlemektir. Bu bağlamda, bazı makine öğrenmesi yöntemleri, çeşitli faktörleri ve bunlar arasındaki etkileşimleri inceleyerek yeni yeni hipotezler oluşturma konusunda faydalı olabilir (Jiang, Gradus ve Rosellini, 2020, s. 676). Verilerin analizinde öznitelik seçimi yöntemlerinden ve derin öğrenme yöntemlerinden faydalanılmıştır.

4. BULGULAR VE YORUMLAR

İncelemeye alınan işletmenin oluklu mukavva departmanında, planlı ve plansız olmak üzere toplamda 33 farklı duruş türü tanımlanmıştır. Ancak, veri setinin alındığı dönemde bunların yalnızca 25'ine rastlanmıştır. İnceleme altına alınan dönemde meydana gelen planlı duruşlar; planlı bakım, planlı temizlik, makine hazırlığı, hafta sonu/resmî tatil, yönetim kararıyla/yapısal duruş ve toplantı/eğitim duruşlarıdır. Ayrıca, inceleme altına alınan dönemde 19 farklı plansız duruş meydana gelmiştir. Plansız duruşlar önceden bilinemediği için çalışmada yalnızca 6 farklı planlı duruş öznitelik olarak belirlenmiştir.

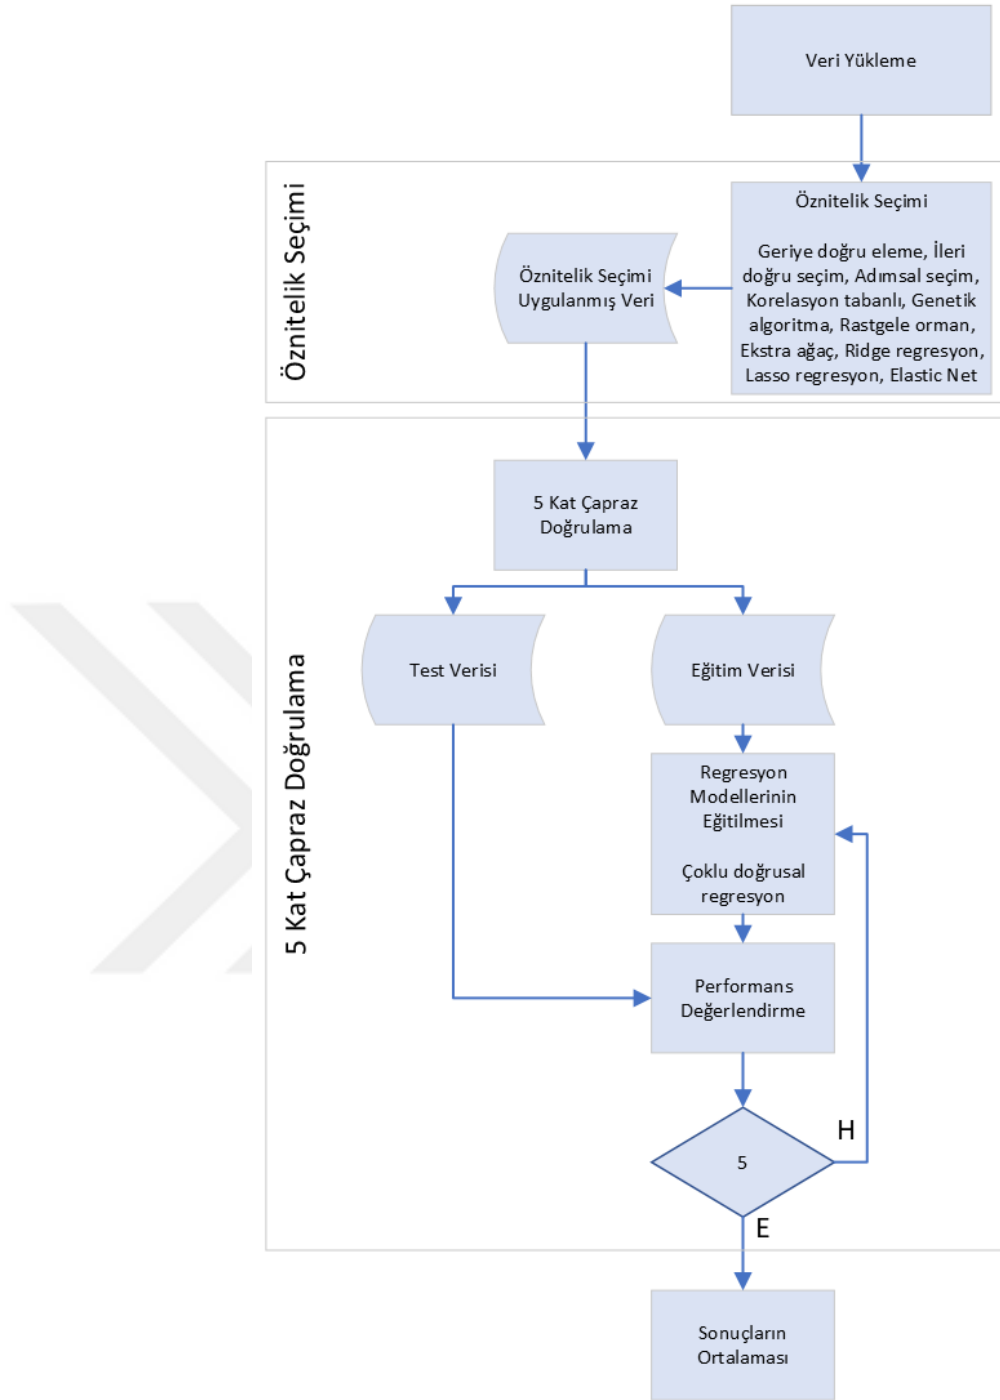
Tıpkı planlı duruşlarda olduğu gibi, bir gün içinde gerçekleşecek faaliyetlere ilişkin önceden bilinen veriler de öznitelik olarak değerlendirilmiştir. Üretim öncesinde niceliksel olarak bilinen; adet cinsinden sipariş miktarı, metrekare cinsinden sipariş miktarı, metrekare cinsinden planlanan net üretim miktarı, metrekare cinsinden planlanan brüt üretim miktarı, üretim siparişi sayısı, üretim talimat (belirli bir çalışma uzunluğu için belirli bir levha kalitesinde bir veya iki sipariştten oluşan oluklu mukavva işi) sayısı, metrekare cinsinden sipariş edilen tanıtım kağıdı miktarı, adet cinsinden sipariş edilen tanıtım kağıdı miktarı, kilogram cinsinden sipariş edilen tanıtım kağıdı miktarı, adet cinsinden satın alınan levha miktarı, metrekare cinsinden satın alınan levha miktarı, kullanılan kağıt makinası çerçevesi (deckle) sayısı (deckle solution olarak geçen kavram atıkları azaltmak amacıyla oluklu makinesi için işlerin kombinasyonu olarak geçmektedir), kâğıt türü sayısı, kullanılacak kağıt türü genişliği sayısı, mukavva türü sayısı, kullanılacak mukavva türü genişliği sayısı ve ıslak son değişiklik sayısı gibi 17 farklı öznitelik de çalışmanın özniteliklerine dahil edilmiştir.

Çalışmada, toplam 23 öznitelik kullanılarak, departmanın toplam ekipman etkinliği tahmin edilmeye çalışılmıştır. Bu öznitelikler arasında, 6 farklı planlı duruş türü ve 17 farklı üretim öncesinde net olarak bilinen siparişe dayalı bilgiler bulunmaktadır. Özniteliklere ilişkin bilgiler, Çizelge 6'da gösterilmiştir.

Çizelge 6. Öznitelik Seçimi Öncesi Öznitelikler

Değişken	Açıklama	Değişken	Açıklama
x_1	Adet cinsinden sipariş miktarı	x_{13}	Kâğıt türü sayısı
x_2	Metrekare cinsinden sipariş miktarı	x_{14}	Kullanılacak kâğıt türü genişliği sayısı
x_3	Metrekare cinsinden planlanan net üretim miktarı	x_{15}	Mukavva türü sayısı
x_4	Metrekare cinsinden planlanan brüt üretim miktarı	x_{16}	Kullanılacak mukavva türü genişliği sayısı
x_5	Üretim siparişi sayısı	x_{17}	Islak son değişiklik sayısı
x_6	Üretim talimat sayısı	x_{18}	Planlı bakım süresi
x_7	Metrekare cinsinden sipariş edilen tanıtım kâğıdı miktarı	x_{19}	Planlı temizlik süresi
x_8	Adet cinsinden sipariş edilen tanıtım kâğıdı miktarı	x_{20}	Hafta sonu / resmî tatil süresi
x_9	Kilogram cinsinden sipariş edilen tanıtım kâğıdı miktarı	x_{21}	Yönetim kararıyla / yapısal duruş süresi
x_{10}	Adet cinsinden satın alınan levha miktarı	x_{22}	Makine hazırlığı süresi
x_{11}	Metrekare cinsinden satın alınan levha miktarı	x_{23}	Toplantı / eğitim süresi
x_{12}	Kullanılan kâğıt makinası çerçevesi (deckle) sayısı		

Ele alınan problem regresyon modelidir. Öncelikle, 23 farklı özneliğin toplam ekipman etkinliği tahmini üzerindeki etkisini belirlemek amacıyla öznelik seçimi yapılmıştır. Öznelik seçiminin amacı, alakasız ve gereksiz öznelikleri çıkararak, boyutu en küçük ve toplu olarak en uygun tahmin özelliğine sahip öznelik alt kümesini belirlemektir (Ranjan vd., 2021, s. 4). Çalışmada, öznelik seçimi için 10 farklı yöntem kullanılmıştır. Öznelik seçimi için geliştirilen modele ilişkin akış şeması Şekil 20’de gösterilmiştir (Emanet, Karatas Baydogmus ve Demir, 2021, s. 747).



Şekil 20. Öznitelik Seçimi için Geliştirilen Modelin Akış Şeması

Kaynak: Emanet, S., Karatas Baydogmus, G. ve Demir, O. (2021). Öznitelik seçme yöntemlerinin makine öğrenmesi tabanlı saldırı tespit sistemi performansına etkileri. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 12 (5), 743-755.

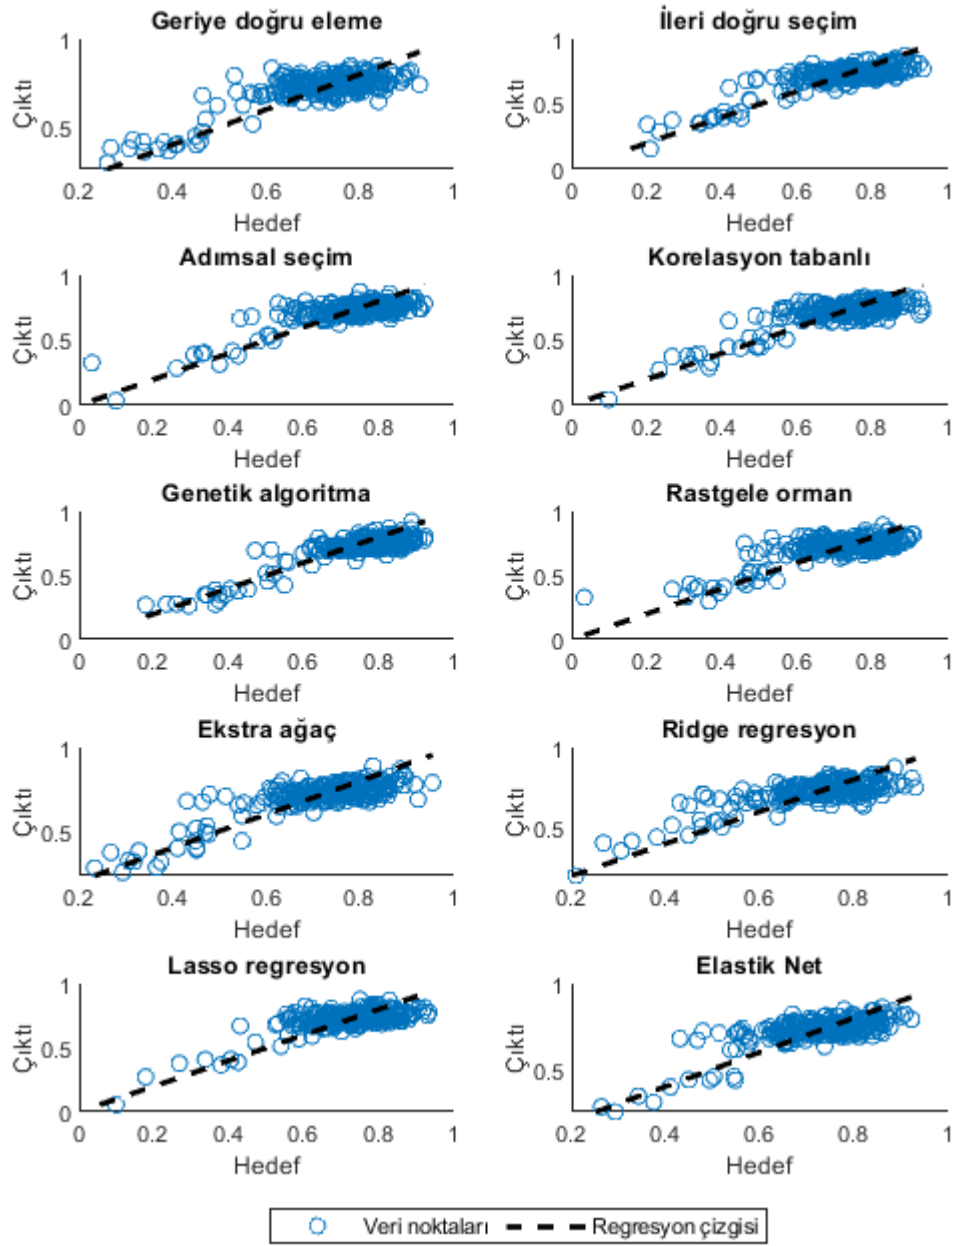
İşletmeden elde edilen veri seti öncelikle yazılıma yüklenmiş ve ardından geriye doğru eleme, ileri doğru seçim, adımsal seçim, korelasyon tabanlı öznitelik seçim, genetik algoritma, rastgele orman, ekstra ağaç, ridge regresyon, lasso regresyon

ve elastik net yöntemleri kullanılarak öznitelik seçimi yapılmıştır. Çalışmanın öznitelik seçimi kısmında geliştirilen modellerin performans ölçütlerini belirlemek amacıyla 5 kat çapraz doğrulama yöntemi kullanılmış ve problem çoklu doğrusal regresyon makine öğrenmesi yöntemi ile modellenmiştir. Öznitelik seçimi sonrasında indirgenmiş veri kümesi, 5 kat çapraz doğrulama fonksiyonu kullanılarak 5 parçaya bölünmüş, 4 parça üzerinde eğitim yapılmış ve 1 parça üzerinde test işlemi gerçekleştirilmiştir. Bu durum tüm eğitim – test parçaları kombinasyonları için tekrarlanmıştır. Modellerin performansları, her kattaki test işlemleri sonucunda elde edilen MSE ve R^2 ölçütleri kullanılarak değerlendirilmiştir. En iyi MSE ve R^2 değerlerine sahip test kümesinden elde edilen tahminler (çıktılar) ile gerçek (hedef) değerler kullanılarak regresyon grafiği ve karşılaştırma grafiği oluşturulmuştur. Ayrıca, performans ölçütü olarak tüm katmanlar için elde edilen MSE ve R^2 değerlerinin ortalamaları da analiz sonucunda hesaplanmıştır. Tüm analizler, MATLAB R2022b kullanılarak gerçekleştirilmiştir. Yapılan analizler neticesinde her bir yöntem için seçilen öznitelikler ve bu özniteliklerle geliştirilen modellerin ortalama ve en iyi performans ölçüt değerleri Çizelge 7’de özetlenmiştir.

Çizelge 7. Yönteme Göre Seçilen Öznitelikler ve Performans Ölçütleri

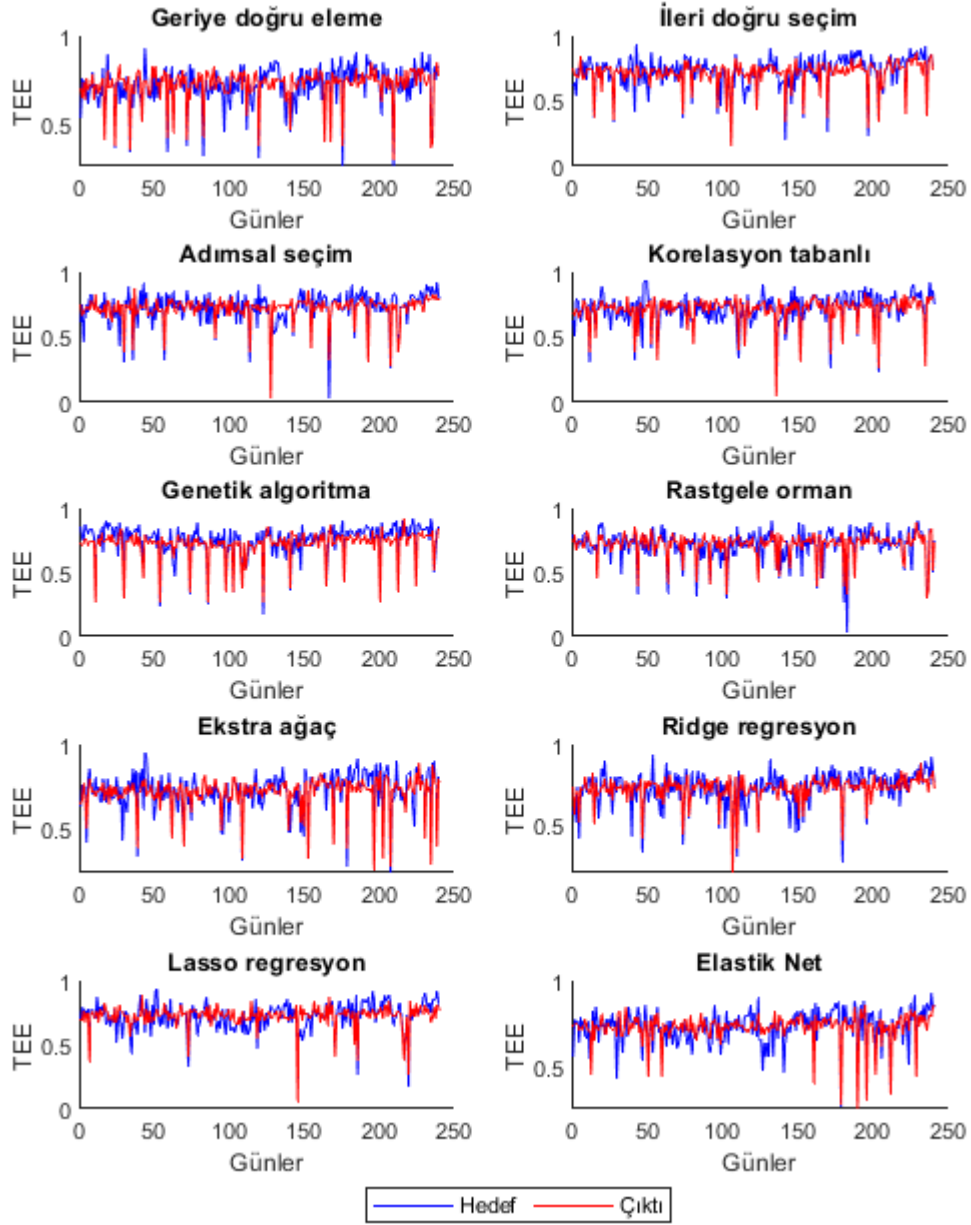
Yöntem	Seçilen Öznitelikler	Öznitelik Sayısı	En iyi R ²	En iyi MSE	Ortalama R ²	Ortalama MSE
Geriye doğru eleme	2, 4, 7, 9, 10, 16, 17, 18, 19, 20, 21, 22	12	0,61640	0,0051594	0,58927	0,0056655
İleri doğru seçim	2, 4, 10, 15, 17, 18, 19, 20, 21, 22, 23	11	0,60104	0,0053484	0,60076	0,0053765
Adımsal seçim	2, 4, 11, 18, 19, 20, 21, 22	8	0,63703	0,0055122	0,61927	0,0057845
Korelasyon tabanlı	1, 2, 3, 4, 5, 6, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20	17	0,62557	0,0058483	0,61344	0,0060317
Genetik algoritma	1, 4, 5, 10, 11, 13, 14, 15, 16, 18, 19, 20, 21, 22	14	0,65252	0,0048157	0,62059	0,0061646
Rastgele orman	1, 2, 3, 4, 5, 6, 9, 10, 11, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23	20	0,63028	0,0050817	0,62061	0,0058052
Ekstra ağaç	1, 2, 3, 4, 5, 6, 10, 11, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22	18	0,64054	0,0052140	0,62787	0,0057962
Ridge regresyon	2, 3, 4, 16, 17, 18, 19, 22	8	0,60813	0,005791	0,60635	0,0058165
Lasso regresyon	1, 2, 3, 4, 8, 10, 13, 15, 17, 18, 19, 20, 21, 22, 23	15	0,64292	0,0050668	0,62768	0,0058081
Elastik Net	1, 2, 3, 4, 7, 8, 10, 11, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23	19	0,638555	0,005037	0,628593	0,005818

Öznitelik seçim yöntemleriyle oluşturulan modellerin test işlemleri sonucunda elde edilen tahmini (çıktı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerleri arasındaki ilişkiyi gösteren regresyon grafikleri Şekil 21’de gösterilmiştir.



Şekil 21. Test İşlemi Sonrasında Elde Edilen Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları

Öznitelik seçim yöntemleriyle oluşturulan modellerin test işlemleri sonucunda elde edilen tahmini (çıktı) toplam ekipman etkinliği değerleriyle gerçek (hedef) toplam ekipman etkinliği değerlerinin seyri Şekil 22’de gösterilmiştir.



Şekil 22. Test İşlemi Sonrasında Elde Edilen Çıktı Değerleri ile Hedef Değerlerin Karşılaştırılması

Gerçek bir veri seti üzerinde gerçekleştirilen deneyler, önerilen yöntemlerin toplam ekipman etkinliğini en iyi 0,65 (genetik algoritma), ortalama 0,63 (elastik net) benzerlikle tahmin ettiğini göstermektedir. Ortalama tahmin performansı en önemli ölçüt olduğundan elastik net yöntemi en iyi sonucu vermiştir. Buna rağmen, kullanılan veri setinde biri hariç diğer yöntem çiftlerine göre daha fazla öznitelik seçilmesi elastik net - çoklu doğrusal regresyon yöntem çifti için bir dezavantaj oluşturmaktadır. Yani öznitelik sayısının artması, modelin kompleks bir yapıya bürünerek hesaplama süresinin artmasına ve genelleme yeteneğinin azalmasına sebep olacaktır. İşte bu

noktada Occam'ın usturası prensibi devreye girer. Bu prensibe göre, benzer başarımlar elde eden model alternatifleri arasından en basiti tercih edilmelidir (Korkmaz ve Eroğlu, 2020, s. 154). Yöntemlere göre elde edilen Ortalama R^2 değerleri arasında büyük bir fark olmadığı için, en az sayıda öznelik seçen (8 farklı öznelik) adimsal regresyon ve ridge regresyon yöntemleri arasından ortalama R^2 değeri büyük olan seçilir. Bu yaklaşıma göre, çalışmada adimsal seçim yöntemi uygulanarak modele dahil edilen özneliklerin istatistiksel olarak anlamlı olup olmadığı incelenmeli, toplam ekipman etkinliğini en iyi açıklayan öznelikler belirlenmeli ve istatistiksel olarak anlamlı olmayan öznelikler modelden çıkarılmalıdır. Bu nedenle adimsal regresyon yönteminden faydalanılmış ve metrekare cinsinden sipariş miktarı, metrekare cinsinden planlanan brüt üretim miktarı, metrekare cinsinden satın alınan levha miktarı, planlı bakım süresi, planlı temizlik süresi, hafta sonu / resmî tatil süresi, yönetim kararıyla / yapısal duruş süresi ve makine hazırlığı süresi isimli öznelikler modelde bırakılmıştır.

Çalışmada; LSTM, Bi-LSTM ve GRU mimarilerinden faydalanılmıştır. Kullanılan mimarilerin tasarımlarında kullanılan hiperparametreler Çizelge 8'de özetlenmiştir. LSTM, Bi-LSTM ve GRU mimarilerinde durum aktivasyon fonksiyonu olarak hiperbolik tanjant sigmoid aktivasyon fonksiyonundan, geçit (kapı) aktivasyon fonksiyonu olarak da sigmoid aktivasyon fonksiyonundan yararlanılmıştır.

Çizelge 8. Derin Sinir Ağları Mimarilerinin Tasarım Hiperparametreleri

Ağ Parametreleri		Değer
Girdi sayısı		8
Gizli katman sayısı		1...100
Çıktı sayısı		1
Veri bölme	Eğitim	% 70
	Doğrulama	% 15
	Test	% 15
Mini yığın büyüklüğü		128
Epoch sayısı		1000
Hata hedefi		0
En İyileme Algoritması		RMSprop, Adam
Başlangıç Öğrenme Oranı		0,001
Bırakma (Dropout) Katmanı Parametresi		0,2

Çalışmada en iyileme algoritması olarak RMSProp ve Adam algoritmalarından faydalanılmıştır.

RMSprop algoritması her bir parametre için farklı öğrenme oranı kullanmaktadır. Bundan dolayı RMSprop algoritması avantajlıdır (Vigneshwaran vd., 2021, s. 7883). RMSprop, Denklem 46’da görüldüğü gibi kare gradyanın hareketli bir ortalamasını alarak her parametre için öğrenme oranını otomatik olarak ayarlar ve gradyan, son gradyan inişlerinin büyüklüğü kullanılarak normalleştirilir (Saab vd., 2022, s. 500).

$$v_i = \beta_2 v_{i-1} + (1 - \beta_2)[E(\theta_i)]^2 \quad (46)$$

Denklemde $E(\theta)$ kayıp fonksiyonunu, v_i varyans hareketli ortalamasını ve β_2 , v_i varyans hareketli ortalamasının bozulma oranını temsil etmekle birlikte parametrenin sonraki güncellenmesi Denklem 47’deki gibi hesaplanır.

$$\theta_{i+1} = \theta_i - \frac{\alpha \nabla E(\theta_i)}{\sqrt{v_i} + \varepsilon} \quad (47)$$

Denklemde θ parametre vektörünü, α öğrenme oranını ve ε sifıra bölmeyi önlemek için eklenen küçük bir sabiti temsil etmektedir (Anilkumar, Manoj ve Sagi, 2021, s. 5).

Adam algoritması, seyrek gradyanlarla iyi çalışan AdaGrad ve doğrusal olmayan ve durağan olmayan durumlarda mükemmel bir performansa sahip RMSProp yöntemlerinin avantajlarını birleştirmektedir. Kolay uygulanması, düşük bellek gereksinimi ve durağan olmayan durumlara uygunluğu Adam algoritmasını etkin ve verimli bir algoritma haline getirmektedir. Özetle, Adam algoritması her bir parametre için öğrenme oranlarını hesaplamaktadır (Chang, Zhang ve Chen, 2019, s. 2; Mohebbanaaz, Padma Sai ve Rajani Kumari, 2022, s. 4). Bu yöntemde, bir sonraki yineleme için ağı parametreleri Denklem 48’deki gibi elde edilir.

$$\theta_{i+1} = \theta_i - \frac{\alpha m_i}{\sqrt{v_i} + \varepsilon} \quad (48)$$

Denklemden θ parametre vektörünü, α öğrenme oranını, m_i ortalama ve v_i varyans hareketli ortalamalarını ve ε sifira bölmeyi önlemek için eklenen küçük bir sabiti temsil etmektedir.

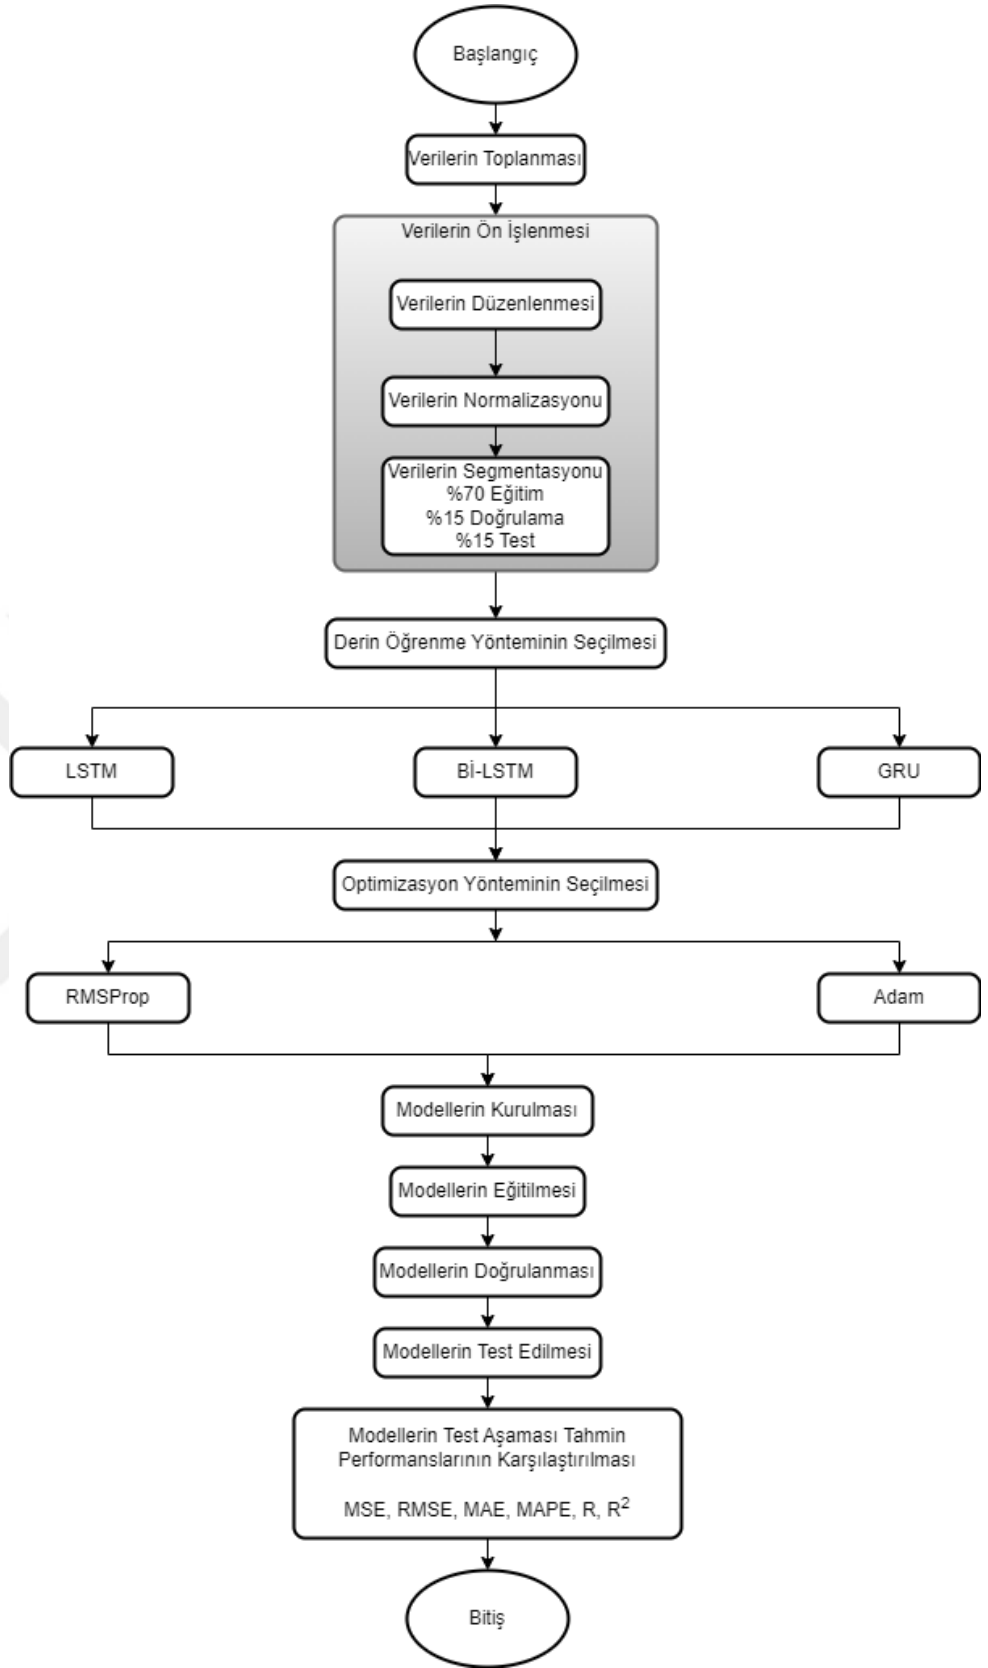
m_i ve v_i hareketli ortalamaları sırasıyla Denklem 49 ve Denklem 50'de gösterildiği gibi hesaplanmaktadır.

$$m_i = \beta_1 m_{i-1} + (1 - \beta_1) \nabla E(\theta_i) \quad (49)$$

$$v_i = \beta_2 v_{i-1} + (1 - \beta_2) [E(\theta_i)]^2 \quad (50)$$

Denklemlerde β_1 ve β_2 , sırasıyla m_i ve v_i hareketli ortalamalarının bozulma oranlarını ve $E(\theta)$ kayıp fonksiyonunu temsil etmektedir (Anilkumar, Manoj ve Sagi, 2021, s. 5).

Bırakma fonksiyonu, belirli bir olasılığa göre ağdaki bazı nöronları rastgele çıkararak aşırı öğrenmeyi önlemektedir. Bırakma fonksiyonu değeri genellikle 0,1 ve 0,5 aralığındadır. Bırakma fonksiyonu değeri ne kadar yüksek olursa, o kadar fazla nöron atılır. Çalışmada bırakma fonksiyonu değeri 0,2 olarak seçilmiştir. Değer 0,2 olduğunda nöronların %20'si atılır. Bırakma fonksiyonuna ek olarak, ilk öğrenme oranı, eğitim sürecinin yakınsama durumunu doğrudan etkilemektedir. Aşırı yüksek bir başlangıç öğrenme oranı, yakınsama olmaması gibi optimal olmayan bir duruma yol açmakta, aşırı düşük bir başlangıç öğrenme oranı ise yavaş bir eğitim sürecine veya öğrenmede başarısızlığa sebep olmaktadır. Başlangıç öğrenme oranının değeri genellikle 0,001 ile 0,01 aralığındadır. Çalışmada RMSprop ve Adam algoritmaları için başlangıç öğrenme oranı 0,001 olarak seçilmiştir (Li vd., 2022, s. 7; Zhang, Bai ve Wang, 2021, s. 6).

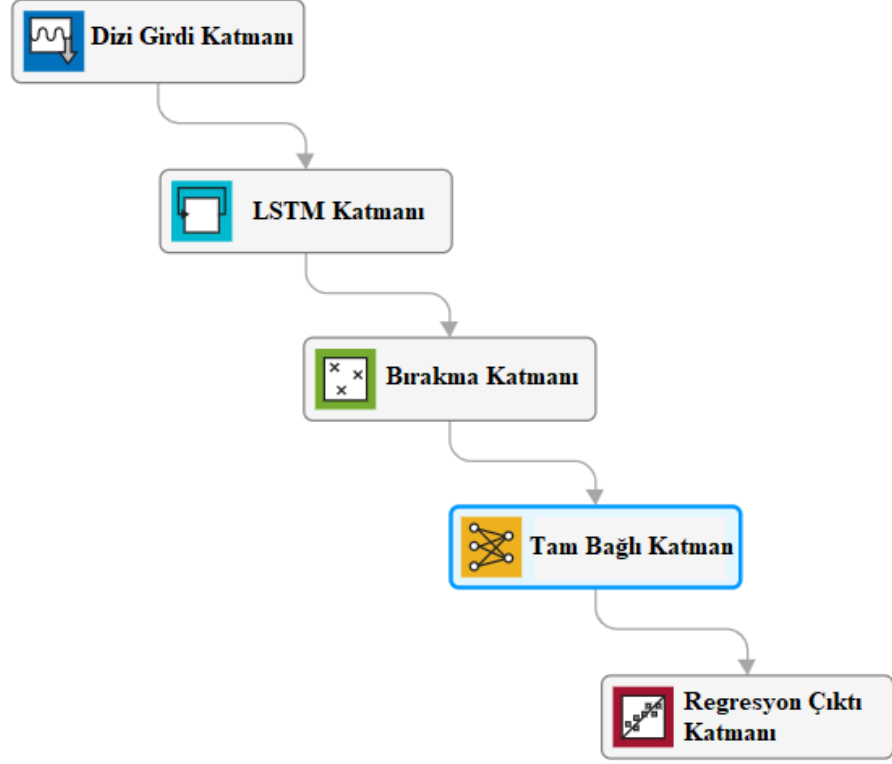


Şekil 23. Toplam Ekipman Etkinliğinin Tahmini İçin Geliştirilen Modellerin Akış Şeması

LSTM, Bi-LSTM ve GRU modellerinin geliştirilmesi sürecinde, gizli katman nöron sayısı 1 ile 100 arasında 1'er 1'er arttırılarak ve optimizasyon işlemi RMSprop ve Adam algoritmalarıyla ayrı ayrı gerçekleştirilerek 200 farklı ağ yapısı üzerine çalışılmıştır. Bu 200 farklı ağ yapısı için analiz 10 defa yinelenmiştir. Özetle, LSTM, Bi-LSTM ve GRU modellerinin her biri için 2000 olmak üzere toplamda 6000 analiz gerçekleştirilmiştir. Ayrıca modeller eğitildikten sonra, modellerin tahmin doğruluğunu değerlendirmek için MSE, RMSE, MAE, MAPE, R ve R^2 performans ölçütlerinden faydalanılmıştır. Tez çalışmasında önerilen modellerin akış diyagramı Şekil 23'te gösterilmiştir.

4.1. Toplam Ekipman Etkinliğinin Tahmin Edilmesi için LSTM Model Mimarilerinin Geliştirilmesi

LSTM model mimarilerinin geliştirilmesi sürecinde, gizli katman nöron sayısı 1 ile 100 arasında 1'er 1'er arttırılarak ve optimizasyon işlemi RMSprop ve Adam algoritmalarıyla ayrı ayrı gerçekleştirilerek toplamda 200 farklı ağ yapısı oluşturulmuştur. Bu 200 farklı ağ yapısı için analiz 10 kez yinelenmiştir. Özetle, LSTM model mimarileri için toplamda 2000 analiz gerçekleştirilmiştir. Ayrıca LSTM model mimarileri eğitildikten sonra, modellerin tahmin doğruluğunu değerlendirmek için MSE, RMSE, MAE, MAPE, R ve R^2 performans ölçütleri kullanılmıştır. Örnek bir LSTM model mimarisi Şekil 24'te gösterilmiştir.



Şekil 24. LSTM Model Mimarisi

LSTM model mimarilerinde, optimizasyon algoritması olarak RMSprop ve Adam algoritmaları kullanılmıştır.

4.1.1. LSTM Model Mimarisinin RMSprop Algoritması ile Optimizasyonu

Toplam ekipman etkinliği değerinin tahmini için geliştirilen, RMSprop algoritması ile optimize edilen tüm LSTM model mimarilerinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük, en küçük ve en iyi değerler, Çizelge 9'da gösterilmiştir. RMSprop algoritması ile optimize edilen tüm LSTM model mimarilerinin eğitilmesi sonucunda elde edilen en iyi MSE, RMSE ve MAE değerlerine gizli katman nöron sayısı 13 olan 6 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 98 olan 9 iterasyon numaralı ağ yapısında, en iyi R ve R^2 değerlerine ise gizli katman nöron sayısı 1 olan 8 iterasyon numaralı ağ yapısında ulaşılmıştır. RMSprop algoritması ile optimize edilen tüm LSTM model mimarilerinin doğrulanması sonucunda elde edilen en iyi MSE, RMSE ve MAE

değerlerine gizli katman nöron sayısı 71 olan 5 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 94 olan 6 iterasyon numaralı ağ yapısında, en iyi R ve R² değerlerine ise gizli katman nöron sayısı 2 olan 7 iterasyon numaralı ağ yapısında ulaşılmıştır. RMSprop algoritması ile optimize edilen tüm LSTM model mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, RMSE, MAE ve MAPE değerlerine gizli katman nöron sayısı 71 olan 5 iterasyon numaralı ağ yapısında, en iyi R ve R² değerlerine ise gizli katman nöron sayısı 1 olan 3 iterasyon numaralı ağ yapısında ulaşılmıştır.

Çizelge 9. RMSprop Algoritması ile Optimize Edilen LSTM Modellerinin Performans Ölçüt Değerleri

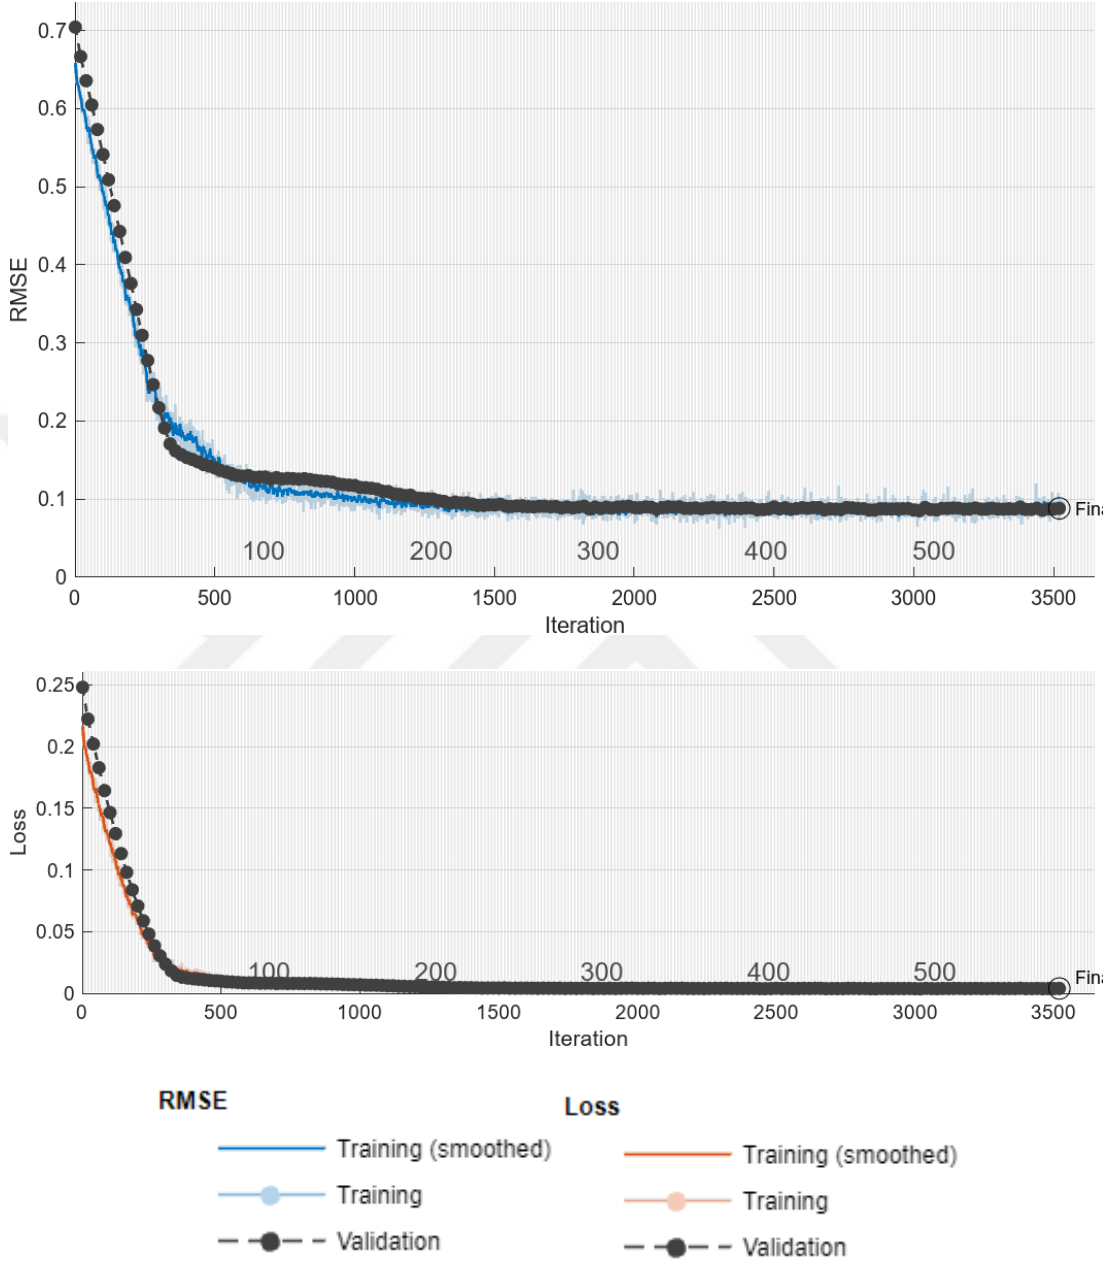
Aşama	Performans Ölçütü	Ortalama	Standart Sapma	En Büyük	En Küçük	En İyi	En İyi Değer için	
							İterasyon No	Gizli Katman Nöron Sayısı
Eğitim	MSE	0,006094	6,98E-05	0,00674	0,006028	0,006028	6	13
	RMSE	0,078063	0,000442	0,082095	0,077642	0,077642	6	13
	MAE	0,060456	0,000593	0,065315	0,059916	0,059916	6	13
	MAPE	0,091611	0,000889	0,098788	0,090627	0,090627	9	98
	R	0,743955	0,000497	0,746064	0,740341	0,746064	8	1
	R ²	0,553469	0,00074	0,556612	0,548105	0,556612	8	1
Doğrulama	MSE	0,006837	0,000595	0,00979	0,005353	0,005353	5	71
	RMSE	0,082608	0,003564	0,098945	0,073167	0,073167	5	71
	MAE	0,068213	0,00325	0,08397	0,059731	0,059731	5	71
	MAPE	0,138764	0,003895	0,158877	0,129843	0,129843	6	94
	R	0,875609	0,000335	0,878537	0,874491	0,878537	7	2
	R ²	0,766692	0,000588	0,771827	0,764735	0,771827	7	2
Test	MSE	0,005107	0,000472	0,007483	0,00399	0,00399	5	71
	RMSE	0,07139	0,003262	0,086503	0,063167	0,063167	5	71
	MAE	0,058627	0,003214	0,073714	0,050358	0,050358	5	71
	MAPE	0,081184	0,003791	0,09872	0,072065	0,072065	5	71
	R	0,889431	0,00082	0,892044	0,885789	0,892044	3	1
	R ²	0,791088	0,001458	0,795743	0,784622	0,795743	3	1

Chicco, Warrens ve Jurman (2021, s. 1) çalışmalarında, regresyon analizi değerlendirmelerinde R^2 belirlilik katsayısının MAE, MAPE, MSE ve RMSE'den daha bilgilendirici olduğu sonucuna varmışlardır. Bu nedenle, bu ve bundan sonraki yöntem-optimizasyon algoritması kombinasyonlarına göre geliştirilen model mimarilerinden optimal performans göstereni, test aşamasında elde edilen en yüksek R^2 belirlilik katsayısına göre belirlenecektir. Bu kabule göre, RMSprop algoritması ile optimize edilen LSTM model mimarilerinin test edilmesi sonucunda en yüksek R^2 değeri, gizli katman nöron sayısı 1 olan 3 iterasyon numaralı modelle elde edilmiştir. Çizelge 10'da optimal performans gösteren, RMSprop algoritması ile optimize edilen LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans değerleri verilmiştir.

Çizelge 10. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen LSTM Modelinin Performans Ölçüt Değerleri


Performans Ölçütü	Aşama		
	Eğitim	Doğrulama	Test
MSE	0,006362	0,007753	0,005917
RMSE	0,079763	0,08805	0,076921
MAE	0,062227	0,072154	0,063924
MAPE	0,097927	0,155133	0,092001
R	0,745147	0,876884	0,892044
R^2	0,555243	0,768925	0,795743

Optimal performans gösteren, RMSprop algoritması ile optimize edilen LSTM modelinin eğitim seyri Şekil 25'te gösterilmiştir.



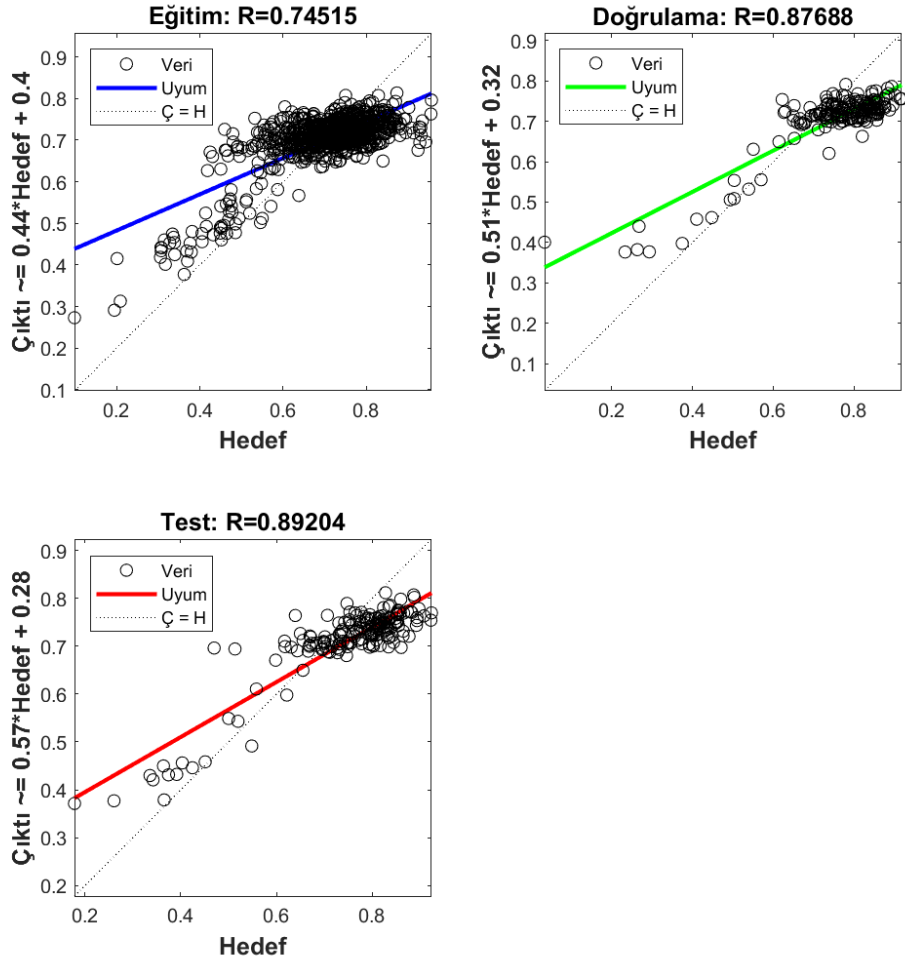
Şekil 25. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen LSTM Modelinin Eğitim Seyri

Optimal performans gösteren, RMSprop ile optimize edilen LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerlerinin zaman içindeki seyri, Şekil 26’da gösterilmiştir.



Şekil 26. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen LSTM Modelinin Çıkıtı Değerleri ile Hedef Değerler

Optimal performans gösteren, RMSprop ile optimize edilen LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerleri arasındaki regresyon grafiği Şekil 27’de gösterilmiştir. Şekilden de görüldüğü gibi eğitim, doğrulama ve test aşamaları için hesaplanan korelasyon değerleri sırasıyla 0,74515, 0,87688 ve 0,89204 olarak elde edilmiştir. Bu değerler, optimal performans gösteren, RMSprop ile optimize edilen LSTM modelinin çıktılarının hedeflerle uyum içinde olduğunu göstermektedir.



Şekil 27. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen LSTM Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları

4.1.2. LSTM Model Mimarisinin Adam Algoritması ile Optimizasyonu

Toplam ekipman etkinliği değerinin tahmini için geliştirilen, Adam algoritması ile optimize edilen tüm LSTM model mimarilerinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük, en küçük ve en iyi değerler Çizelge 11’de gösterilmiştir. Adam algoritması ile optimize edilen tüm LSTM model mimarilerinin eğitilmesi sonucunda elde edilen en iyi MSE ve RMSE değerlerine gizli katman nöron sayısı 61 olan 5 iterasyon numaralı ağ yapısında, en iyi MAE değerine gizli katman nöron sayısı 83 olan 9 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 23 olan 3 iterasyon numaralı ağ yapısında, en iyi R ve R^2 değerlerine ise gizli katman nöron sayısı 10 olan 3 iterasyon numaralı ağ yapısında ulaşılmıştır. Adam

algoritması ile optimize edilen tüm LSTM model mimarilerinin doğrulanması sonucunda elde edilen en iyi MSE, RMSE ve MAE değerlerine gizli katman nöron sayısı 64 olan 5 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 83 olan 10 iterasyon numaralı ağ yapısında, en iyi R ve R² değerlerine ise gizli katman nöron sayısı 9 olan 9 iterasyon numaralı ağ yapısında ulaşılmıştır. Adam algoritması ile optimize edilen LSTM model mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, RMSE, MAE ve MAPE değerlerine gizli katman nöron sayısı 64 olan 5 iterasyon numaralı ağ yapısında, en iyi R ve R² değerlerine ise gizli katman nöron sayısı 19 olan 1 iterasyon numaralı ağ yapısında ulaşılmıştır.

Çizelge 11. Adam Algoritması ile Optimize Edilen LSTM Modellerinin Performans Ölçüt Değerleri

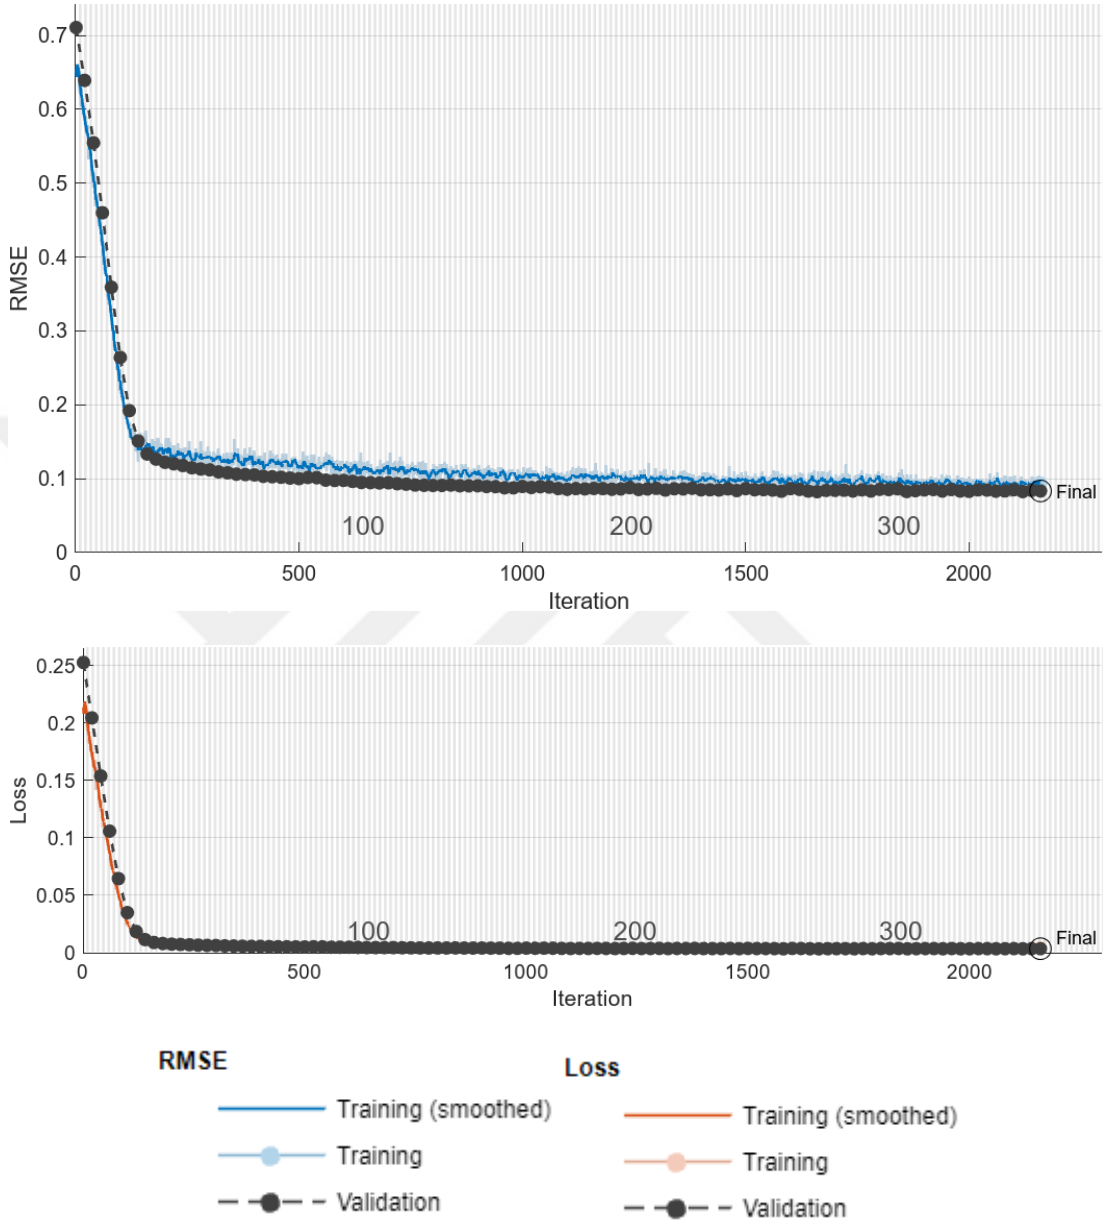
Aşama	Performans Ölçütü	Ortalama	Standart Sapma	En Büyük	En Küçük	En İyi	En İyi Değer için	
							İterasyon No	Gizli Katman Nöron Sayısı
Eğitim	MSE	0,006077	6,51E-05	0,006717	0,006026	0,006026	5	61
	RMSE	0,077957	0,000413	0,081959	0,077627	0,077627	5	61
	MAE	0,060360	0,000443	0,064031	0,059905	0,059905	9	83
	MAPE	0,091236	0,001145	0,102505	0,090419	0,090419	3	23
	R	0,743627	0,001521	0,746269	0,728187	0,746269	3	10
	R ²	0,552984	0,00225	0,556917	0,530256	0,556917	3	10
Doğrulama	MSE	0,006923	0,000316	0,008488	0,006234	0,006234	5	64
	RMSE	0,083182	0,001884	0,092132	0,078958	0,078958	5	64
	MAE	0,068779	0,001633	0,075520	0,064920	0,06492	5	64
	MAPE	0,138298	0,003577	0,167823	0,133701	0,133701	10	83
	R	0,876315	0,00089	0,879724	0,866374	0,879724	9	9
	R ²	0,767929	0,001558	0,773914	0,750604	0,773914	9	9
Test	MSE	0,005196	0,000301	0,006706	0,004594	0,004594	5	64
	RMSE	0,072051	0,002059	0,081890	0,067780	0,067780	5	64
	MAE	0,059234	0,001989	0,068358	0,054996	0,054996	5	64
	MAPE	0,081598	0,00279	0,099538	0,076688	0,076688	5	64
	R	0,889688	0,001542	0,892522	0,878044	0,892522	1	19
	R ²	0,791547	0,002737	0,796595	0,770962	0,796595	1	19

Adam algoritması ile optimize edilen LSTM model mimarilerinin test edilmesi sonucunda en yüksek R^2 değeri, gizli katman nöron sayısı 19 olan 1 iterasyon numaralı modelle elde edilmiştir. Çizelge 12’de optimal performans gösteren, Adam algoritması ile optimize edilen LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans değerleri verilmiştir.

Çizelge 12. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen LSTM Modelinin Performans Ölçüt Değerleri


Performans Ölçütü	Aşama		
	Eğitim	Doğrulama	Test
MSE	0,006043	0,006947	0,005189
RMSE	0,077737	0,083351	0,072031
MAE	0,060154	0,068851	0,059097
MAPE	0,090525	0,135012	0,080667
R	0,74531	0,87816	0,892522
R^2	0,555487	0,771166	0,796595

Optimal performans gösteren, Adam algoritması ile optimize edilen LSTM modelinin eğitim seyri Şekil 28’de gösterilmiştir.



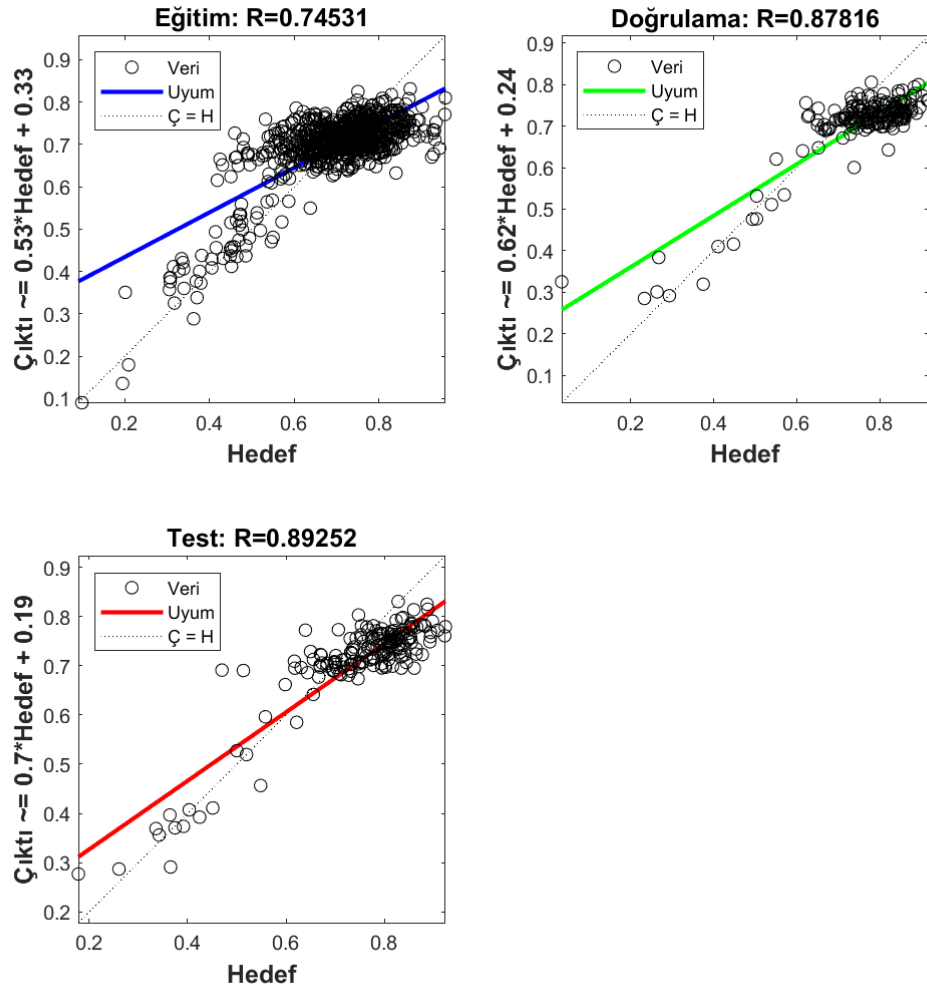
Şekil 28. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen LSTM Modelinin Eğitim Seyri

Optimal performans gösteren, Adam ile optimize edilen LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerlerinin zaman içindeki seyri Şekil 29’da gösterilmiştir.



Şekil 29. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen LSTM Modelinin Çıktı Değerleri ile Hedef Değerler

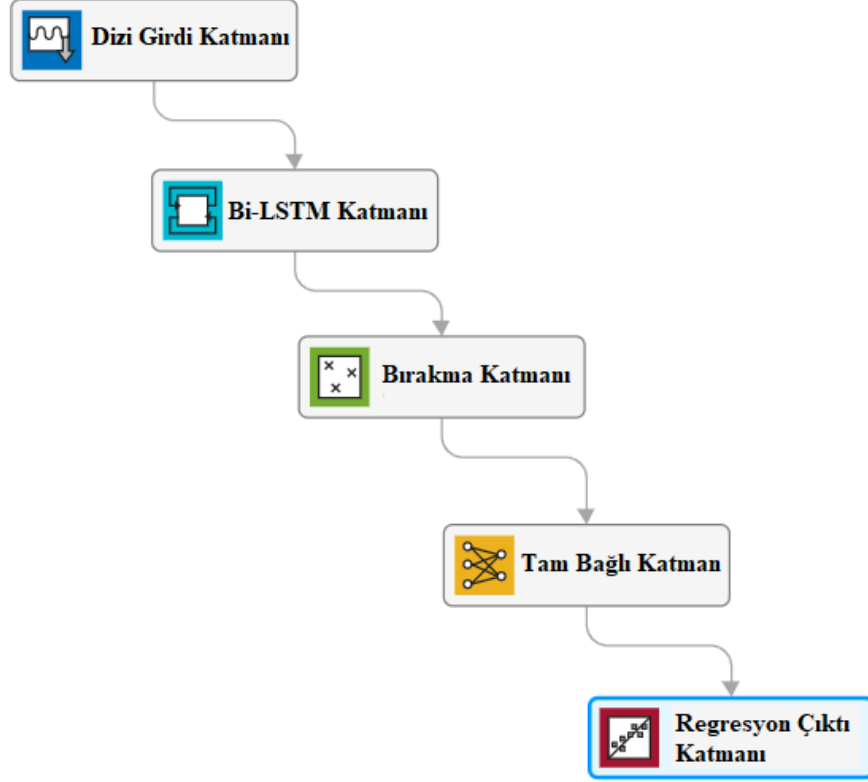
Optimal performans gösteren, Adam ile optimize edilen LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerleri arasındaki regresyon grafiği Şekil 30’da gösterilmiştir. Şekilden de görüldüğü gibi eğitim, doğrulama ve test aşamaları için hesaplanan korelasyon değerleri sırasıyla 0,74531, 0,87816 ve 0,89252 olarak elde edilmiştir. Bu değerler, optimal performans gösteren, Adam ile optimize edilen LSTM modelinin çıktılarının hedeflerle uyum içinde olduğunu göstermektedir.



Şekil 30. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen LSTM Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları

4.2. Toplam Ekipman Etkinliğinin Tahmin Edilmesi için Bi-LSTM Model Mimarilerinin Geliştirilmesi

Bi-LSTM model mimarilerinin geliştirilmesi sürecinde, gizli katman nöron sayısı 1 ile 100 arasında 1'er 1'er artırılarak ve optimizasyon işlemi RMSprop ve Adam algoritmalarıyla ayrı ayrı gerçekleştirilerek toplamda 200 farklı ağ yapısı oluşturulmuştur. Bu 200 farklı ağ yapısı için analiz 10 kez yinelenmiştir. Özetle, Bi-LSTM model mimarileri için toplamda 2000 analiz gerçekleştirilmiştir. Ayrıca Bi-LSTM model mimarileri eğitildikten sonra, modellerin tahmin doğruluğunu değerlendirmek için MSE, RMSE, MAE, MAPE, R ve R^2 performans ölçütleri kullanılmıştır. Örnek bir Bi-LSTM model mimarisi Şekil 31'de gösterilmiştir.



Şekil 31. Bi-LSTM Model Mimarisi

Bi-LSTM model mimarilerinde, optimizasyon algoritması olarak RMSprop ve Adam algoritmaları kullanılmıştır.

4.2.1. Bi-LSTM Model Mimarisinin RMSprop Algoritması ile Optimizasyonu

Toplam ekipman etkinliği değerinin tahmini için geliştirilen, RMSprop algoritması ile optimize edilen tüm Bi-LSTM model mimarilerinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük, en küçük ve en iyi değerler Çizelge 13'te gösterilmiştir. RMSprop algoritması ile optimize edilen tüm Bi-LSTM model mimarilerinin eğitilmesi sonucunda elde edilen en iyi MSE ve RMSE değerlerine gizli katman nöron sayısı 8 olan 10 iterasyon numaralı ağ yapısında, en iyi MAE değerine gizli katman nöron sayısı 6 olan 10 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 93 olan 7 numaralı ağ yapısında, en iyi R ve R^2 değerlerine ise gizli katman nöron sayısı 1 olan 3 iterasyon numaralı ağ yapısında ulaşılmıştır. RMSprop algoritması ile optimize edilen Bi-LSTM model mimarilerinin

doğrulanması sonucunda elde edilen en iyi MSE, RMSE, MAE ve MAPE değerlerine gizli katman nöron sayısı 99 olan 7 iterasyon numaralı ağ yapısında, en iyi R ve R² değerlerine ise gizli katman nöron sayısı 1 olan 7 iterasyon numaralı ağ yapısında ulaşılmıştır. RMSprop algoritması ile optimize edilen tüm Bi-LSTM model mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, RMSE, MAE ve MAPE değerlerine gizli katman nöron sayısı 99 olan 7 iterasyon numaralı ağ yapısında, en iyi R ve R² değerlerine ise gizli katman nöron sayısı 79 olan 10 iterasyon numaralı ağ yapısında ulaşılmıştır.

Çizelge 13. RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modellerinin Performans Ölçüt Değerleri

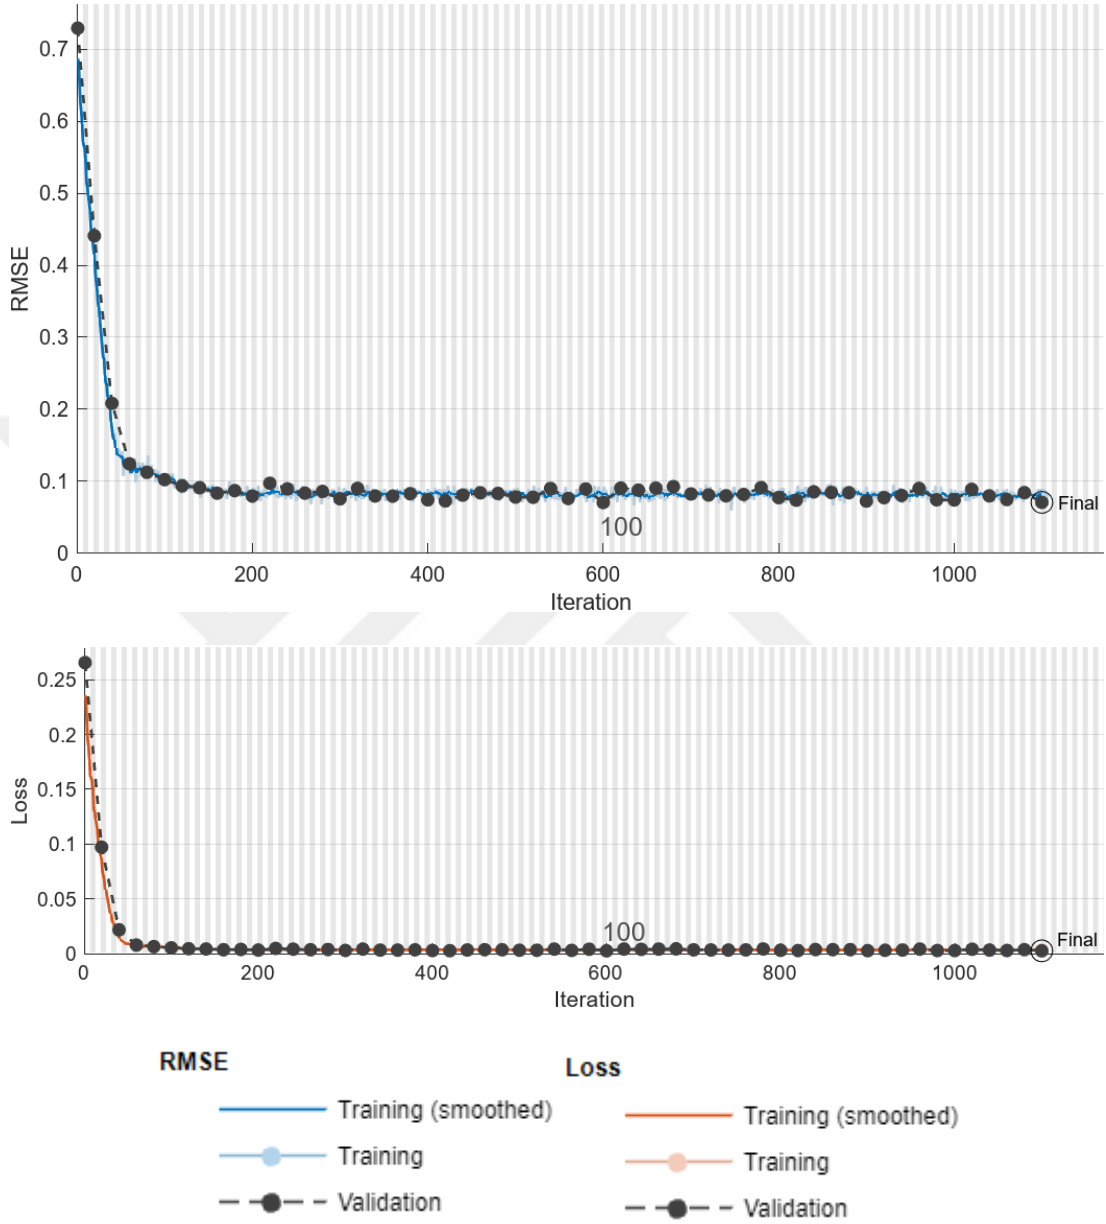
Aşama	Performans Ölçütü	Ortalama	Standart Sapma	En Büyük	En Küçük	En İyi	En İyi Değer için	
							İterasyon No	Gizli Katman Nöron Sayısı
Eğitim	MSE	0,006115	9,1E-05	0,006683	0,006036	0,006036	10	8
	RMSE	0,078198	0,000577	0,081751	0,07769	0,07769	10	8
	MAE	0,060594	0,000726	0,064938	0,059911	0,059911	10	6
	MAPE	0,09171	0,000933	0,098376	0,090641	0,090641	7	93
	R	0,743916	0,000382	0,74665	0,73968	0,74665	3	1
	R ²	0,553411	0,000568	0,557486	0,547126	0,557486	3	1
Doğrulama	MSE	0,006796	0,000791	0,009571	0,004753	0,004753	7	99
	RMSE	0,082302	0,004773	0,097834	0,068943	0,068943	7	99
	MAE	0,067979	0,004392	0,082996	0,055542	0,055542	7	99
	MAPE	0,137997	0,00458	0,154347	0,125879	0,125879	7	99
	R	0,875511	0,000335	0,877177	0,874531	0,877177	7	1
	R ²	0,76652	0,000586	0,769439	0,764805	0,769439	7	1
Test	MSE	0,005063	0,000614	0,007317	0,003639	0,003639	7	99
	RMSE	0,071024	0,004284	0,085537	0,060325	0,060325	7	99
	MAE	0,058251	0,004257	0,072711	0,046972	0,046972	7	99
	MAPE	0,080617	0,004816	0,097311	0,068737	0,068737	7	99
	R	0,889743	0,000818	0,891331	0,884651	0,891331	10	79
	R ²	0,791643	0,001455	0,794471	0,782608	0,794471	10	79

RMSprop algoritması ile optimize edilen Bi-LSTM model mimarilerinin test edilmesi sonucunda en yüksek R^2 değeri, gizli katman nöron sayısı 79 olan 10 iterasyon numaralı modelle elde edilmiştir. Çizelge 14’te optimal performans gösteren, RMSprop algoritması ile optimize edilen Bi-LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans değerleri verilmiştir.

Çizelge 14. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modelinin Performans Ölçüt Değerleri

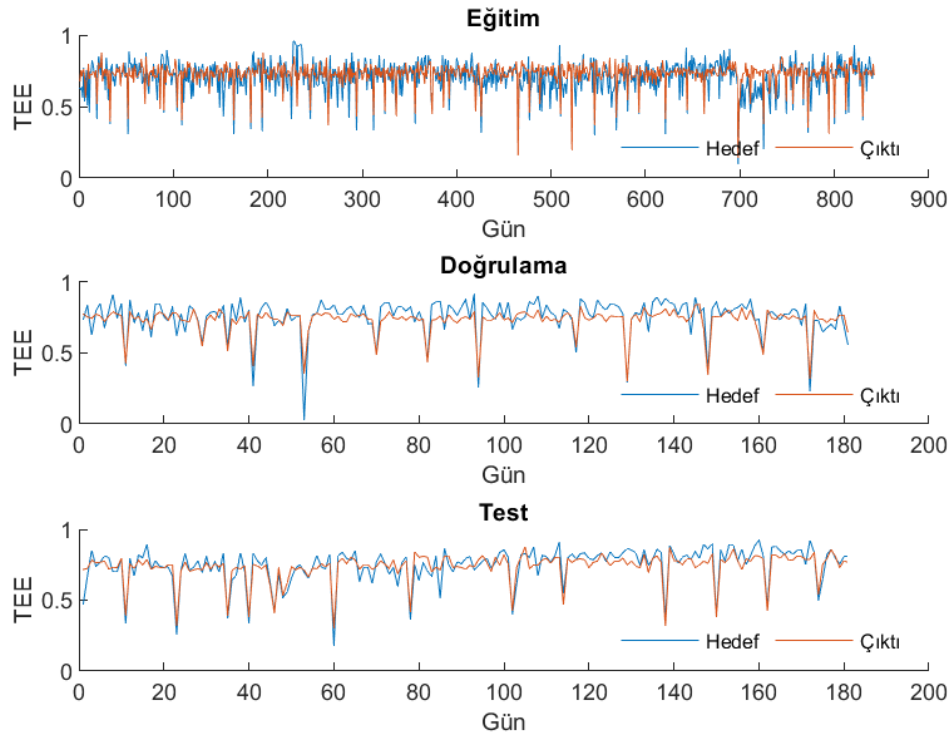
Performans Ölçütü	Aşama		
	Eğitim	Doğrulama	Test
MSE	0,00648	0,005017	0,003775
RMSE	0,080497	0,070833	0,06144
MAE	0,062018	0,057201	0,048185
MAPE	0,096915	0,128457	0,070288
R	0,74346	0,874813	0,891331
R^2	0,552732	0,765297	0,794471

Optimal performans gösteren, RMSprop algoritması ile optimize edilen Bi-LSTM modelinin eğitim seyri Şekil 32’de gösterilmiştir.



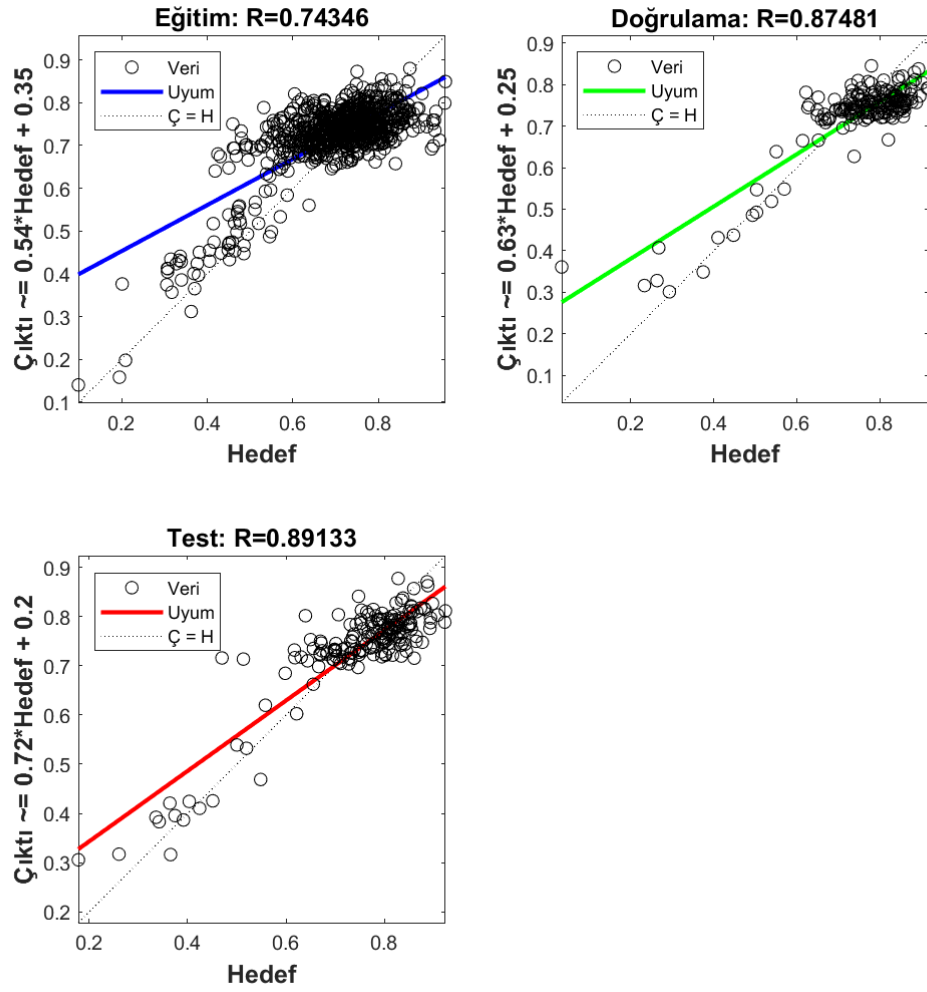
Şekil 32. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modelinin Eğitim Seyri

Optimal performans gösteren, RMSprop ile optimize edilen Bi-LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerlerinin zaman içindeki seyri Şekil 33'te gösterilmiştir.



Şekil 33. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modelinin Çıkıtı Değerleri ile Hedef Değerler

Optimal performans gösteren, RMSprop ile optimize edilen Bi-LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerleri arasındaki regresyon grafiği Şekil 34'te gösterilmiştir. Şekilden de görüldüğü gibi eğitim, doğrulama ve test aşamaları için hesaplanan korelasyon değerleri sırasıyla 0,74346, 0,87481 ve 0,89133 olarak elde edilmiştir. Bu değerler, optimal performans gösteren, RMSprop ile optimize edilen Bi-LSTM modelinin çıktılarının hedeflerle uyum içinde olduğunu göstermektedir.



Şekil 34. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen Bi-LSTM Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları

4.2.2. Bi-LSTM Model Mimarisinin Adam Algoritması ile Optimizasyonu

Toplam ekipman etkinliği değerinin tahmini için geliştirilen, Adam algoritması ile optimize edilen tüm Bi-LSTM model mimarilerinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük, en küçük ve en iyi değerler Çizelge 15'te gösterilmiştir. Adam algoritması ile optimize edilen tüm Bi-LSTM model mimarilerinin eğitilmesi sonucunda elde edilen en iyi MSE ve RMSE değerlerine gizli katman nöron sayısı 15 olan 1 iterasyon numaralı ağ yapısında, en iyi MAE değerine gizli katman nöron sayısı 16 olan 2 numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 15 olan 3 numaralı ağ yapısında, en iyi R ve R^2 değerlerine ise gizli katman nöron sayısı 4 olan 9 iterasyon numaralı ağ yapısında ulaşılmıştır. Adam algoritması ile optimize

edilen tüm Bi-LSTM model mimarilerinin doğrulanması sonucunda elde edilen en iyi MSE, RMSE ve MAE değerlerine gizli katman nöron sayısı 90 olan 4 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 77 olan 5 iterasyon numaralı ağ yapısında, en iyi R ve R^2 değerlerine ise gizli katman nöron sayısı 3 olan 7 iterasyon numaralı ağ yapısında ulaşılmıştır. Adam algoritması ile optimize edilen tüm Bi-LSTM model mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, RMSE, MAE ve MAPE değerlerine gizli katman nöron sayısı 90 olan 4 iterasyon numaralı ağ yapısında, en iyi R ve R^2 değerlerine ise gizli katman nöron sayısı 15 olan 3 iterasyon numaralı ağ yapısında ulaşılmıştır.

Çizelge 15. Adam Algoritması ile Optimize Edilen Bi-LSTM Modellerinin Performans Ölçüt Değerleri


Aşama	Performans Ölçütü	Ortalama	Standart Sapma	En Büyük	En Küçük	En İyi	En İyi Değer için	
							İterasyon No	Gizli Katman Nöron Sayısı
Eğitim	MSE	0,006063	4,12E-05	0,006422	0,006026	0,006026	1	15
	RMSE	0,077863	0,000263	0,080138	0,077628	0,077628	1	15
	MAE	0,060246	0,00032	0,062513	0,05989	0,05989	2	16
	MAPE	0,091048	0,000613	0,096663	0,090471	0,090471	3	15
	R	0,743797	0,001071	0,747839	0,731448	0,747839	9	4
	R^2	0,553236	0,001587	0,559263	0,535016	0,559263	9	4
Doğrulama	MSE	0,006794	0,000311	0,008247	0,00604	0,00604	4	90
	RMSE	0,082404	0,001875	0,090813	0,077715	0,077715	4	90
	MAE	0,068101	0,00166	0,075775	0,063942	0,063942	4	90
	MAPE	0,137238	0,002538	0,152515	0,132712	0,132712	5	77
	R	0,876048	0,000707	0,879745	0,871186	0,879745	7	3
	R^2	0,76746	0,001239	0,77395	0,758965	0,77395	7	3
Test	MSE	0,005063	0,000282	0,006633	0,00444	0,00444	4	90
	RMSE	0,071126	0,001956	0,081444	0,066632	0,066632	4	90
	MAE	0,058346	0,001917	0,068342	0,053806	0,053806	4	90
	MAPE	0,080443	0,002409	0,093495	0,075333	0,075333	4	90
	R	0,890041	0,00112	0,89216	0,879099	0,89216	3	15
	R^2	0,792174	0,001988	0,795949	0,772814	0,795949	3	15

Adam algoritması ile optimize edilen Bi-LSTM model mimarilerinin test edilmesi sonucunda en yüksek R^2 değeri, gizli katman nöron sayısı 15 olan 3 iterasyon numaralı modelle elde edilmiştir. Çizelge 16’da optimal performans gösteren, Adam algoritması ile optimize edilen Bi-LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans değerleri verilmiştir.

Çizelge 16. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen Bi-LSTM Modelinin Performans Ölçüt Değerleri


Performans Ölçütü	Aşama		
	Eğitim	Doğrulama	Test
MSE	0,006039	0,006948	0,005194
RMSE	0,077711	0,083352	0,072066
MAE	0,060153	0,068971	0,059286
MAPE	0,090471	0,135328	0,08088
R	0,745154	0,877755	0,89216
R^2	0,555255	0,770453	0,795949

Optimal performans gösteren, Adam algoritması ile optimize edilen Bi-LSTM modelinin eğitim seyri Şekil 35'te gösterilmiştir.



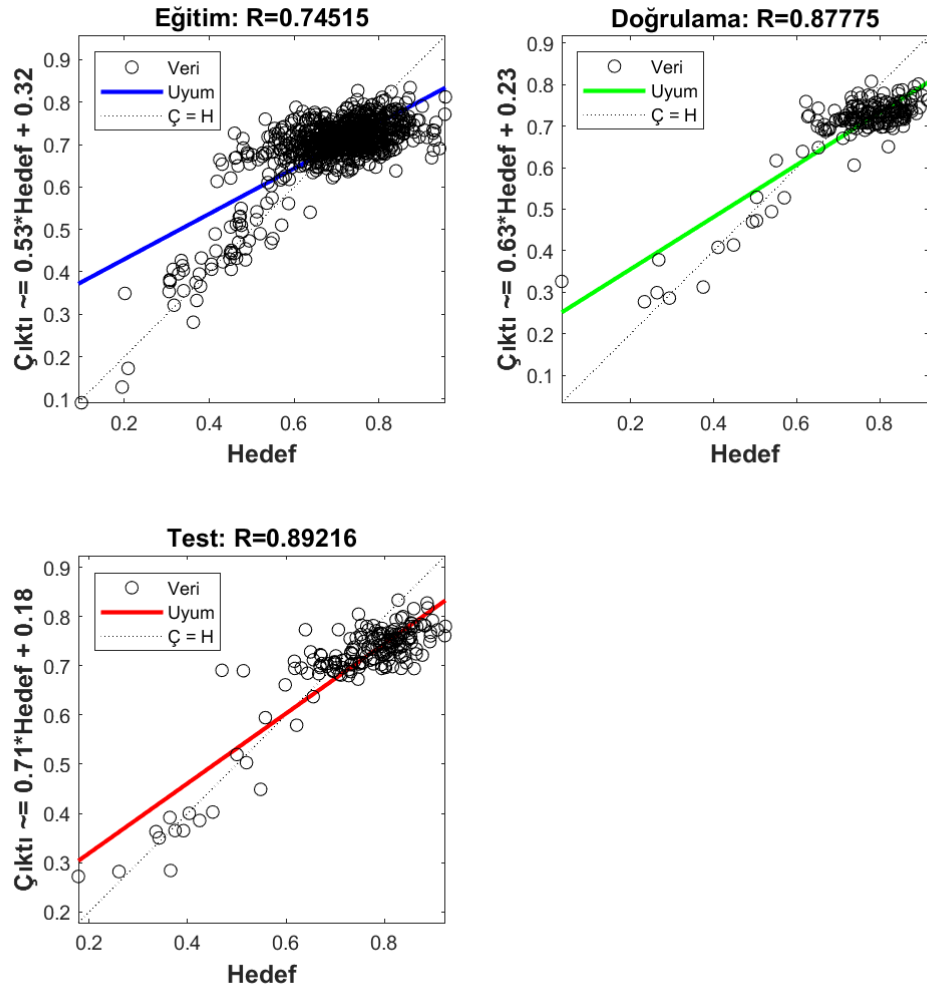
Şekil 35. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen Bi-LSTM Modelinin Eğitim Seyri

Optimal performans gösteren, Adam ile optimize edilen Bi-LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerlerinin zaman içindeki seyri Şekil 36’da gösterilmiştir.



Şekil 36. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen Bi-LSTM Modelinin Çıkıtı Değerleri ile Hedef Değerler

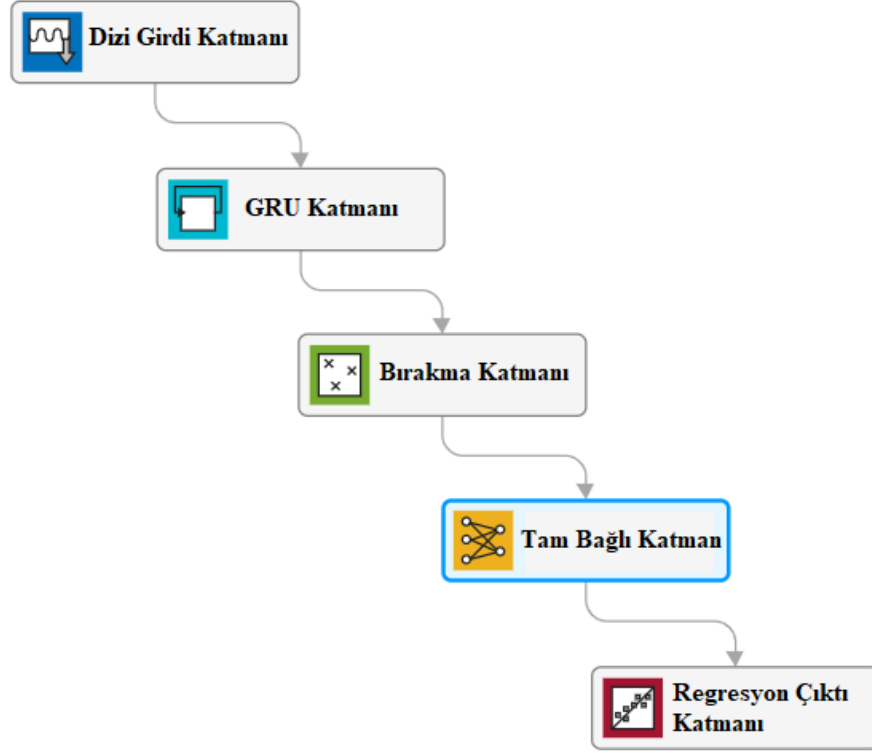
Optimal performans gösteren, Adam ile optimize edilen Bi-LSTM modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerleri arasındaki regresyon grafiği Şekil 37’de gösterilmiştir. Şekilden de görüldüğü gibi eğitim, doğrulama ve test aşamaları için hesaplanan korelasyon değerleri sırasıyla 0,74515, 0,87775 ve 0,89216 olarak elde edilmiştir. Bu değerler, optimal performans gösteren, Adam ile optimize edilen Bi-LSTM modelinin çıktılarının hedeflerle uyum içinde olduğunu göstermektedir.



Şekil 37. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen Bi-LSTM Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları

4.3. Toplam Ekipman Etkinliğinin Tahmin Edilmesi için GRU Model Mimarilerinin Geliştirilmesi

GRU model mimarilerinin geliştirilmesi sürecinde, gizli katman nöron sayısı 1 ile 100 arasında 1'er 1'er artırılarak ve optimizasyon işlemi RMSprop ve Adam algoritmalarıyla ayrı ayrı gerçekleştirilerek toplamda 200 farklı ağ yapısı oluşturulmuştur. Bu 200 farklı ağ yapısı için analiz 10 kez yinelenmiştir. Özetle, GRU model mimarileri için toplamda 2000 analiz gerçekleştirilmiştir. Ayrıca GRU model mimarileri eğitildikten sonra, modellerin tahmin doğruluğunu değerlendirmek için MSE, RMSE, MAE, MAPE, R ve R^2 performans ölçütleri kullanılmıştır. Örnek bir GRU model mimarisi Şekil 38'de gösterilmiştir.



Şekil 38. GRU Model Mimarisi

GRU model mimarilerinde, optimizasyon algoritması olarak RMSprop ve Adam algoritmaları kullanılmıştır.

4.3.1. GRU Model Mimarisinin RMSprop Algoritması ile Optimizasyonu

Toplam ekipman etkinliği değerinin tahmini için geliştirilen, RMSprop algoritması ile optimize edilen tüm GRU model mimarilerinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük, en küçük ve en iyi değerler Çizelge 17’de gösterilmiştir. RMSprop algoritması ile optimize edilen tüm GRU model mimarilerinin eğitilmesi sonucunda elde edilen en iyi MSE ve RMSE değerlerine gizli katman nöron sayısı 53 olan 10 iterasyon numaralı ağ yapısında, en iyi MAE değerine gizli katman nöron sayısı 25 olan 7 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 76 olan 5 iterasyon numaralı ağ yapısında, en iyi R ve R^2 değerlerine ise gizli katman nöron sayısı 4 olan 1 iterasyon numaralı ağ yapısında ulaşılmıştır. RMSprop algoritması ile optimize edilen tüm GRU model mimarilerinin doğrulanması sonucunda elde edilen en iyi MSE, RMSE ve MAE değerlerine gizli

katman nöron sayısı 90 olan 3 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 100 olan 5 iterasyon numaralı ağ yapısında, en iyi R ve R² değerlerine ise gizli katman nöron sayısı 1 olan 7 iterasyon numaralı ağ yapısında ulaşılmıştır. RMSprop algoritması ile optimize edilen tüm GRU model mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, RMSE, MAE ve MAPE değerlerine gizli katman nöron sayısı 90 olan 3 iterasyon numaralı ağ yapısında, en iyi R ve R² değerlerine ise gizli katman nöron sayısı 2 olan 1 iterasyon numaralı ağ yapısında ulaşılmıştır.

Çizelge 17. RMSprop Algoritması ile Optimize Edilen GRU Modellerinin Performans Ölçüt Değerleri

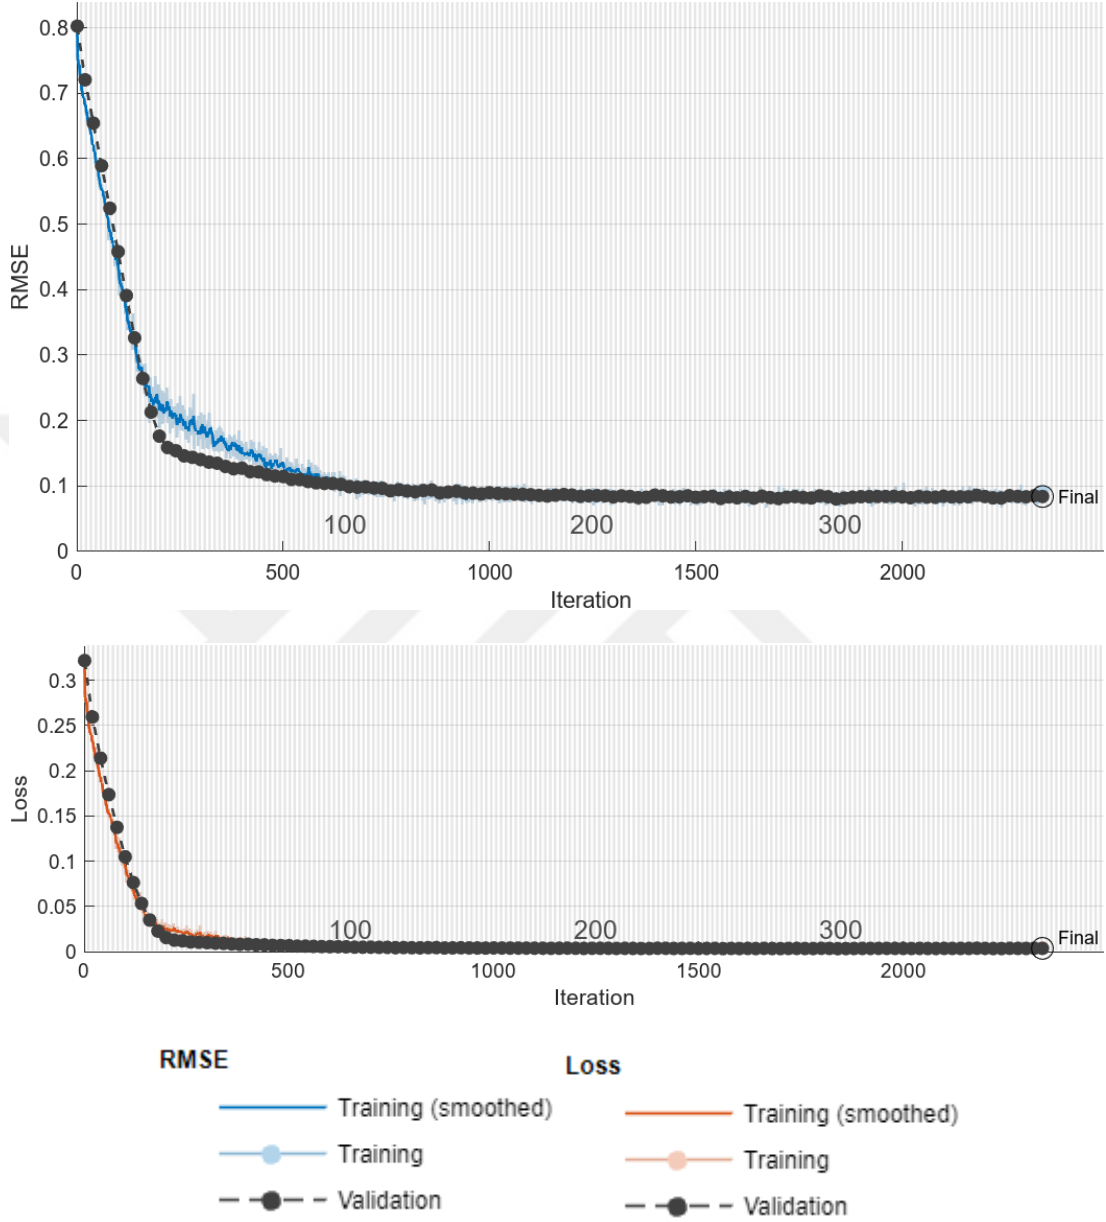
Aşama	Performans Ölçütü	Ortalama	Standart Sapma	En Büyük	En Küçük	En İyi	En İyi Değer için	
							İterasyon No	Gizli Katman Nöron Sayısı
Eğitim	MSE	0,006104	0,000106	0,006958	0,006024	0,006024	10	53
	RMSE	0,078126	0,000672	0,083416	0,077614	0,077614	10	53
	MAE	0,060526	0,000842	0,066737	0,05978	0,05978	7	25
	MAPE	0,091468	0,001098	0,098858	0,090502	0,090502	5	76
	R	0,744338	0,00047	0,746454	0,737189	0,746454	1	4
	R ²	0,55404	0,000699	0,557194	0,543448	0,557194	1	4
Doğrulama	MSE	0,006807	0,000782	0,010269	0,00483	0,00483	3	90
	RMSE	0,082372	0,004686	0,101335	0,069502	0,069502	3	90
	MAE	0,068103	0,004315	0,08684	0,056489	0,056489	3	90
	MAPE	0,137718	0,004837	0,156813	0,126418	0,126418	5	100
	R	0,875242	0,000511	0,878563	0,871719	0,878563	7	1
	R ²	0,766049	0,000895	0,771874	0,759894	0,771874	7	1
Test	MSE	0,00509	0,000615	0,008005	0,0037	0,0037	3	90
	RMSE	0,071216	0,00425	0,08947	0,060827	0,060827	3	90
	MAE	0,058502	0,004231	0,076751	0,047342	0,047342	3	90
	MAPE	0,080845	0,004942	0,102299	0,068631	0,068631	3	90
	R	0,88948	0,000801	0,892125	0,885797	0,892125	1	2
	R ²	0,791176	0,001425	0,795888	0,784637	0,795888	1	2

RMSprop algoritması ile optimize edilen GRU model mimarilerinin test edilmesi sonucunda en yüksek R^2 değeri, gizli katman nöron sayısı 2 olan 1 iterasyon numaralı modelle elde edilmiştir. Çizelge 18’de optimal performans gösteren, RMSprop algoritması ile optimize edilen GRU modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans değerleri verilmiştir.

Çizelge 18. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen GRU Modelinin Performans Ölçüt Değerleri


Performans Ölçütü	Aşama		
	Eğitim	Doğrulama	Test
MSE	0,006139	0,007031	0,005217
RMSE	0,07835	0,083854	0,072228
MAE	0,06086	0,068518	0,059489
MAPE	0,093782	0,143762	0,083897
R	0,745977	0,876165	0,892125
R^2	0,556481	0,767665	0,795888

Optimal performans gösteren, RMSprop algoritması ile optimize edilen GRU modelinin eğitim seyri Şekil 39'da gösterilmiştir.



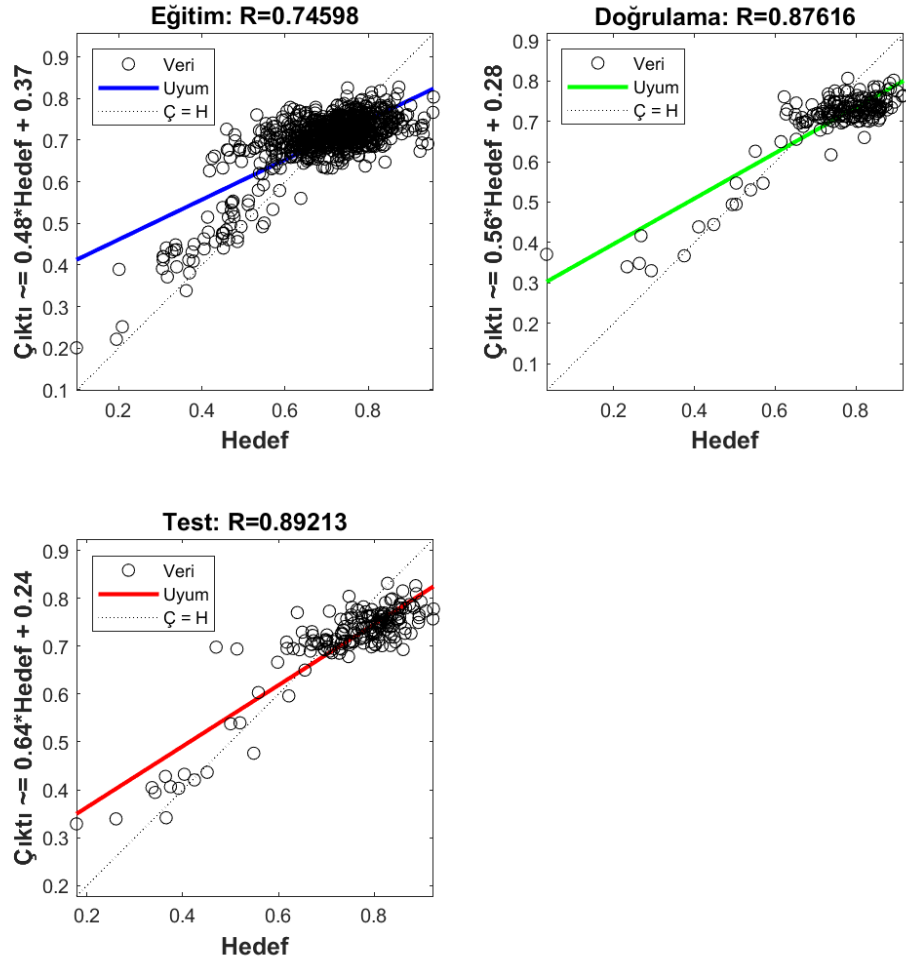
Şekil 39. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen GRU Modelinin Eğitim Seyri

Optimal performans gösteren, RMSprop ile optimize edilen GRU modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerlerinin zaman içindeki seyri Şekil 40'ta gösterilmiştir.



Şekil 40. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen GRU Modelinin Çıktı Değerleri ile Hedef Değerler

Optimal performans gösteren, RMSprop ile optimize edilen GRU modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerleri arasındaki regresyon grafiği Şekil 41'de gösterilmiştir. Şekilden de görüldüğü gibi eğitim, doğrulama ve test aşamaları için hesaplanan korelasyon değerleri sırasıyla 0,74598, 0,87616 ve 0,89213 olarak elde edilmiştir. Bu değerler, optimal performans gösteren, RMSprop ile optimize edilen GRU modelinin çıktılarının hedeflerle uyum içinde olduğunu göstermektedir.



Şekil 41. Optimal Performans Gösteren, RMSprop Algoritması ile Optimize Edilen GRU Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları

4.3.2. GRU Model Mimarisinin Adam Algoritması ile Optimizasyonu

Toplam ekipman etkinliği değerinin tahmini için geliştirilen, Adam algoritması ile optimize edilen tüm GRU model mimarilerinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük, en küçük ve en iyi değerler Çizelge 19’da gösterilmiştir. Adam algoritması ile optimize edilen tüm GRU model mimarilerinin eğitilmesi sonucunda elde edilen en iyi MSE ve RMSE değerlerine gizli katman nöron sayısı 27 olan 6 iterasyon numaralı ağ yapısında, en iyi MAE değerine gizli katman nöron sayısı 64 olan 2 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 16 olan 3 iterasyon numaralı ağ yapısında, en iyi R ve R^2 değerlerine ise gizli katman nöron sayısı 13 olan 2 iterasyon numaralı ağ yapısında ulaşılmıştır. Adam

algoritması ile optimize edilen tüm GRU model mimarilerinin doğrulanması sonucu elde edilen en iyi MSE, RMSE ve MAPE değerlerine gizli katman nöron sayısı 92 olan 2 iterasyon numaralı ağ yapısında, en iyi MAPE değerine gizli katman nöron sayısı 64 olan 2 iterasyon numaralı ağ yapısında, en iyi R ve R^2 değerlerine ise gizli katman nöron sayısı 1 olan 5 iterasyon numaralı ağ yapısında ulaşılmıştır. Adam algoritması ile optimize edilen tüm GRU model mimarilerinin test edilmesi sonucu elde edilen en iyi MSE, RMSE, MAE ve MAPE değerlerine gizli katman nöron sayısı 92 olan 2 iterasyon numaralı ağ yapısında, en iyi R ve R^2 değerlerine gizli katman nöron sayısı 17 olan 9 iterasyon numaralı ağ yapısında ulaşılmıştır.

Çizelge 19. Adam Algoritması ile Optimize Edilen GRU Modellerinin Performans Ölçüt Değerleri


Aşama	Performans Ölçütü	Ortalama	Standart Sapma	En Büyük	En Küçük	En İyi	En İyi Değer için	
							İterasyon No	Gizli Katman Nöron Sayısı
Eğitim	MSE	0,006059	6,76E-05	0,006854	0,005999	0,005999	6	27
	RMSE	0,077837	0,000428	0,082786	0,077456	0,077456	6	27
	MAE	0,060247	0,000458	0,06486	0,05976	0,05976	2	64
	MAPE	0,090956	0,001101	0,102977	0,090117	0,090117	3	16
	R	0,744271	0,001754	0,746669	0,721741	0,746669	2	13
	R^2	0,553943	0,00259	0,557515	0,52091	0,557515	2	13
Doğrulama	MSE	0,006837	0,000332	0,008601	0,005952	0,005952	2	92
	RMSE	0,082665	0,00199	0,092743	0,077151	0,077151	2	92
	MAE	0,068384	0,001751	0,076587	0,063627	0,063627	2	92
	MAPE	0,137261	0,003473	0,166388	0,131237	0,131237	2	64
	R	0,875811	0,000908	0,878859	0,862603	0,878859	5	1
	R^2	0,767046	0,001586	0,772392	0,744085	0,772392	5	1
Test	MSE	0,005132	0,000316	0,00719	0,004427	0,004427	2	92
	RMSE	0,071605	0,002167	0,084791	0,066536	0,066536	2	92
	MAE	0,058897	0,002094	0,071166	0,053845	0,053845	2	92
	MAPE	0,081101	0,00284	0,102629	0,075174	0,075174	2	92
	R	0,889479	0,001829	0,892719	0,867359	0,892719	9	17
	R^2	0,791176	0,003234	0,796947	0,752311	0,796947	9	17

Adam algoritması ile optimize edilen GRU model mimarilerinin test edilmesi sonucunda en yüksek R^2 değeri, gizli katman nöron sayısı 17 olan 9 iterasyon numaralı modelle elde edilmiştir. Çizelge 20’de optimal performans gösteren, Adam algoritması ile optimize edilen GRU modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen performans değerleri verilmiştir.

Çizelge 20. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen GRU Modelinin Performans Ölçüt Değerleri


Performans Ölçütü	Aşama		
	Eğitim	Doğrulama	Test
MSE	0,00604	0,006893	0,00502
RMSE	0,077715	0,083021	0,070853
MAE	0,060234	0,068371	0,058231
MAPE	0,090137	0,135543	0,079652
R	0,745686	0,875726	0,892719
R^2	0,556048	0,766896	0,796947

Optimal performans gösteren, Adam algoritması ile optimize edilen GRU modelinin eğitim seyri Şekil 42’de gösterilmiştir.



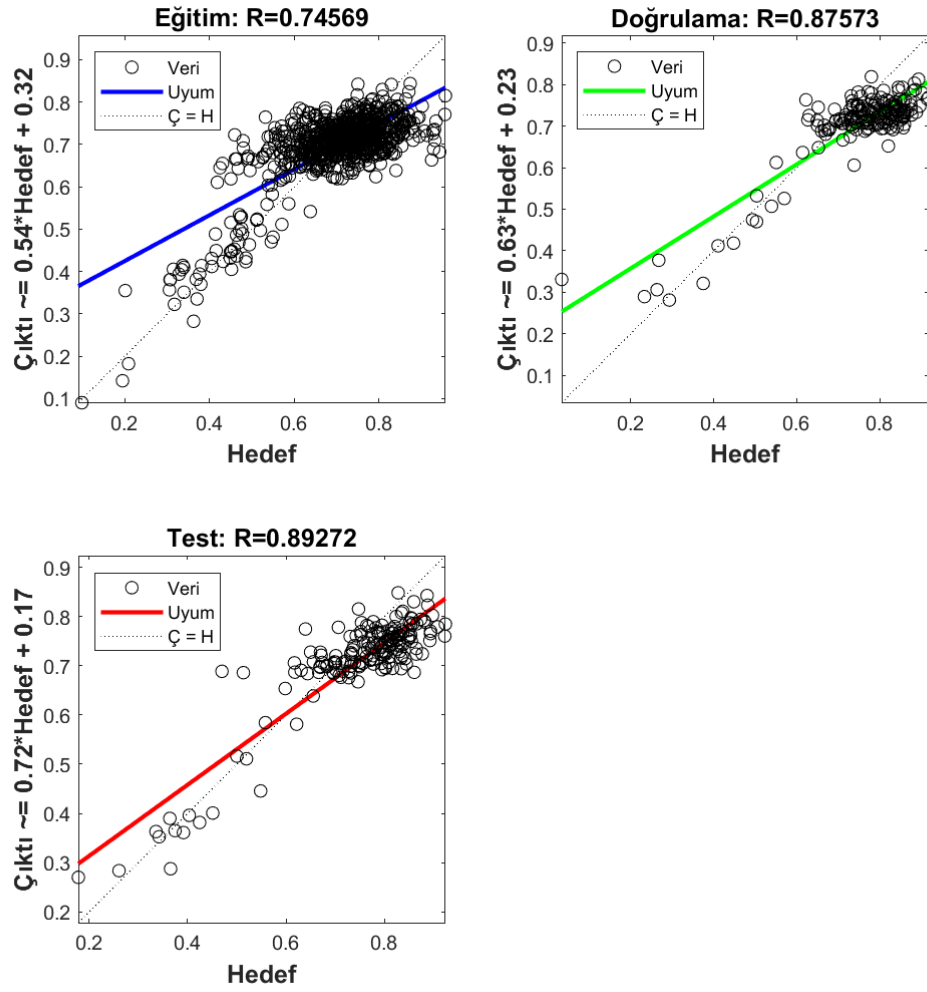
Şekil 42. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen GRU Modelinin Eğitim Seyri

Optimal performans gösteren, Adam ile optimize edilen GRU modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerlerinin zaman içindeki seyri Şekil 43'te gösterilmiştir.



Şekil 43. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen GRU Modelinin Çıktı Değerleri ile Hedef Değerler

Optimal performans gösteren Adam ile optimize edilen GRU modelinin eğitilmesi, doğrulanması ve test edilmesi sonucunda elde edilen tahmini (çıkıtı) toplam ekipman etkinliği değerleri ile gerçek (hedef) toplam ekipman etkinliği değerleri arasındaki regresyon grafiği Şekil 44'te gösterilmiştir. Şekilden de görüldüğü gibi eğitim, doğrulama ve test aşamaları için hesaplanan korelasyon değerleri sırasıyla 0,74569, 0,87573 ve 0,89272 olarak elde edilmiştir. Bu değerler, optimal performans gösteren, Adam ile optimize edilen GRU modelinin çıktılarının hedeflerle uyum içinde olduğunu göstermektedir.



Şekil 44. Optimal Performans Gösteren, Adam Algoritması ile Optimize Edilen GRU Modelinin Çıktı Değerleri ile Hedef Değerlerin Regresyon Durumları

4.4. Toplam Ekipman Etkinliğinin Tahmini için Geliştirilen Modellerin Karşılaştırılması

4.4.1. RMSprop Algoritması ile Optimize Edilen Modellerin Karşılaştırılması

RMSprop algoritması ile optimize edilen LSTM, Bi-LSTM ve GRU model mimarilerinin test edilmesi sonucunda elde edilen optimal performans ölçüt sonuçları Çizelge 21’de özetlenmiştir.

Çizelge 21. RMSprop Algoritması ile Optimize Edilen LSTM, Bi-LSTM ve GRU Model Mimarilerinin Test Edilmesi Sonucunda Elde Edilen Optimal Performans Ölçüt Değerleri

Performans Ölçütleri	LSTM		Bi-LSTM		GRU	
	İterasyon Numarası	Gizli Katman Nöron Sayısı	İterasyon Numarası	Gizli Katman Nöron Sayısı	İterasyon Numarası	Gizli Katman Nöron Sayısı
	3	1	10	79	1	2
	Performans Değerleri		Performans Değerleri		Performans Değerleri	
MSE	0,005917		0,003775		0,005217	
RMSE	0,076921		0,061440		0,072228	
MAE	0,063924		0,048185		0,059489	
MAPE	0,092001		0,070288		0,083897	
R	0,892044		0,891331		0,892125	
R ²	0,795743		0,794471		0,795888	

Çizelge 21 incelendiğinde, model mimarilerinin test edilmesi sonucunda elde edilen optimal performans ölçütü değerleri, gizli katman nöron sayısı 2 olan RMSprop Algoritması ile Optimize Edilen GRU model mimarisi ile elde edilmiştir.

4.4.2. Adam Algoritması ile Optimize Edilen Modellerin Karşılaştırılması

Adam algoritması ile optimize edilen LSTM, Bi-LSTM ve GRU model mimarilerinin test edilmesi sonucunda elde edilen optimal performans ölçüt sonuçları Çizelge 22’de özetlenmiştir.

Çizelge 22. Adam Algoritması ile Optimize Edilen LSTM, Bi-LSTM ve GRU Model Mimarilerinin Test Edilmesi Sonucunda Elde Edilen Optimal Performans Ölçüt Değerleri

Performans Ölçütleri	LSTM		Bi-LSTM		GRU	
	İterasyon Numarası	Gizli Katman Nöron Sayısı	İterasyon Numarası	Gizli Katman Nöron Sayısı	İterasyon Numarası	Gizli Katman Nöron Sayısı
		1		19		3
	Performans Değerleri		Performans Değerleri		Performans Değerleri	
MSE	0,005189		0,005194		0,005020	
RMSE	0,072031		0,072066		0,070853	
MAE	0,059097		0,059286		0,058231	
MAPE	0,080667		0,080880		0,079652	
R	0,892522		0,892160		0,892719	
R ²	0,796595		0,795949		0,796947	

Çizelge 22 incelendiğinde, model mimarilerinin test edilmesi sonucunda elde edilen optimal performans ölçütü değerleri, gizli katman nöron sayısı 17 olan Adam Algoritması ile Optimize Edilen GRU model mimarisi ile elde edilmiştir.

4.4.3. Optimizasyon Algoritmalarına Göre Optimum Sonuç Veren Model Mimarilerinin Performans Ölçüt Değerlerinin Karşılaştırılması

Optimizasyon algoritmasına göre test aşamasında optimum sonuç veren model mimarilerinin performans ölçüt sonuçları Çizelge 23'te yer almaktadır. Çizelge incelendiğinde, toplam ekipman etkinliğinin tahmininde gizli katman nöron sayısı 17 olan, Adam algoritması ile optimize edilen GRU modelinin en iyi sonucu verdiği görülmektedir.

Çizelge 23. Optimizasyon Algoritmalarına Göre Optimum Sonuç Veren Modellere İlişkin Performans Ölçüt Sonuçları

Performans Ölçütleri	RMSprop-GRU		Adam-GRU	
	İterasyon Numarası	Gizli Katman Nöron Sayısı	İterasyon Numarası	Gizli Katman Nöron Sayısı
	1	2	9	17
	Performans Değerleri		Performans Değerleri	
MSE	0,005217		0,005020	
RMSE	0,072228		0,070853	
MAE	0,059489		0,058231	
MAPE	0,083897		0,079652	
R	0,892125		0,892719	
R ²	0,795888		0,796947	

5. SONUÇ VE ÖNERİLER

5.1. Sonuçlar

Bu tez çalışmasında, oluklu mukavva departmanının toplam ekipman etkinliği, 6'sı planlı duruş türlerine ait duruş süreleri ve 17'si üretim öncesinde net olarak bilinen siparişe dayalı bilgiler olmak üzere toplam 23 öznitelik kullanılarak tahmin edilmeye çalışılmıştır. Planlı duruşlar; planlı bakım, planlı temizlik, makine hazırlığı, hafta sonu/resmî tatil, yönetim kararıyla/yapısal duruş ve toplantı/eğitim duruşlarıdır. Üretim öncesinde net olarak bilinen siparişe dayalı bilgiler ise; adet cinsinden sipariş miktarı, metrekaşe cinsinden sipariş miktarı, metrekaşe cinsinden planlanan net üretim miktarı, metrekaşe cinsinden planlanan brüt üretim miktarı, üretim siparişi sayısı, üretim talimat sayısı, metrekaşe cinsinden sipariş edilen tanıtım kağıdı miktarı, adet cinsinden sipariş edilen tanıtım kağıdı miktarı, kilogram cinsinden sipariş edilen tanıtım kağıdı miktarı, adet cinsinden satın alınan levha miktarı, metrekaşe cinsinden satın alınan levha miktarı, kullanılan kağıt makinası çerçevesi sayısı, kâğıt türü sayısı, kullanılacak kağıt türü genişliği sayısı, mukavva türü sayısı, kullanılacak mukavva türü genişliği sayısı ve ıslak son değişiklik sayısıdır.

Tez çalışmasında ilk olarak, 23 özneliğin toplam ekipman etkinliği tahmini üzerindeki etkisini belirlemek amacıyla öznitelik seçimi yapılmıştır. Öznitelik seçiminde kullanılan yöntemler; geriye doğru eleme, ileri doğru seçim, adımsal seçim, korelasyon tabanlı öznitelik seçim, genetik algoritma, rastgele orman, ekstra ağaç, ridge regresyon, lasso regresyon ve elastik nettir. Öznitelik seçiminde geliştirilen modellerin performans ölçütlerini belirlemek amacıyla 5 kat çapraz doğrulama yöntemi kullanılmış ve problem çoklu doğrusal regresyon makine öğrenmesi yöntemi ile modellenmiştir. Yöntemlere göre elde edilen Ortalama R^2 değerleri arasında önemli bir fark olmadığı için, en az sayıda öznitelik seçen (8 öznitelik) adımsal regresyon ve ridge regresyon yöntemleri arasından ortalama R^2 değeri daha yüksek olan adımsal regresyon seçilmiştir. Adımsal regresyon yöntemiyle yapılan öznitelik seçimi

sonucunda, metrekafe cinsinden sipariş miktarı, metrekafe cinsinden planlanan brüt üretim miktarı, metrekafe cinsinden satın alınan levha miktarı, planlı bakım süresi, planlı temizlik süresi, hafta sonu / resmî tatil süresi, yönetim kararıyla / yapısal duruş süresi ve makine hazırlığı süresi değişkenleri modelde bırakılmıştır.

Tez çalışmasında, kutu fabrikasının oluklu mukavva departmanının toplam etkinliğini tahmin etmek amacıyla LSTM, Bi-LSTM ve GRU yöntemlerini ve RMSprop ve Adam optimizasyon algoritmalarını içeren çeşitli modeller geliştirilmiştir. Öznitelik seçimi sonucunda modelde bırakılan öznitelikler, geliştirilen modellerin girdilerini; departmanın toplam ekipman etkinliği ise geliştirilen modellerin çıktısını oluşturmuştur. Çalışmada LSTM, Bi-LSTM ve GRU model mimarileri kullanılmıştır. LSTM modeli dizi girdi katmanı, LSTM katmanı, bırakma katmanı, tam bağlı katman ve regresyon çıktı katmanından oluşmaktadır. Bi-LSTM modeli dizi girdi katmanı, Bi-LSTM katmanı, bırakma katmanı, tam bağlı katman ve regresyon çıktı katmanından oluşmaktadır. GRU modeli ise dizi girdi katmanı, GRU katmanı, bırakma katmanı, tam bağlı katman ve regresyon çıktı katmanından oluşmaktadır. Çalışmada tüm model mimarileri için başlangıç öğrenme oranı 0,001 olarak belirlenmiş, en iyi sonuçları elde etmek amacıyla RMSprop ve Adam optimizasyon algoritmaları kullanılmış, bırakma katmanı parametresi 0,2 olarak ayarlanmıştır.

LSTM, Bi-LSTM ve GRU modellerinin geliştirilmesi sürecinde, gizli katman nöron sayısı 1 ile 100 arasında 1'er 1'er arttırılarak ve optimizasyon işlemi RMSprop ve Adam algoritmalarıyla ayrı ayrı gerçekleştirilerek 200 farklı ağ yapısı üzerine çalışılmıştır. Bu 200 farklı ağ yapısı için analiz 10 kez yinelenmiştir. Özetle, LSTM, Bi-LSTM ve GRU modellerinin her biri için 2000 olmak üzere toplamda 6000 analiz gerçekleştirilmiştir. Ayrıca modeller eğitildikten sonra, modellerin tahmin doğruluğunu değerlendirmek için MSE, RMSE, MAE, MAPE, R ve R² performans ölçütlerinden faydalanılmıştır.

Öncelikle, toplam ekipman etkinliğinin tahmini için geliştirilen modellerin performans ölçüt değerleri, derin öğrenme yöntemleri başlıkları altında karşılaştırılmıştır. LSTM modellerinin test edilmesi sonucunda, gizli katman nöron sayısı 19 olan ve Adam algoritması ile optimize edilen model, optimal performans ölçüt değerlerini sağlamıştır. Bi-LSTM modellerinin test edilmesi sonucunda, gizli katman nöron sayısı 15 olan ve Adam algoritması ile optimize edilen model, optimal

performans ölçüt değerlerini sağlamıştır. GRU modellerinin test edilmesi sonucunda, gizli katman nöron sayısı 17 olan ve Adam algoritması ile optimize edilen model, optimal performans ölçüt değerlerini sağlamıştır. Ardından, toplam ekipman etkinliğinin tahmini için geliştirilen modellerin performans ölçüt değerleri, optimizasyon algoritmaları başlıkları altında karşılaştırılmıştır. RMSprop optimizasyon algoritmasını kullanan modellerin test edilmesi sonucunda, gizli katman nöron sayısı 2 olan GRU modeli optimal performans ölçüt değerlerini sağlamıştır. Adam optimizasyon algoritmasını kullanan modellerin test edilmesi sonucunda, gizli katman nöron sayısı 17 olan GRU modeli optimal performans ölçüt değerlerini sağlamıştır. Özetle, gizli katman nöron sayısı 17 olan ve Adam algoritması ile optimize edilen GRU modeli, optimal performans göstermiştir.

5.2. Öneriler

Toplam ekipman etkinliğinin tahmini için geliştirilen model mimarilerinde gizli katman nöron sayısı 1 ile 100 arasında sınırlandırılmıştır. Tez çalışması için gerçekleştirilen analizler Intel® Core™ i5-10400T CPU @2.00Ghz 1.99 Ghz işlemciye ve 8.00 GB RAM'a sahip bir masaüstü bilgisayarda gerçekleştirilmiştir. Gelecekteki çalışmalarda, analizler daha donanımlı bir bilgisayarda gerçekleştirilirse, gizli katman nöron sayısı aralığı artırılarak daha isabetli tahminler elde edilebilir. Ayrıca, gelecekteki çalışmalarda tez çalışmasında geliştirilen model mimarilerinin girdileri, hiperparametreleri ve katmanları değiştirilerek yeni model mimarileri oluşturulabilir. Böylece, daha düşük hata oranlarına sahip toplam ekipman etkinliği tahminlerine ulaşmak mümkün olacaktır.

Toplam ekipman etkinliği tahminleri bir oluklu mukavva işletmesinden alınan veriler yardımıyla gerçekleştirilmiştir. İlerideki çalışmalarda tez çalışmasında önerilen model mimarileri diğer sektörlere de uygulanarak kararlılıkları sınanabilir.

KAYNAKÇA

- Adak, M. F. ve Duraliođlu, Ö. (2023). Makine öğrenmesi yöntemleri kullanılarak öğrencilerin kazanım bilgileri ile sınavlardaki başarı durumunun tahmini. *Journal of Intelligent Systems: Theory and Applications*, 6 (1), 43-51. <https://doi.org/10.38016/jista.1183353>
- Akgün, E., Salman, Y. B., Ayvaz, S. ve Karadeniz Oran, Ş. (2020). Makine öğrenmesi ile tahmin: Akademik başarı örneđi. V. Nabiyev ve A. K. Erümit (Editörler), *Eđitimde yapay zeka: Kuramdan uygulamaya içinde* (s. 283-304). Ankara: Pegem Akademi. <https://doi.org/10.14524/9786257052986>
- Akman, D. V., Malekipirbazari, M., Yenice, Z. D., Yeo, A., Adhikari, N., Wong, Y. K., Abbasi, B. and Gumus, A. T. (2023). K-best feature selection and ranking via stochastic approximation. *Expert Systems with Applications*, 213, 118864. <https://doi.org/10.1016/j.eswa.2022.118864>
- Alkinani, H. H., Al-Hameedi, A. T. T. and Dunn-Norman, S. (2020). Data-driven decision-making for lost circulation treatments: A machine learning approach. *Energy and AI*, 100031. <https://doi.org/10.1016/j.egyai.2020.100031>
- Almaghrabi, F., Xu, D.-L. and Yang, J.-B. (2021). An evidential reasoning rule based feature selection for improving trauma outcome prediction. *Applied Soft Computing*, 103, 107112. <https://doi.org/10.1016/j.asoc.2021.107112>
- Amini, F. and Hu, G. (2021). A two-layer feature selection method using genetic algorithm and elastic net. *Expert Systems with Applications*, 166, 114072. <https://doi.org/10.1016/j.eswa.2020.114072>
- Anilkumar, K. K., Manoj, V. J. and Sagi, T. M. (2021). Automated detection of b cell and t cell acute lymphoblastic leukaemia using deep learning. *IRBM*. <https://doi.org/10.1016/j.irbm.2021.05.005>
- Austin, P. C. and Tu, J. V. (2004). Automated variable selection methods for logistic regression produced unstable models for predicting acute myocardial

- infarction mortality. *Journal of Clinical Epidemiology*, 57 (11), 1138-1146.
<https://doi.org/10.1016/j.jclinepi.2004.04.003>
- Aydın, F. (2022). A new instance selection method for enlarging margins between classes. *Journal of Intelligent Systems: Theory and Applications*, 5 (2), 119-126. <https://doi.org/10.38016/jista.1033354>
- Badiger, A. S. and Gandhinathan, R. (2008). A proposal: evaluation of OEE and impact of six big losses on equipment earning capacity. *International Journal of Process Management and Benchmarking*, 2 (3), 234-248.
- Bai, H., Liu, P., Fu, X., Qiao, L., Liu, C., Xin, Y. and Ling, Z. (2023). Application of elastic net in quantitative analysis of major elements using Martian laser-induced breakdown spectroscopy datasets. *Spectrochimica Acta Part B: Atomic Spectroscopy*, 199, 106587. <https://doi.org/10.1016/j.sab.2022.106587>
- Bayraktaroğlu, A. ve Adıgüzel, T. (2020). Ölçme ve değerlendirmede yapay zeka kullanımı ve yabancı dil öğretimi örnekleri. V. Nabiyev ve A. K. Erümit (Editörler), *Eğitimde yapay zeka: Kuramdan uygulamaya içinde* (s. 305-326). Ankara: Pegem Akademi. <https://doi.org/10.14524/9786257052986>
- Becker, J. M. J., Borst, J. and van der Veen, A. J. C. A. (2015). Improving the overall equipment effectiveness in high-mix-low-volume manufacturing environments. 64 (1), 419-422.
- Bengio, Y., Lodi, A. and Prouvost, A. (2020). Machine learning for combinatorial optimization: A methodological tour d’horizon. *European Journal of Operational Research*. <https://doi.org/10.1016/j.ejor.2020.07.063>
- Bonada, F., Echeverria, L., Domingo, X. and Anzaldi, G. (2020). AI for improving the overall equipment efficiency in manufacturing industry. In *New trends in the use of artificial intelligence for the industry 4.0* (pp. 1-22): IntechOpen. <https://doi.org/10.5772/intechopen.89967>
- Brunelli, L., Masiero, C., Tosato, D., Beghi, A. and Susto, G. A. (2019). Deep Learning-based Production Forecasting in Manufacturing: a Packaging Equipment Case Study. *Procedia Manufacturing*, 38, 248-255. <https://doi.org/https://doi.org/10.1016/j.promfg.2020.01.033>
- Calp, M. H. (2021). Use of Deep Learning Approaches in Cancer Diagnosis. In U. Kose and J. Alzubi (Eds.), *Deep Learning for Cancer Diagnosis* (Vol. 908, pp. 249-267). Singapore: Springer. https://doi.org/10.1007/978-981-15-6321-8_15

- Canhoto, A. I. (2020). Leveraging machine learning in the global fight against money laundering and terrorism financing: An affordances perspective. *Journal of Business Research*. <https://doi.org/10.1016/j.jbusres.2020.10.012>
- Caselli, S., Pattera, M. and Ricci, M. (2012). Towards manufacturing execution systems for the food and beverage packaging industry. *Proceedings of the 9th International Conference on Informatics in Control, Automation and Robotics (ICINCO-2012)*, Rome, Italy, pp. 552-556.
- Cesarotti, V., Giuiusa, A. and Introna, V. (2013). Using overall equipment effectiveness for manufacturing system design. In M. Schiraldi (Ed.), *Operations Management* (pp. 51-79). IntechOpen. <https://doi.org/10.5772/56089>
- Chang, Z., Zhang, Y. and Chen, W. (2019). Electricity price prediction based on hybrid model of adam optimized LSTM neural network and wavelet transform. *Energy*, 187, 115804. <https://doi.org/10.1016/j.energy.2019.07.134>
- Cheah, C. K., Prakash, J. and Ong, K. S. (2020). An integrated OEE framework for structured productivity improvement in a semiconductor manufacturing facility. *International Journal of Productivity and Performance Management*, 69 (5), 1081-1105. <https://doi.org/10.1108/IJPPM-04-2019-0176>
- Chebila, M. (2020). Predicting the consequences of accidents involving dangerous substances using machine learning. *Ecotoxicology and Environmental Safety*, 208, 111470. <https://doi.org/10.1016/j.ecoenv.2020.111470>
- Chen, X. and Voigt, T. (2020). Implementation of the manufacturing execution system in the food and beverage industry. *Journal of Food Engineering*, 278, 109932. <https://doi.org/10.1016/j.jfoodeng.2020.109932>
- Chicco, D., Warrens, M. J. and Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Comput Sci*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Chikwendu, O. C., Chima, A. S. and Edith, M. C. (2020). The optimization of overall equipment effectiveness factors in a pharmaceutical company. *Heliyon*, 6 (4), e03796. <https://doi.org/10.1016/j.heliyon.2020.e03796>
- Chollet, F. (2019). *Python ile derin öğrenme*. Ankara: Buzdağı Yayınevi.
- Columbus, L. (2018). 10 Ways Machine Learning Is Revolutionizing Manufacturing In 2018. *Forbes*. <https://www.forbes.com/sites/louiscolumbus/2018/03/11/10->

[ways-machine-learning-is-revolutionizing-manufacturing-in-2018/?sh=21145c3d23ac](https://doi.org/10.1016/j.kint.2020.08.026)

- Coorey, C. P., Sharma, A., Mueller, S. and Yang, J. (2020). Prediction modelling-Part 2-Using machine learning strategies to improve transplantation outcomes. *Kidney International*. <https://doi.org/10.1016/j.kint.2020.08.026>
- Cox, C., Moscardini, E. H., Cohen, A. S. and Tucker, R. P. (2020). Machine learning for suicidology: A practical review of exploratory and hypothesis-driven approaches. *Clinical Psychology Review*, 101940. <https://doi.org/10.1016/j.cpr.2020.101940>
- Cui, Z., Ke, R., Pu, Z. and Wang, Y. (2020). Stacked bidirectional and unidirectional LSTM recurrent neural network for forecasting network-wide traffic state with missing values. *Transportation Research Part C: Emerging Technologies*, 118, 102674. <https://doi.org/10.1016/j.trc.2020.102674>
- Çelik, H. (2020). Ekipman etkinliğine farklı bir yaklaşım: Genel operasyon etkinliği. *Verimlilik Dergisi* (4), 25-40. <https://doi.org/10.51551/verimlilik.560600>
- Çifçi, F., Kaleli, C. ve Günel, S. (2018). Öznitelik seçme ve makine öğrenmesi yöntemleriyle eğitim performansının tahmin edilmesi. *Anadolu Journal of Educational Sciences International*, 8 (2), 419-440. <https://doi.org/10.18039/ajesi.454587>
- da Costa, N. L., de Lima, M. D. and Barbosa, R. (2022). Analysis and improvements on feature selection methods based on artificial neural network weights. *Applied Soft Computing*, 127, 109395. <https://doi.org/10.1016/j.asoc.2022.109395>
- da Silva, A. F., Marins, F. A. S., Tamura, P. M. and Dias, E. X. (2017). Bi-objective multiple criteria data envelopment analysis combined with the overall equipment effectiveness: An application in an automotive company. *Journal of cleaner production*, 157, 278-288. <https://doi.org/10.1016/j.jclepro.2017.04.147>
- Dadashnejad, A.-A. and Valmohammadi, C. (2019). Investigating the effect of value stream mapping on overall equipment effectiveness: A case study. *Total Quality Management and Business Excellence*, 30 (4), 466-482. <https://doi.org/10.1080/14783363.2017.1308821>

- Dobra, P. and J3svai, J. (2022a). Assembly Line Overall Equipment Effectiveness (OEE) Prediction from Human Estimation to Supervised Machine Learning. *Journal of Manufacturing and Materials Processing*, 6 (3), 59.
- Dobra, P. and J3svai, J. (2022b). Overall Equipment Effectiveness (OEE) Life Cycle at the Automotive Semi-Automatic Assembly Lines. *Acta Polytechnica Hungarica*, 19 (9), 141-155.
- Dobra, P. and J3svai, J. (2023). Cumulative and Rolling Horizon Prediction of Overall Equipment Effectiveness (OEE) with Machine Learning. *Big Data and Cognitive Computing*, 7 (3), 138.
- Dogan, A. and Birant, D. (2021). Machine learning and data mining in manufacturing. *Expert Systems with Applications*, 166, 114060. <https://doi.org/10.1016/j.eswa.2020.114060>
- Dođan, F. ve T3rkođlu, İ. (2019). Derin 3đrenme modelleri ve uygulama alanlarına iliřkin bir derleme. *D3UMF M3hendislik Dergisi*, 10 (2), 409-445. <https://doi.org/10.24012/dumf.411130>
- El-Amir, H. and Hamdy, M. (2020). *Deep learning pipeline: Building a deep learning model with TensorFlow*. Jizah, Egypt: Apress Media LLC. <https://doi.org/10.1007/978-1-4842-5349-6>
- El Mazgualdi, C., Masrour, T., El Hassani, I. and Khoudi, A. (2019). Using machine learning for predicting efficiency in manufacturing industry. *Advances in Intelligent Systems and Computing International Conference on Advanced Intelligent Systems for Sustainable Development*, Marrakech, pp. 750-762.
- El Mazgualdi, C., Masrour, T., El Hassani, I. and Khoudi, A. (2020). Machine learning for KPIs prediction: A case study of the overall equipment effectiveness within the automotive industry. *Soft Computing*, 1-19. <https://doi.org/10.1007/s00500-020-05348-y>
- Elmas, . (2018). *Yapay zeka uygulamaları: Yapay sinir ađları - makine 3đrenmesi - derin 3đrenme - derin ađlar - bulanık mantık - sinirsel bulanık mantık - genetik algoritma* (4. baskı). Ankara: Sekin Yayıncılık.
- Emanet, S., Karatas Baydogmus, G. ve Demir, O. (2021). 3znitelik seme y3ntemlerinin makine 3đrenmesi tabanlı saldırı tespit sistemi performansına etkileri. *Dicle 3niversitesi M3hendislik Fak3ltesi M3hendislik Dergisi*, 12 (5), 743-755.

- Ercan, E. (2020). Conduct asset performance management with a software-based approach. *Plant Engineering*, 74 (3), 27-29.
- Fagundez, J. L. S., Netto, M. S., Dotto, G. L. and Salau, N. P. G. (2021). A new method of developing ANN-isotherm hybrid models for the determination of thermodynamic parameters in the adsorption of ions Ag⁺, Co²⁺ and Cu²⁺ onto zeolites ZSM-5, HY, and 4A. *Journal of Environmental Chemical Engineering*, 9 (5), 106126. <https://doi.org/10.1016/j.jece.2021.106126>
- Fathima, M. D., Samuel, S. J., Natchadalingam, R. and Kaveri, V. V. (2022). Majority voting ensembled feature selection and customized deep neural network for the enhanced clinical decision support system. *International Journal of Computers and Applications*, 44 (10), 991-1001. <https://doi.org/10.1080/1206212X.2022.2069643>
- Fletcher, L., Akhtar, N., Zhan, X., Jafarikia, M., Sullivan, B. P., Huber, L.-A. and Li, J. (2022). Identification of candidate salivary, urinary and serum metabolic biomarkers for high litter size potential in Sows (*Sus scrofa*). *Metabolites*, 12 (11), 1045. <https://doi.org/10.3390/metabo12111045>
- Franzini, A., Polenghi, A., Roda, I. and Macchi, M. (2021, 2021//). System-Level Overall Equipment Effectiveness for Improving Asset Management Performance: A Case Study Application. *Advances in Production Management Systems. Artificial Intelligence for Sustainable and Resilient Production Systems*, Cham, pp. 410-417.
- Gao, K., Mei, G., Piccialli, F., Cuomo, S., Tu, J. and Huo, Z. (2020). Julia language in machine learning: Algorithms, applications, and open issues. *Computer Science Review*, 37, 100254. <https://doi.org/10.1016/j.cosrev.2020.100254>
- Garza-Reyes, J. A. (2015). From measuring overall equipment effectiveness (OEE) to overall resource effectiveness (ORE). *Journal of Quality in Maintenance Engineering*, 21 (4), 506-527. <https://doi.org/10.1108/JQME-03-2014-0014>
- Ge, R., Wu, Y. and Wang, H. (2016). Structure design of die cutting unit in corrugated carton production line. In Y. Ouyang, M. Xu, L. Yang, and Y. Ouyang (Eds.), *Advanced graphic communications, packaging technology and materials* (pp. 707-711). Singapore: Springer. https://doi.org/10.1007/978-981-10-0072-0_88
- Gopika, P., Krishnendu, C. S., Hari Chandana, M., Ananthakrishnan, S., Sowmya, V., Gopalakrishnan, E. A. and Soman, K. P. (2020). Chapter two - Single-layer

- convolution neural network for cardiac disease classification using electrocardiogram signals. In H. Das, C. Pradhan and N. Dey (Eds.), *Deep learning for data analytics* (pp. 21-35): Academic Press. <https://doi.org/10.1016/B978-0-12-819764-6.00003-X>
- Griffin, R. C. (2012). *Principles of package development* (2 ed.). New York: Springer Science & Business Media.
- Gunes, H., Coramik, M., Bicakci, S., Citak, H. and Ege, Y. (2022). Crack identification system on MOH cold rolled grain oriented sheets: Application of K-fold cross validated BRANN. *Measurement*, 195, 111128. <https://doi.org/10.1016/j.measurement.2022.111128>
- Guo, P., Zhao, D., Han, M. and Feng, S. (2019). Pseudoinverse learners: New trend and applications to big data. In P. Angelov and R. Kozma, *Proceedings of the International Neural Networks Society INNS Big Data and Deep Learning conference*, Genova, Italy, pp. 158-168.
- Hägglund, R. and Carlsson, L. A. (2012). Packaging performace. In K. Niskanen (Ed.), *Mechanics of paper products* (pp. 29-52). Berlin: Walter de Gruyter.
- Hatipoğlu, S. and Akar, C. (2022). A new scoring approach to calculate overall equipment efficieny: A case study. *Verimlilik Dergisi* (3), 499-510. <https://doi.org/10.51551/verimlilik.1055354>
- Hedman, R., Subramaniyan, M. and Almström, P. (2016). Analysis of critical factors for automatic measurement of OEE. *Procedia CIRP*, 57, 128-133. <https://doi.org/10.1016/j.procir.2016.11.023>
- Hosseinzadeh, A., Najafpoor, A. A., Jafari, A. J., Jazani, R. K., Baziar, M., Bargozin, H. and Piranloo, F. G. (2018). Application of response surface methodology and artificial neural network modeling to assess non-thermal plasma efficiency in simultaneous removal of BTEX from waste gases: Effect of operating parameters and prediction performance. *Process Safety and Environmental Protection*, 119, 261-270. <https://doi.org/10.1016/j.psep.2018.08.010>
- Houssein, E. H., Emam, M. M., Ali, A. A. and Suganthan, P. N. (2020). Deep and machine learning techniques for medical imaging-based breast cancer: A comprehensive review. *Expert Systems with Applications*. <https://doi.org/10.1016/j.eswa.2020.114161>
- Hörmann, B. O., Bizubac, D. and Popa, M. S. (2019). Industrial intelligent software applications of the overall equipment effectiveness (OEE) in manufacturing.

- The 14th International Conference Modern Technologies in Manufacturing (MTeM 2019)*, Cluj Napoca, Romania, pp. 05011.
- Hull, I. (2021). *Machine learning for economics and finance in TensorFlow 2*. Nacka, Sweden: Apress Media LLC. <https://doi.org/10.1007/978-1-4842-6373-0>
- Hung, Y.-H., Li, L. Y. O. and Cheng, T. C. E. (2022). Uncovering hidden capacity in overall equipment effectiveness management. *International Journal of Production Economics*, 248, 108494. <https://doi.org/10.1016/j.ijpe.2022.108494>
- Iannone, R. and Nenni, M. E. (2013). Managing OEE to optimize factory performance. In M. Schiraldi (Ed.), *Operations Management* (pp. 31-50). IntechOpen <https://doi.org/10.5772/55322>
- Jia, F., Lei, Y., Guo, L., Lin, J. and Xing, S. (2018). A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines. *Neurocomputing*, 272, 619-628. <https://doi.org/10.1016/j.neucom.2017.07.032>
- Jiang, T., Gradus, J. L. and Rosellini, A. J. (2020). Supervised machine learning: A brief primer. *Behavior Therapy*, 51, 675-687. <https://doi.org/10.1016/j.beth.2020.05.002>
- Jing, L., Zhao, M., Li, P. and Xu, X. (2017). A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox. *Measurement*, 111, 1-10. <https://doi.org/10.1016/j.measurement.2017.07.017>
- Jordan, M. I. and Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349 (6245), 255-260. <https://doi.org/10.1126/science.aac4520>
- Kang, Z., Catal, C. and Tekinerdogan, B. (2020). Machine learning applications in production lines: A systematic literature review. *Computers and Industrial Engineering*, 149, 106773. <https://doi.org/10.1016/j.cie.2020.106773>
- Kara, A. (2019). Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7 (4), 882-892. <https://doi.org/10.29109/gujsc.571831>
- Keskin, B., Günal, E. Ş., Urazel, B. ve Keskin, K. (2022). Elektrikli araç bataryalarının şarj durumu tahmini için bir model. *Nicel Bilimler Dergisi*, 4 (2), 161-175. <https://doi.org/10.51541/nicel.1117756>

- Khedkar, S., Gandhi, P., Shinde, G. and Subramanian, V. (2020). Deep learning and explainable AI in healthcare using EHR. In S. Dash, B. R. Acharya, M. Mittal, A. Abraham and A. Kelemen (Eds.), *Deep Learning Techniques for Biomedical and Health Informatics* (pp. 129-148). Cham, Switzerland: Springer. https://doi.org/10.1007/978-3-030-33966-1_7
- Koçak, A. (2015). İmalat süreçlerinde kullanılan performans ölçütleri üzerine bir literatür araştırması. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17 (3), 160-185.
- Korkmaz, G. ve Eroğlu, E. (2020). Model karmaşıklığının kontrolü. *İktisadi ve İdari Yaklaşımlar Dergisi*, 2 (2), 146-162.
- Kose, U., Deperlioglu, O., Alzubi, J. and Patrut, B. (2021). *Deep learning for medical decision support systems* (Vol. 909). Singapore: Springer. <https://doi.org/10.1007/978-981-15-6325-6>
- Kumar, E. S. and Jayadev, P. S. (2020). Deep learning for clinical decision support systems: A review from the panorama of smart healthcare. In S. Dash, B. R. Acharya, M. Mittal, A. Abraham and A. Kelemen (Eds.), *Deep Learning Techniques for Biomedical and Health Informatics* (pp. 79-99). Cham, Switzerland: Springer. https://doi.org/10.1007/978-3-030-33966-1_5
- Kuo, Y. and Lin, K.-P. (2010). Using neural network and decision tree for machine reliability prediction. *The International Journal of Advanced Manufacturing Technology*, 50, 1243-1251. <https://doi.org/10.1007/s00170-010-2593-7>
- Lanza, G., Stoll, J., Stricker, N., Peters, S. and Lorenz, C. (2013). Measuring Global Production Effectiveness. *Procedia CIRP*, 7, 31-36. <https://doi.org/10.1016/j.procir.2013.05.006>
- Lap, B. Q., Phan, T.-T.-H., Nguyen, H. D., Quang, L. X., Hang, P. T., Phi, N. Q., Hoang, V. T., Linh, P. G. and Hang, B. T. T. (2023). Predicting Water Quality Index (WQI) by feature selection and machine learning: A case study of An Kim Hai irrigation system. *Ecological Informatics*, 74, 101991. <https://doi.org/10.1016/j.ecoinf.2023.101991>
- Li, H., Lin, Z., An, Z., Zuo, S., Zhu, W., Zhang, Z., Mu, Y., Cao, L. and Prades García, J. D. (2022). Automatic electrocardiogram detection and classification using bidirectional long short-term memory network improved by Bayesian optimization. *Biomedical Signal Processing and Control*, 73, 103424. <https://doi.org/10.1016/j.bspc.2021.103424>

- Liao, D.-Y., Tsai, W.-P., Chen, H.-T., Ting, Y.-P., Chen, C.-Y., Chen, H.-C. and Chang, S.-C. (2018). Recurrent reinforcement learning for predictive overall equipment effectiveness. *2018 e-Manufacturing & Design Collaboration Symposium (eMDC)*, Hsinchu, Taiwan, pp. 1-4.
- Liu, F., Jiang, X., Wang, X. and Wang, L. (2020). Machine learning-based design and optimization of curved beams for multistable structures and metamaterials. *Extreme Mechanics Letters*, 41, 101002. <https://doi.org/10.1016/j.eml.2020.101002>
- Liu, Y., Guo, B., Zou, X., Li, Y. and Shi, S. (2020). Machine learning assisted materials design and discovery for rechargeable batteries. *Energy Storage Materials*, 31, 434-450. <https://doi.org/10.1016/j.ensm.2020.06.033>
- Liu, Y. and Schumann, M. (2005). Data mining feature selection for credit scoring models. *Journal of the Operational Research Society*, 56 (9), 1099-1108. <https://doi.org/10.1057/palgrave.jors.2601976>
- Long, X. Y., Zhao, S. K., Jiang, C., Li, W. P. and Liu, C. H. (2021). Deep learning-based planar crack damage evaluation using convolutional neural networks. *Engineering Fracture Mechanics*, 246, 107604. <https://doi.org/10.1016/j.engfracmech.2021.107604>
- Malița, M., Popescu, G. V. and Ștefan, G. M. (2020). Heterogeneous computing system for deep learning. In W. Pedrycz and S.-M. Chen (Eds.), *Deep learning: Concepts and architectures* (pp. 287-319). Cham, Switzerland: Springer. https://doi.org/10.1007/978-3-030-31756-0_10
- Marafino, B. J., John Boscardin, W. and Adams Dudley, R. (2015). Efficient and sparse feature selection for biomedical text classification via the elastic net: Application to ICU risk stratification from nursing notes. *Journal of Biomedical Informatics*, 54, 114-120. <https://doi.org/10.1016/j.jbi.2015.02.003>
- Meidiana, C., Yakin, H. A. and Wijayanti, W. P. (2017). Household's willingness to accept waste separation for improvement of rural waste bank's effectivity. In F.-C. Mihai (Ed.), *Solid waste management in rural areas* (pp. 11-26). Rijeka, Croatia: InTech. <https://doi.org/10.5772/intechopen.69428>
- Messaoud, S., Bradai, A., Bukhari, S. H. R., Qung, P. T. A., Ahmed, O. B. and Atri, M. (2020). A survey on machine learning in internet of things: Algorithms,

- strategies, and applications. *Internet of Things*, 100314. <https://doi.org/10.1016/j.iot.2020.100314>
- Mohapatra, S., Swarnkar, T. and Das, J. (2021). Deep convolutional neural network in medical image processing. In V. E. Balas, B. K. Mishra and R. Kumar (Eds.), *Handbook of deep learning in biomedical engineering* (pp. 25-60). London, UK: Elsevier. <https://doi.org/10.1016/B978-0-12-823014-5.00006-5>
- Mohebbanaaz, Padma Sai, Y. and Rajani Kumari, L. V. (2022). Cognitive assistant DeepNet model for detection of cardiac arrhythmia. *Biomedical Signal Processing and Control*, 71, 103221. <https://doi.org/10.1016/j.bspc.2021.103221>
- Mousavi-Nasab, S. H., Safari, J. and Hafezalkotob, A. (2020). Resource allocation based on overall equipment effectiveness using cooperative game. *Kybernetes*, 49 (3), 819-834. <https://doi.org/10.1108/K-09-2018-0491>
- Muchiri, P. and Pintelon, L. (2008). Performance measurement using overall equipment effectiveness (OEE): Literature review and practical application discussion. *International Journal of Production Research*, 46 (13), 3517-3535. <https://doi.org/10.1080/00207540601142645>
- Muthiah, K. M. N. and Huang, S. H. (2007). Overall throughput effectiveness (OTE) metric for factory-level performance monitoring and bottleneck detection. *International Journal of Production Research*, 45 (20), 4753-4769. <https://doi.org/10.1080/00207540600786731>
- Muthiah, K. M. N., Huang, S. H. and Mahadevan, S. (2008). Automating factory performance diagnostics using overall throughput effectiveness (OTE) metric. *The International Journal of Advanced Manufacturing Technology*, 36 (7), 811-824. <https://doi.org/10.1007/s00170-006-0891-x>
- Nakajima, S. (1988). *Introduction to TPM: Total productive maintenance*. Portland, OR: Productivity Press.
- Nakaura, T., Higaki, T., Awai, K., Ikeda, O. and Yamashita, Y. (2020). A primer for understanding radiology articles about machine learning and deep learning. *Diagnostic and Interventional Imaging*, 101 (10). <https://doi.org/10.1016/j.diii.2020.10.001>
- Narayanan, P., Ambrogio, S., Tsai, H., Mackin, C., Shelby, R. M. and Burr, G. W. (2020). Analog acceleration of deep learning using phase-change memory. In S. Spiga, A. Sebastian, D. Querlioz and B. Rajendran (Eds.), *Memristive*

- devices for brain-inspired computing* (pp. 329-362). Duxford, UK: Woodhead Publishing. <https://doi.org/10.1016/B978-0-08-102782-0.00013-7>
- Narayanan, S. J., Perumal, B., Saman, S. and Singh, A. P. (2020). Deep learning for person re-identification in surveillance videos. In W. Pedrycz and S.-M. Chen (Eds.), *Deep learning: Algorithms and applications* (pp. 263-297). Cham, Switzerland: Springer. https://doi.org/10.1007/978-3-030-31760-7_9
- Naseri, H., Waygood, E. O. D., Wang, B., Patterson, Z. and Daziano, R. A. (2022). A novel feature selection technique to better predict climate change stage of change. *Sustainability*, 14 (1), 40. <https://doi.org/10.3390/su14010040>
- Nasiri, A., Taheri-Garavand, A., Omid, M. and Carlomagno, G. M. (2019). Intelligent fault diagnosis of cooling radiator based on deep learning analysis of infrared thermal images. *Applied Thermal Engineering*, 163, 114410. <https://doi.org/10.1016/j.applthermaleng.2019.114410>
- Ng Corrales, L. d. C., Lambán, M. P., Hernandez Korner, M. E. and Royo, J. (2020). Overall equipment effectiveness: Systematic literature review and overview of different approaches. *Applied Sciences*, 10 (18), 6469. <https://doi.org/10.3390/app10186469>
- Nisha, S. S. and Meeral, M. N. (2021). Applications of deep learning in biomedical engineering. In V. E. Balas, B. K. Mishra and R. Kumar (Eds.), *Handbook of deep learning in biomedical engineering* (pp. 245-270). London, UK: Elsevier. <https://doi.org/10.1016/B978-0-12-823014-5.00008-9>
- Niu, H., Xu, W., Akbarzadeh, H., Parvin, H., Beheshti, A. and Alinejad-Rokny, H. (2020). Deep feature learnt by conventional deep neural network. *Computers & Electrical Engineering*, 84, 106656. <https://doi.org/10.1016/j.compeleceng.2020.106656>
- Noman, N. (2020). A shallow introduction to deep neural networks. In N. Noman and H. Iba (Eds.), *Deep neural evolution: Deep learning with evolutionary computation* (pp. 35-63). Singapore: Springer. https://doi.org/10.1007/978-981-15-3685-4_2
- Oliveira, R., Taki, S. A., Sousa, S. and Salimi, M. A. (2019). Global Process Effectiveness: When Overall Equipment Effectiveness Meets Adherence to Schedule. *Procedia Manufacturing*, 38, 1615-1622. <https://doi.org/10.1016/j.promfg.2020.01.123>

- Onyekpe, U., Kanarachos, S., Palade, V. and Christopoulos, S.-R. G. (2021). Vehicular localisation at high and low estimation rates during GNSS outages: A deep learning approach. In M. A. Wani, T. M. Khoshgoftaar and V. Palade (Eds.), *Deep learning applications, Volume 2* (pp. 229-248). Singapore: Springer. https://doi.org/10.1007/978-981-15-6759-9_10
- Osarogiagbon, A. U., Khan, F., Venkatesan, R. and Gillard, P. (2021). Review and analysis of supervised machine learning algorithms for hazardous events in drilling operations. *Process Safety and Environmental Protection*, 147, 367-384. <https://doi.org/10.1016/j.psep.2020.09.038>
- Önder, E. ve Hasgül Kuvat, Ö. (2009). Yabancı ziyaretçi sayısının tahmininde box-jenkins modeli, winters yöntemi ve yapay sinir ağlarıyla zaman serisi analizi. *Yönetim Dergisi:İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü*, 20 (62), 62-83.
- Paine, F. A. (1996). *The packaging user's handbook* (5 ed.). Bishopbriggs, Glasgow: Blackie Academic and Professional. <https://doi.org/10.1007/978-1-4613-1483-7>
- Pala, F. K. (2020). Makine öğrenmesi ve eğitim sistemine getirdikleri. V. Nabiyeve A. K. Erümit (Editörler), *Eğitimde yapay zeka: Kuramdan uygulamaya içinde* (s. 233-257). Ankara: Pegem Akademi. <https://doi.org/10.14524/9786257052986>
- Paluszek, M. and Thomas, S. (2020). *Practical MATLAB deep learning: A project-based approach*. New York, NY: New York, NY. <https://doi.org/10.1007/978-1-4842-5124-9>
- Pariyani, P. (2018). *How is Machine Learning Reshaping Manufacturing?* Retrieved 14.11.2020 from <https://www.rapidvaluesolutions.com/machine-learning-reshaping-manufacturing/>
- Park, Y.-J. and Hur, S. (2020). Improvement of productivity through the reduction of unexpected equipment faults in die attach equipment. *Processes*, 8 (4), 394. <https://doi.org/10.3390/pr8040394>
- Pasha, S. J. and Mohamed, E. S. (2022). Advanced hybrid ensemble gain ratio feature selection model using machine learning for enhanced disease risk prediction. *Informatics in Medicine Unlocked*, 32, 101064. <https://doi.org/10.1016/j.imu.2022.101064>

- Pauletto, P. S., Gonçalves, J. O., Pinto, L. A. A., Dotto, G. L. and Salau, N. P. G. (2020). Single and competitive dye adsorption onto chitosan-based hybrid hydrogels using artificial neural network modeling. *Journal of Colloid and Interface Science*, 560, 722-729. <https://doi.org/10.1016/j.jcis.2019.10.106>
- Peng, T., Zhang, C., Zhou, J. and Nazir, M. S. (2021). An integrated framework of bi-directional long-short term memory (BiLSTM) based on sine cosine algorithm for hourly solar radiation forecasting. *Energy*, 221, 119887. <https://doi.org/10.1016/j.energy.2021.119887>
- Petersson, H., Klingvall, R. and Holmberg, M. (2009). Sensor array optimization using variable selection and a scanning light pulse technique. *Sensors and Actuators B: Chemical*, 142 (2), 435-445. <https://doi.org/10.1016/j.snb.2009.04.029>
- Ponta, L., Puliga, G., Oneto, L. and Manzini, R. (2019). Innovation capability of firms: A big data approach with patents. In P. Angelov and R. Kozma, *Proceedings of the International Neural Networks Society INNS Big Data and Deep Learning conference*, Genova, Italy, pp. 169-179.
- Potluri, S., Ahmed, S. and Diedrich, C. (2020). Securing industrial control systems from false data injection attacks with convolutional neural networks. In W. Pedrycz and S.-M. Chen (Eds.), *Development and analysis of deep learning architectures* (pp. 197-222). Cham, Switzerland: Springer. https://doi.org/10.1007/978-3-030-31764-5_8
- Prasetyo, Y. T. and Veroya, F. C. (2020). An application of overall equipment effectiveness (OEE) for minimizing the bottleneck process in semiconductor industry. *2020 IEEE 7th International Conference on Industrial Engineering and Applications (ICIEA)*, pp. 345-349.
- Puvanasvaran, P., Teoh, Y. S. and Ito, T. (2020). Novel availability and performance ratio for internal transportation and manufacturing processes in job shop company. *Journal of Industrial Engineering and Management*, 13 (1), 1-17. <https://doi.org/10.3926/jiem.2755>
- Qu, K., Xu, J., Hou, Q., Qu, K. and Sun, Y. (2023). Feature selection using information gain and decision information in neighborhood decision system. *Applied Soft Computing*, 136, 110100. <https://doi.org/10.1016/j.asoc.2023.110100>
- Rabelo, G. M., Batocchio, A. and Sato, A. I. (2020). Estudo e Análise do Indicador OEEML Aplicado em uma empresa de Autopeças. *Journal of Lean System*, 5 (1), 29-46.

- Raj, M., Bhushan, R., Prakash, K., Pandey, V., Raju, B. and Borkar, M. (2021). Embellishing TPM through Losses Analysis to Enhance Overall Plant Effectiveness in Ferro Alloys Plant-A Case Study at JSPL, Raigarh.
- Ranjan, A., Singh, V. P., Mishra, R. B., Thakur, A. K. and Singh, A. K. (2021). Sentence polarity detection using stepwise greedy correlation based feature selection and random forests: An fMRI study. *Journal of Neurolinguistics*, 59, 100985. <https://doi.org/10.1016/j.jneuroling.2021.100985>
- Raouf, A. (1994). Improving Capital Productivity through Maintenance. *International Journal of Operations & Production Management*, 14 (7), 44-52. <https://doi.org/10.1108/01443579410062167>
- Risum, A. B. and Bro, R. (2019). Using deep learning to evaluate peaks in chromatographic data. *Talanta*, 204, 255-260. <https://doi.org/10.1016/j.talanta.2019.05.053>
- Roda, I. and Macchi, M. (2019). Factory-level performance evaluation of buffered multi-state production systems. *Journal of Manufacturing Systems*, 50, 226-235. <https://doi.org/10.1016/j.jmsy.2018.12.008>
- Rodríguez-Padial, N., Marín, M. and Domingo, R. (2017). An approach to integrating tactical decision-making in industrial maintenance balance scorecards using principal components analysis and machine learning. *Complexity*, 2017, 1-15. <https://doi.org/10.1155/2017/3759514>
- Saab, S., Saab, K., Phoha, S., Zhu, M. and Ray, A. (2022). A multivariate adaptive gradient algorithm with reduced tuning efforts. *Neural Networks*, 152, 499-509. <https://doi.org/10.1016/j.neunet.2022.05.016>
- Sacco, C., Radwan, A. B., Anderson, A., Harik, R. and Gregory, E. (2020). Machine learning in composites manufacturing: A case study of automated fiber placement inspection. *Composite Structures*, 240, 112514. <https://doi.org/10.1016/j.compstruct.2020.112514>
- Sahu, S. K. and Anand, A. (2020). Unified neural architecture for drug, disease, and clinical entity recognition. In B. Agarwal, V. E. Balas, L. C. Jain, R. C. Poonia and Manisha (Eds.), *Deep Learning Techniques for Biomedical and Health Informatics* (pp. 1-19). London, UK: Elsevier. <https://doi.org/10.1016/B978-0-12-819061-6.00001-X>

- Sakarya, Ş. ve Yılmaz, Ü. (2019). Derin öğrenme mimarisi kullanarak BIST30 indeksinin tahmini. *European Journal of Educational and Social Sciences*, 4 (2), 106-121.
- Saud, S., Jamil, B., Upadhyay, Y. and Irshad, K. (2020). Performance improvement of empirical models for estimation of global solar radiation in India: A k-fold cross-validation approach. *Sustainable Energy Technologies and Assessments*, 40, 100768. <https://doi.org/10.1016/j.seta.2020.100768>
- Savian, S., Elahi, M. and Tillo, T. (2020). Optical flow estimation with deep learning, a survey on recent advances. In R. Jiang, C.-T. Li, D. Crookes, W. Meng and C. Rosenberger (Eds.), *Deep biometrics* (pp. 257-287). Cham, Switzerland: Springer. https://doi.org/10.1007/978-3-030-32583-1_12
- Sayuti, M., Juliananda, Syarifuddin and Fatimah. (2019). Analysis of the overall equipment effectiveness (OEE) to minimize six big losses of pulp machine: A case study in pulp and paper Industries. *IOP Conference Series: Materials Science and Engineering*, pp. 012061.
- Schiraldi, M. M. and Varisco, M. (2020). Overall equipment effectiveness: Consistency of ISO standard with literature. *Computers and Industrial Engineering*, 145, 106518. <https://doi.org/10.1016/j.cie.2020.106518>
- Schmitz, J. and Platts, K. W. (2004). Supplier logistics performance measurement: Indications from a study in the automotive industry. *International Journal of Production Economics*, 89 (2), 231-243. [https://doi.org/10.1016/S0925-5273\(02\)00469-3](https://doi.org/10.1016/S0925-5273(02)00469-3)
- Selvaratnam, B. and Koodali, R. T. (2020). Machine learning in experimental materials chemistry. *Catalysis Today*. <https://doi.org/10.1016/j.cattod.2020.07.074>
- Ser, G. ve Bati, C. T. (2019). Derin sinir ağları ile en iyi modelin belirlenmesi: Mantar verileri üzerine keram uygulaması. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 29 (3), 406-417. <https://doi.org/10.29133/yyutbd.505086>
- Seyyarer, E., Ayata, F., Uçkan, T. ve Karcı, A. (2020). Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması. *Anatolian Journal of Computer Sciences*, 5 (2), 90-98.
- Shamshirband, S., Fathi, M., Dehhangi, A., Chronopoulos, A. T. and Alinejad-Rokny, H. (2021). A review on deep learning approaches in healthcare systems:

- Taxonomies, challenges, and open issues. *Journal of Biomedical Informatics*, 113, 103627. <https://doi.org/10.1016/j.jbi.2020.103627>
- Sharma, R., Kamble, S. S., Gunasekaran, A., Kumar, V. and Kumar, A. (2020). A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. *Computers and Operations Research*, 104926. <https://doi.org/10.1016/j.cor.2020.104926>
- Shehadeh, A., Alshboul, O., Al Mamlook, R. E. and Hamedat, O. (2021). Machine learning models for predicting the residual value of heavy construction equipment: An evaluation of modified decision tree, LightGBM, and XGBoost regression. *Automation in Construction*, 129, 103827. <https://doi.org/10.1016/j.autcon.2021.103827>
- Siddique, S. and Chow, J. C. L. (2020). Artificial intelligence in radiotherapy. *Reports of Practical Oncology & Radiotherapy*, 25 (4), 656-666. <https://doi.org/10.1016/j.rpor.2020.03.015>
- Sigamani, R. M. S. (2020). Adoption of machine learning with adaptive approach for securing CPS. In P. Ganapathi and D. Shanmugapriya (Eds.), *Handbook of research on machine and deep learning applications for cyber security* (pp. 388-415). Hershey PA, USA: IGI Global. <https://doi.org/10.4018/978-1-5225-9611-0.ch018>
- Sinaei, S. and Daneshtalab, M. (2020). Hardware acceleration for recurrent neural networks. In M. Daneshtalab and M. Modarressi (Eds.), *Hardware architectures for deep learning* (pp. 27-51). London, United Kingdom: The Institution of Engineering and Technology.
- Smiti, A. (2020). When machine learning meets medical world: Current status and future challenges. *Computer Science Review*, 37, 100280. <https://doi.org/10.1016/j.cosrev.2020.100280>
- Sonmez, V., Testik, M. C. and Testik, O. M. (2018). Overall equipment effectiveness when production speeds and stoppage durations are uncertain. *The International Journal of Advanced Manufacturing Technology*, 95 (1-4), 121-130. <https://doi.org/10.1007/s00170-017-1170-8>
- Soroka, W. (2008). *Illustrated glossary of packaging terminology* (2 ed.). Naperville, Illinois: Institute of Packaging Professionals.
- Stamatis, D. H. (2017). *The OEE primer: Understanding overall equipment effectiveness, reliability, and maintainability*. New York: CRC Press.

- Sun, H., Burton, H. V. and Huang, H. (2021). Machine learning applications for building structural design and performance assessment: State-of-the-art review. *Journal of Building Engineering*, 33, 101816. <https://doi.org/10.1016/j.jobe.2020.101816>
- Sun, S., Hu, M., Wang, S. and Zhang, C. (2023). How to capture tourists' search behavior in tourism forecasts? A two-stage feature selection approach. *Expert Systems with Applications*, 213, 118895. <https://doi.org/10.1016/j.eswa.2022.118895>
- Swapna, G., Soman, K. and Vinayakumar, R. (2020). Diabetes detection using ecg signals: An overview. In S. Dash, B. R. Acharya, M. Mittal, A. Abraham and A. Kelemen (Eds.), *Deep Learning Techniques for Biomedical and Health Informatics* (pp. 299-327). Cham, Switzerland: Springer. https://doi.org/10.1007/978-3-030-33966-1_14
- Taywade, P. and Ashtankar, K. M. (2016). Evaluation of overall equipment effectiveness (OEE), its optimization and analysis through design of experiment (DOE). *International Journal of Advance Engineering and Research Development*, 3 (4), 385-391.
- Thongsuwan, S., Jaiyen, S., Padcharoen, A. and Agarwal, P. (2021). ConvXGB: A new deep learning model for classification problems based on CNN and XGBoost. *Nuclear Engineering and Technology*, 53 (2), 522-531. <https://doi.org/10.1016/j.net.2020.04.008>
- Toğaçar, M., Ergen, B. and Cömert, Z. (2020a). Application of breast cancer diagnosis based on a combination of convolutional neural networks, ridge regression and linear discriminant analysis using invasive breast cancer images processed with autoencoders. *Medical Hypotheses*, 135, 109503. <https://doi.org/10.1016/j.mehy.2019.109503>
- Toğaçar, M., Ergen, B. and Cömert, Z. (2020b). Waste classification using AutoEncoder network with integrated feature selection method in convolutional neural network models. *Measurement*, 153, 107459. <https://doi.org/10.1016/j.measurement.2019.107459>
- Toprak, İ. and Toygar, Ö. (2021). Detection of spoofing attacks for ear biometrics through image quality assessment and deep learning. *Expert Systems with Applications*, 172, 114600. <https://doi.org/10.1016/j.eswa.2021.114600>

- Trattner, A., Hvam, L. and Haug, A. (2020). Why slow down? Factors affecting speed loss in process manufacturing. *The International Journal of Advanced Manufacturing Technology*, 106 (5), 2021-2034. <https://doi.org/10.1007/s00170-019-04559-4>
- Tsanas, A. (2022). Relevance, redundancy, and complementarity trade-off (RRCT): A principled, generic, robust feature-selection tool. *Patterns*, 3 (5), 100471. <https://doi.org/10.1016/j.patter.2022.100471>
- Tsarouhas, P. (2019a). Improving operation of the croissant production line through overall equipment effectiveness (OEE). *International Journal of Productivity and Performance Management*, 68 (1), 88-108. <https://doi.org/10.1108/IJPPM-02-2018-0060>
- Tsarouhas, P. (2019b). Overall equipment effectiveness (OEE) evaluation for an automated ice cream production line. *International Journal of Productivity and Performance Management*, 69 (5), 1009-1032. <https://doi.org/10.1108/IJPPM-03-2019-0126>
- Twede, D., Selke, S. E., Kamdem, D.-P. and Shires, D. (2014). *Cartons, crates and corrugated board: Handbook of paper and wood packaging technology* (2th ed.). Lancaster, Pennsylvania: DEStech Publications, Inc.
- van Klompenburg, T., Kassahun, A. and Catal, C. (2020). Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture*, 177, 105709. <https://doi.org/10.1016/j.compag.2020.105709>
- Verma, D., Jansen, D., Bach, K., Poel, M., Mork, P. J. and d'Hollosy, W. O. N. (2022). Exploratory application of machine learning methods on patient reported data in the development of supervised models for predicting outcomes. *BMC Medical Informatics and Decision Making*, 22 (1), 227. <https://doi.org/10.1186/s12911-022-01973-9>
- Vigneshwaran, B., Maheswari, R. V., Kalavani, L., Shanmuganathan, V., Rho, S., Kadry, S. and Lee, M. Y. (2021). Recognition of pollution layer location in 11 kV polymer insulators used in smart power grid using dual-input VGG convolutional neural network. *Energy Reports*, 7, 7878-7889. <https://doi.org/10.1016/j.egyr.2020.12.044>
- Wang, T., Hu, Z. and Liu, H. (2023). A unified view of feature selection based on Hilbert-Schmidt independence criterion. *Chemometrics and Intelligent Laboratory Systems*, 104807. <https://doi.org/10.1016/j.chemolab.2023.104807>

- Wang, Z., Lei, Y., Cui, H., Miao, H., Zhang, D., Wu, Z. and Liu, G. (2022). Enhanced RBF neural network metamodelling approach assisted by sliced splitting-based k-fold cross-validation and its application for the stiffened cylindrical shells. *Aerospace Science and Technology*, 124, 107534. <https://doi.org/10.1016/j.ast.2022.107534>
- Wani, M. A., Bhat, F. A., Afzal, S. and Khan, A. I. (2020). *Advances in deep learning* (Vol. 57). Singapore: Springer. <https://doi.org/10.1007/978-981-13-6794-6>
- Waqas, M., Tariq, S., Shahzad, M., Ali, Z. and Saqib, S. (2015). Performance measurement of surface mining equipment by using overall equipment effectiveness. *Pakistan Journal of Science*, 67 (2), 212-216.
- Wen, S., Buyukada, M., Evrendilek, F. and Liu, J. (2020). Uncertainty and sensitivity analyses of co-combustion/pyrolysis of textile dyeing sludge and incense sticks: Regression and machine-learning models. *Renewable Energy*, 151, 463-474. <https://doi.org/10.1016/j.renene.2019.11.038>
- Wu, T., Hao, Y., Yang, B. and Peng, L. (2023). ECM-EFS: An ensemble feature selection based on enhanced co-association matrix. *Pattern Recognition*, 139, 109449. <https://doi.org/10.1016/j.patcog.2023.109449>
- Xing, W., Pei, B., Li, S., Chen, G. and Xie, C. (2019). Using learning analytics to support students' engineering design: The angle of prediction. *Interactive Learning Environments*, 1-18. <https://doi.org/10.1080/10494820.2019.1680391>
- Yalçın, O. G. (2021). *Applied neural networks with TensorFlow 2: API oriented deep learning with python*. İstanbul: Apress Media LLC. <https://doi.org/10.1007/978-1-4842-6513-0>
- Yao, G., Hu, X. and Wang, G. (2022). A novel ensemble feature selection method by integrating multiple ranking information combined with an SVM ensemble model for enterprise credit risk prediction in the supply chain. *Expert Systems with Applications*, 200, 117002. <https://doi.org/10.1016/j.eswa.2022.117002>
- Zhang, A., Lipton, Z. C., Li, M. and Smola, A. J. (2021). *Dive into deep learning*.
- Zhang, G., Bai, X. and Wang, Y. (2021). Short-time multi-energy load forecasting method based on CNN-Seq2Seq model with attention mechanism. *Machine Learning with Applications*, 5, 100064. <https://doi.org/10.1016/j.mlwa.2021.100064>

- Zhang, L., He, M. and Shao, S. (2020). Machine learning for halide perovskite materials. *Nano Energy*, 78, 105380. <https://doi.org/10.1016/j.nanoen.2020.105380>
- Zhang, Q., Hu, W., Liu, Z. and Tan, J. (2020). TBM performance prediction with bayesian optimization and automated machine learning. *Tunnelling and Underground Space Technology*, 103, 103493. <https://doi.org/10.1016/j.tust.2020.103493>
- Zhang, Y., Xin, J., Li, X. and Huang, S. (2020). Overview on routing and resource allocation based machine learning in optical networks. *Optical Fiber Technology*, 60, 102355. <https://doi.org/10.1016/j.yofte.2020.102355>
- Zhang, Z., Lei, Y., Mao, X., Yan, M., Xu, L. and Zhang, X. (2021). A study of effectiveness of deep learning in locating real faults. *Information and Software Technology*, 131, 106486. <https://doi.org/10.1016/j.infsof.2020.106486>
- Zhao, Z., Wu, J., Cai, F., Zhang, S. and Wang, Y.-G. (2022). A statistical learning framework for spatial-temporal feature selection and application to air quality index forecasting. *Ecological Indicators*, 144, 109416. <https://doi.org/10.1016/j.ecolind.2022.109416>
- Zhou, J., Wang, Y. and Chua, Y. Q. (2020). Machine OEE monitoring and analysis for a complex manufacturing environment. *2020 15th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, pp. 1413-1418.
- Zimmerling, C., Dörr, D., Henning, F. and Kärger, L. (2019). A machine learning assisted approach for textile formability assessment and design improvement of composite components. *Composites Part A: Applied Science Manufacturing*, 124, 105459. <https://doi.org/10.1016/j.compositesa.2019.05.027>

http-1:

<https://oden.io/blog/oe-calculation-using-machine-learning> (Erişim Tarihi: 14.11.2020)

http-2:

<https://builders.intel.com/docs/aibuilders/tvarit-ai-optimizes-overall-equipment-effectiveness-for-metal-manufacturing.pdf> (Erişim Tarihi: 14.11.2020)

