



**STANDART SÜRE HESABINDA MAKİNE ÖĞRENMESİ
YÖNTEMLERİNİN KULLANILMASI İLE ÜRETİM PLANLAMA
FAALİYETLERİNİN ETKİNLİĞİNİN ARTTIRILMASI**

Halil Erkan AKDOĞAN

**YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

AĞUSTOS 2024

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına 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 herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Halil Erkan AKDOĞAN

01/08/2024

STANDART SÜRE HESABINDA MAKİNE ÖĞRENMESİ YÖNTEMLERİNİN
KULLANILMASI İLE ÜRETİM PLANLAMA FAALİYETLERİNİN ETKİNLİĞİNİN
ARTTIRILMASI

(Yüksek Lisans Tezi)

Halil Erkan AKDOĞAN

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ağustos 2024

ÖZET

Standart zaman hesaplamaları üretim ve planlama faaliyetlerinin temelini oluşturan, maliyetleri düşürmek ve müşteri taleplerini zamanında karşılamak için kritik bir süreçtir. Standart zaman hesaplamalarında en sık kullanılan geleneksel iş ölçümü yöntemlerinden zaman etüdü uygun üretim ve hizmet sistemlerinde temel, dinlenme ve dağılım zamanlarının hesabı ile doğru standart sürenin belirlenmesi ve performans düzeylerinin analizinde hem bilimsel yazında hem de alan uygulamalarında çoklukla tercih edilmektedir. Ancak uzun çevrimler, tek seferlik siparişler, yüksek el işçiliği oranlı üretim süreçleri, parça geometrisinde talep kaynaklı yüksek değişkenlik gibi faktörler nedeni ile dolaysız iş ölçümü yöntemlerinin yetersiz kaldığı durumlarda, tahmin ve karşılaştırma gibi dolaylı iş ölçümü yöntemlerinin tercih edilmesi gereği doğmaktadır. Bu çalışmada, savunma sanayinde faaliyet gösteren büyük ölçekli bir firmanın yoğun el işçilikli değişkenliği yüksek ürün aileleri için yürütülen üretim planlama faaliyetlerinde geleneksel yöntemler ile hesaplanamayan standart süreler öncelikle literatürde baskın olarak tercih edilen geleneksel regresyon tahmin modelleri ile, daha sonra ise günümüzde gelişen hesaplama teknolojileri ve veri bilimindeki ilerlemeler ışığında yapay sinir ağları, destek vektör makineleri ve rasgele orman makine öğrenmesi algoritmaları ile hesaplanmış, hesaplanan standart süreler dört farklı performans metriği temelinde derinlemesine analiz edilmiş, çıktı güvenilirlikleri karşılaştırmalı olarak yorumlanmış, sonuçlar açıklayıcı görseller ile desteklenmiştir.

Bilim Kodu : 90603

Anahtar Kelimeler : İş ölçümü, makine öğrenmesi, destek vektör makineleri, yapay sinir ağları, rasgele orman, standart zaman

Sayfa Adedi : 109

Danışman : Doç. Dr. Burcu YILMAZ KAYA

INCREASING THE EFFICIENCY OF PRODUCTION PLANNING ACTIVITIES BY USING MACHINE LEARNING METHODS IN STANDARD TIME CALCULATION

(M. Sc. Thesis)

Halil Erkan AKDOĞAN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

August 2024

ABSTRACT

Standard time calculations are critical processes that form the foundation of production and planning activities, aimed at reducing costs and meeting customer demands on time. Time studies, one of the most frequently used traditional work measurement methods in standard time calculations, are widely preferred both in scientific literature and in field applications for determining the correct standard time and analyzing performance levels by calculating basic, rest, and distribution times in appropriate production and service systems. However, in cases where direct work measurement methods are insufficient due to factors such as long cycles, one-off orders, production processes with high manual labor rates, or high variability in part geometry due to demand, indirect work measurement methods such as estimation and comparison need to be preferred. In this study, for the production planning activities carried out for product families with high variability and intensive manual labor of a large-scale company operating in the defense industry, standard times that cannot be calculated with traditional methods were first calculated with traditional regression estimation models predominantly preferred in the literature. Then, leveraging advancements in today's computing technologies and data science, artificial neural networks, support vector machines, and random forest machine learning algorithms were employed. The calculated standard times were analyzed in depth based on four different performance metrics, their output reliabilities were interpreted comparatively, and the results were supported with explanatory visuals.

Science Code : 90603

Key Words : Work measurement, machine learning, support vector machines, artificial neural networks, random forest, standard time

Page Number : 109

Supervisor : Assoc. Prof. Dr. Burcu YILMAZ KAYA

TEŞEKKÜR

Bu tez çalışması süresince bana her zaman rehberlik eden ve desteğini hiç esirgemeyen kıymetli hocam Doç. Dr. Burcu YILMAZ KAYA'ya içten teşekkürlerimi sunarım. Ayrıca, sevgili eşim Betül AKDOĞAN'a sürekli desteği için ve oğullarım Demirhan ile Kerem'e bana verdikleri ilham ve neşe dolu anlar için minnettarım. Onların varlığı, bu süreçte bana güç ve motivasyon kaynağı oldu. Son olarak, tez çalışmam boyunca bana destek sağlayan Epsilon A.Ş ailesine de şükranlarımı sunuyorum.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. GENEL KAVRAMLAR	5
2.1. Süreç Yönetimi	5
2.1.1. Süreç yönetiminin temel aşamaları	8
2.2. Üretim Planlama	9
2.3. İş Ölçümü	11
2.3.1. İş ölçümü teknikleri.....	13
2.4. Makine Öğrenmesi	22
2.4.1. Denetimli öğrenme	24
2.4.2. Denetimsiz öğrenme.....	26
2.4.3. Yarı-denetimli öğrenme	27
2.4.4. Pekiştirmeli öğrenme	27
2.4.5. Derin öğrenme.....	28
3. LİTERATÜR ARAŞTIRMASI.....	29
4. MATERYAL VE METODOLOJİ	35
4.1. Regresyon Analizi.....	35

	Sayfa
4.1.1. Doğrusal regresyon analizi.....	35
4.1.2. Doğrusal olmayan regresyon analizi.....	36
4.2. Yapay Sinir Ağları	39
4.2.1. YSA'nın yapılarına göre sınıflandırılması.....	45
4.3. Destek Vektör Makineleri.....	47
4.3.1. Doğrusal DVM.....	48
4.3.2. Çok sınıflı DVM	54
4.4. Karar Ağaçları.....	55
4.4.1. ID3 algoritması.....	57
4.4.2. C4.5 algoritması	57
4.4.3. C5.0 algoritması	57
4.4.4. SLIQ algoritması.....	58
4.4.5. SPRINT algoritması	58
4.4.6. CART algoritması	58
4.4.7. CHAID algoritması	59
5. UYGULAMA	61
5.1. Problem Tanımı.....	61
5.2. Verilen Toplanması ve Veri Özellikleri.....	64
5.3. Geleneksel Tahmin Yöntemleri Algoritması ve Hesaplamaları	66
5.3.1. Regresyon modeli uygulama sonuçları	68
5.4. YSA Algoritması ve Hesaplamaları.....	70
5.4.1. YSA uygulama sonuçları	74
5.5. DVM Algoritması ve Hesaplamaları	75
5.5.1. DVM uygulama sonuçları	79
5.6. Karar Ağaçları Algoritması ve Hesaplamaları.....	80

	Sayfa
5.6.1. Karar ağacı uygulama sonuçları.....	84
5.7. Bulgular ve Tartışma.....	85
6. SONUÇ VE ÖNERİLER.....	89
KAYNAKLAR	93
ÖZGEÇMİŞ	109

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. YSA elemanlarının biyolojik sinir sistemindeki karşılıkları.....	41
Çizelge 4.2. Bazı toplama fonksiyonları	44
Çizelge 5.1. Gerçek hayat uygulaması faktörleri ve açıklamaları	64
Çizelge 5.2. Regresyon modeli sonuçlarının performans değerlendirmesi	68
Çizelge 5.3. Doğrusal regresyon modeli test ve eğitim verileri performans değerleri kıyaslaması.....	69
Çizelge 5.4. YSA katman sayısı değişimlerinin tahmin performansına etkisi	72
Çizelge 5.5. YSA iterasyon sayısı değişimlerinin tahmin performansına etkisi.....	73
Çizelge 5.6. YSA sonuçlarının performans değerlendirmesi.....	74
Çizelge 5.7. YSA test ve eğitim verileri performans değerleri kıyaslaması.....	75
Çizelge 5.8. DVM çekirdek fonksiyonu değişimlerinin tahmin performansına etkisi ...	78
Çizelge 5.9. Doğrusal ve döngüsel temelli DVM performans sonuçları	79
Çizelge 5.10. DVM test ve eğitim verileri performans değerleri kıyaslaması.....	79
Çizelge 5.11. Derinlik değişimlerinin tahmin performansına etkisi	82
Çizelge 5.12. Seçilen modelin performans sonuçları.....	84
Çizelge 5.13. Karar ağacı test ve eğitim verileri performans değerleri kıyaslaması	84
Çizelge 5.14. DVM, YSA, karar ağaçları ve regresyon modelleri performans değerleri kıyaslaması	85

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Süreç yönetimi aşamaları.....	9
Şekil 2.2. İş ölçümü teknikleri	13
Şekil 2.3. Normal dağılım güvenlik düzeyleri	17
Şekil 2.4. Makine öğrenmesi türleri.....	24
Şekil 4.1. Biyolojik sinir hücresi.....	39
Şekil 4.2. (A) Biyolojik Sinir Hücresi (B) Yapay Sinir Hücresi (C) Biyolojik Sinaps (D) YSA'daki Sinapslar	40
Şekil 4.3. Yapay sinir hücresinin bileşenleri	41
Şekil 4.4. Yapay sinir hücresinin yapısı.....	43
Şekil 4.5. YSA'da kullanılan yaygın aktivasyon fonksiyonlarının grafikleri.....	45
Şekil 4.6. İleri beslemeli YSA	46
Şekil 4.7. Geri beslemeli YSA	47
Şekil 4.8. DVM genel yapısı.....	48
Şekil 4.9. Doğrusal olarak ayrılan sınıflama problemi	49
Şekil 4.10. Doğrusal olarak ayrılamayan verilerin yüksek dereceli uzaya aktarılması ..	50
Şekil 4.11. Karar ağacı genel yapısı.....	56
Şekil 5.1. Parça ailesi üretim rotası.....	62
Şekil 5.2. Önerilen çözüm yaklaşımı akış diyagramı	63
Şekil 5.3. Geliştirilen YSA modelinin yapısı.....	74
Şekil 5.4. Geliştirilen karar ağacı modeli yapısı	84

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

d	Polinom derecesi
k	Çekirdek fonksiyonu
log	Logaritma
n	Örnek sayısı
p	Oluş yüzdesi
q	Oluş yüzdesi dışında kalan oran
R	Reel sayılar kümesi
tan	Tanjant
W	Ağırlık katsayısı
x	Girdi değeri
y	Çıktı değeri
∅	Boş küme
σ	Dağılımın standart sapması

Kısaltmalar

Açıklamalar

CHAID	Ki kare otomatik etkileşim belirleme
CNC	Bilgisayarlı sayısal denetim
DVM	Destek vektör makineleri
ERP	Kurumsal kaynak planlaması
KNN	K-en yakın komşuları algoritması
LIGHTGBM	Hafif gradyan artırma makinesi
OKH	Ortalama kare hatası
OMH	Ortalama mutlak hata
MLP	Çok katmanlı algılayıcılar
PMTS	Önceden belirlenmiş hareket zaman sistemleri

Kısaltmalar**Açıklamalar****RBF**

Döngüsel temelli çekirdek fonksiyonu

RFID

Radyo frekansı ile tanımlama

KOKH

Kök ortalama karesel hata

SVS

Standart veri sistemleri

YSA

Yapay sinir ağı

1. GİRİŞ

Günümüzde artan rekabet koşulları, havacılık ve savunma sanayii gibi birçok sektörü derinden etkilemektedir. Bu koşullar altında, firmalar ürünlerini yüksek kalitede ve maliyet açısından verimli şekilde üretmek zorundalar. Ayrıca, pazar fiyatlarını sürekli rekabetçi seviyede tutabilmek için kar marjlarını titizlikle yönetmeleri gerekmektedir. Bu çerçevede, kaynakların optimum kullanılarak, müşterilere doğru zamanda, doğru miktarda ürün temininin sağlanması amacıyla üretim planlamanın önemi büyük ölçüde artmaktadır.

Üretim planlama; müşteri talepleri, finansman durumu, üretim kapasitesi, insan gücü vb. parametreleri sürekli olarak tartan, kontrol altında tutan bir mekanizma kurarak bu çelişkili amaçlar arasında uzlaşma sağlar (Öztürk, 2007). Bu nedenle; üretim planlama, işletmelerin verimliliğini artırmak, maliyetleri düşürmek ve müşteri taleplerini zamanında karşılamak için kritik bir süreçtir.

Bu sürecin temelinde; üretim faaliyetlerinin ne kadar süreceğini belirleyen standart süre hesapları bulunmaktadır. Standart sürelerin doğru tayin edilmesi sayesinde, işletmelerin üretim kapasiteleri doğru bir şekilde tahmin edilebilir, kaynak tahsisleri optimize edilebilir ve teslimat süreleri akılcı bir şekilde planlanabilir. Ancak, geleneksel standart süre hesaplama yöntemleri, üretim süreçlerinin karmaşıklığı ve dinamik doğası nedeniyle karar verici ve yöneticilerin uygulamada çeşitli sınırlılıklarla karşılaşmasına neden olabilmektedir. Özellikle kafilili işlerde, değişkenlik gösteren sipariş miktar ve ürün yapılarında, mevsimlik ürün veya hizmetlerde, yüksek el işçiliği olan ürünlerde ve iş akışı uzun zamana yayılan işlerde standart sürenin dolaylı ya da dolaysız geleneksel yöntemlerle belirlenmesi yoğun emek ve yatırım gerektirmekte, yine de çoğu kez doğru hesaplamaların yapılması mümkün olmamaktadır. Bu bağlamda, iş ölçümü çalışmalarında zaman etüdü, iş örnekleme ya da önceden belirlenmiş hareket zaman sistemleri (Predetermined motion and time systems – PMTS) gibi geleneksel araçların kullanımıyla standart sürenin hesaplanması yerine, gelişen teknoloji, hesaplama kapasitesi ve veri bilimindeki ilerlemeler sayesinde makine öğrenmesi yöntemlerinin kullanımı günümüzde rağbet kazanmakta, talep tahmini (Acı ve Doğanşoy, 2022), stok yönetimi (Namir, Labriji ve Lahmar, 2022), ürün geliştirme (Joung ve Kim, 2023), finans (Culkin ve Das, 2017), dağıtım ağı planlama (Matijašević, Antić ve Capuder, 2022), enerji yönetimi (Fu, Wu ve Liu, 2021) gibi çok farklı uygulama alanlarında tahmin

ve ileri hesaplama operasyonlarında başarı ile kullanılmakta olan bu tekniklerin üretim planlama faaliyetleri ve iş ölçümünde ihtiyaç duyulan standart süre hesaplamalarında tahminleri doğru ve hızlı bir şekilde gerçekleştirme potansiyeline sahip olduğu belirtilmektedir (Lim, Yusof ve Shamsudin, 2019).

Makine öğrenmesi ilk kez 1959'da Arthur Samuel tarafından bir dama oyununu analiz etmek için kullanılmıştır. Arthur Samuel, makine öğrenmesini, bilgisayarlara açıkça programlanmadan öğrenme yeteneği veren araştırma alanı olarak tanımlamıştır (Samuel, 1959). Makine öğrenmesi, verileri önce öğrenebilen, öğrendiği veriler doğrultusunda tahmin yapabilen yapay zekâ temelli bir modeldir. Makine öğrenmesi, makineler verileri nasıl daha verimli şekilde kullanacaklarını öğretmek için kullanılır. Mevcut veri setlerinin bolluğu ile makine öğrenimine olan talep artmaktadır. Birçok endüstri, ilgili verileri çıkarmak için makine öğrenimine başvurmaktadır. Makine öğreniminin amacı verilerden öğrenmektir. Açıkça programlanmadan makinelerin kendi kendine öğrenmesinin nasıl sağlanabileceği konusunda birçok çalışma yapılmıştır. Birçok matematikçi ve programcı, büyük veri setlerine sahip olan bu sorunun çözümünü bulmak için çeşitli yaklaşımlar uygulamıştır (Mahesh, 2018). Makine öğrenimi algoritmaları; istatistiksel yöntemlerin kullanılmasıyla, sınıflandırma ve tahminler yapması için eğitilirler. Büyük veriler genişleyip büyüse dahi makine öğreniminin işlevsizleşmesi yerine, daha iyi tahminler üretmesini ve sonuçların daha kesinleşmesini sağlar (IBM, 2020).

Bu tez çalışmasında özellikle geleneksel yöntemlerle standart sürenin belirlenmesinin zor olduğu yüksek el işçiliği olan ve iş akışı uzun zamana yayılan işler için üretim planlama etkinliğinin artırılması amacıyla standart süre hesabında makine öğrenmesi yöntemlerinin kullanılması konu alınmış, makine öğrenmesi teknolojileri ile standart süre tahminlerini geliştirmek konusunda akademik ve endüstriyel alandaki ilgili paydaşlara, yenilikçi yaklaşımlar sunulması amaçlanmaktadır. Çalışma kapsamında standart süre tahmini, yapılan derin literatür araştırmaları sonucunda öncelikle mevcut tahmin analizleri ve konu özelinde süre tahmini analizlerinde en sık kullanılan yöntem olan regresyon analizi ile gerçekleştirilmiş, daha sonra sonuç verilerinin doğruluğunu ve güvenilirliğini artırmak için yapay sinir ağları (YSA), destek vektör makineleri (DVM) ve rasgele orman makine öğrenmesi algoritmaları ile gerçekleştirilen hesaplamalar ile yeniden incelenmiştir. Gerçekleştirilen analizler sonucunda elde edilen standart süreler dört farklı performans metriği temelinde geleneksel regresyon analizi ve yenilikçi makine öğrenmesi hesaplamaları

sonuçları açısından karşılaştırılmış, geleneksel çözüm yöntemi ile makine öğrenmesi algoritmalarının performansları karşılaştırılmıştır. Ayrıca, var olan ilişkin literatürde en sık kullanıldığı tespit edilen YSA, DVM ve rasgele orman algoritmalarının performansları da yine makine öğrenmesi algoritmalarının etkinliklerinin ve standart süre tahmininde kullanımları için uygunluklarının analiz edilebilmesi için kendi içlerinde karşılaştırılarak derinlemesine analiz edilmiştir.

Bu tez çalışması altı bölümden oluşmaktadır. Çalışmanın ikinci bölümünde süreç yönetimi ve iş ölçümü kavramları açıklanmış, üretim planlama süreçlerinin temel bileşenleri, süreç yönetimi, iş ölçümü ve üretim planlama arasındaki ilişkiler ve standart süre hesaplarının bu süreçlerdeki rolü detaylarıyla incelenmiş makine öğrenmesi kavramı ve makine öğrenmesi yöntemlerinin temelleri açıklanmıştır. Üçüncü bölümde, literatürde sık kullanılan makine öğrenmesi yöntemleri problem sınıflarına göre derlenerek sunulmuş ve literatür araştırması bulguları bu yöntemlerin üretim planlama faaliyetlerinde nasıl kullanılabileceğinin irdelenmesi amacıyla derlenmiştir. Daha sonra özellikle standart süre tahminlerinde makine öğrenmesi yönteminin uygulanmasında kullanılan algoritmalar incelenmiştir. Tez çalışmasının dördüncü bölümünde araştırma kapsamında ele alınan üretim planlama problemi özelinde seçilen makine öğrenmesi algoritmalarının ve regresyon analizinin detayları incelenmiştir. Beşinci bölümde; regresyon modelleri ve makine öğrenmesi yöntemlerinin kullanımı ile standart süre hesabı bir gerçek hayat uygulamasında derlenen gerçek hayat verileri ile gerçekleştirilmiştir. Problem tanımı, veri toplama, model eğitimleri, testler ve validasyon işlemleri ardıl olarak açıklanmış, öne sürülen çözüm yaklaşımında yer alan farklı modellerinin standart süre tahminlerindeki performansları hesaplanmış ve sunulmuştur. Yürütülen matematiksel hesaplamalardan elde edilen sonuçlar makine öğrenmesi yöntemlerinin standart süre tahminlerindeki potansiyel avantajları ve sınırlılıkları ışığında tartışılmış, senaryo analizleri gerçekleştirilmiş ve bulgular derinlemesine incelenmiştir. Altıncı bölümde araştırmanın sonuçları özetlenerek makine öğrenmesi yöntemlerinin üretim planlama süreçlerinde standart süre hesaplarına katkısı vurgulanarak gelecek araştırmalar için bazı önerilerde bulunulmuştur.

2. GENEL KAVRAMLAR

2.1. Süreç Yönetimi

Kuruluşların genellikle insan, yapı, görev ve iş gibi belirli kavramlar üzerine yoğunlaşmaları sonucunda, işletmelerin süreç odaklı olmaları gerekirken, bu kavramlara odaklanılması nedeniyle süreçlerle ilgili sıkıntılar yaşanmaktadır. İşletmelerin organizasyon yapısı ve tasarımının yeniden yapılandırılması, yapılan işlerin küçük parçalara ayrılarak bölünmesi ve bölünen parçaların uzmanlaşmış departmanlara dağıtılması ve yönetilmesi ile süreç yönetimi odaklı düşünce tarzına geçişin başlatıldığı görülmektedir (Hammer ve Champy, 1996: 31).

Şirket yapıları çeşitli boyutlara sahip iş süreçlerinden meydana gelmektedir. Bu süreçler, tek bir bölümde veya birden fazla bölümde işlevlerini yürütebilmekte ve işletmelerin finansal başarısını bu süreçlerdeki performansı yüksek oranda etkilemektedir. Süreçlerin mali işleyişe olan etkisi ve şirket yapısının geleneksel biçimde kurgulanması, müşteriler ve verimlilik açısından önemli problemlere yol açmış ve süreç yönetimi kavramının ortaya çıkmasına neden olmuştur. (Kılıç ve Aydın, 2014).

Yönetim düşüncelerinin tarihsel gelişimine göre, klasik yönetim anlayışı en eski yönetim düşüncesi olarak kabul edilmektedir. Bu dönemde, verimlilikte önemli artışlar sağlanması amacıyla faaliyetlerin etkili bir şekilde düzenlenmesi ve yönetici rolünün net şekilde belirlenmesi konusunda odaklanılmıştır (Certo, 2003: 31). Bu dönemin en temel çalışma alanı, mekanik kalite kontrol faaliyetleri olmuştur. Sanayi Devrimi'ne kadar küçük aile şirketleri olarak faaliyet gösteren organizasyon, devrimin getirdiği yenilikler sayesinde artan üretim kapasiteleri ile büyük imalat tesislerine dönüşmüştür. Bu büyük imalat tesislerinden çıkan ürünler, niteliksel farklılık gözetilmeden ve bölünmemiş pazarlarda kolayca alıcı bulmuştur. Bu dönemde hedef; mümkün olduğunca düşük maliyetle yüksek miktarda üretim yapmak ve böylece kârlılığı artırmaktır (Güçlü, 2003). Süreç yönetimini şekillendiren Bilimsel Yönetim Teorisi bu dönemde ilk kez geliştirilmiştir. Taylorizm veya Taylor sistemi olarak da bilinen Bilimsel Yönetim, çalışan verimliliğini artırmayı amaçlayan ve işlem adımlarını analiz ederek, sonuçlar üreten bir yönetim teorisidir. Bilimsel Yönetim'in evrensel yaklaşımları; işgücü verimliliğini artırmak, işlem adımlarını standartlaştırmak, disiplin ve iş hiyerarşisini oluşturmak amacıyla geliştirilmiştir (Of ve Kılıçaslan, 2020). Bilimsel yönetim yaklaşımında, Taylor'un çalışanların sorunlarına mühendis bakış açısıyla

yaklaşması, yalnızca sıklıkla tekrar eden işlerin daha hızlı gerçekleştirilmesi amacıyla metot geliştirme çabalarıyla sınırlı kalmıştır (Eren, 2011: 24). Bu yaklaşım, kapsamlı bir teori olmaktan ziyade, organizasyonun alt birimlerindeki işlerin analiz edilmesi, standartların belirlenmesi ve ücret sistemlerinin devreye alınması gibi konularda politikalar oluşturmaya odaklanmıştır (Gürüz ve Gürel, 2009: 78). Taylor'un araştırdığı organizasyonlar, mekanik kapalı sistemler olarak değerlendirilmiştir. Çevresinden izole edilen bu organizasyonların, yalnızca iç işleyişleri detaylı bir şekilde incelenmiştir. Verimliliği artırma amacıyla olan Taylor, dış etkenlerden gelen ekonomik, hukuki, teknolojik gibi unsurların yapı üzerindeki etkilerini fark etmesine rağmen, bunları yeterince göz önünde bulundurmamıştır (Atıgan, 2011: 25). Günümüzde organik ve açık sistemler olarak değerlendirilen organizasyonlar, geçmiş dönemin organizasyonlarından oldukça farklıdır. Taylor'un öngördüğü organizasyonlar ile günümüzün bilgi üreten ve küresel şebeke organizasyonu ile dünya çapında faaliyet gösteren imalat birimleri aynı değildir. Ancak, ortaya koyulan fikirler zamanla denenerek geliştirilmiş ve yeni görüşlerle zenginleştirilmiştir. Bu fikirlerin geçen asır içinde evrim geçirdiği söylenebilir (Koçel, 2014: 243).

Klasik yönetim anlayışının ardından gelen Neo-Klasik Yönetim düşüncesinde, iş rotasyonu ve iş zenginleştirilmesi gibi süreç yönetimi için kritik olan iş tasarımı teknikleri ilk defa gündeme gelmiştir. Modern yönetim teorilerinde ise, Sistem Yaklaşımı ve iş sistemi yapısına ve uygulama bağlamına göre değişiklik gösteren Durumsallık Yaklaşımları ortaya çıkmıştır.

Sistem Yaklaşımı, bir kuruluşu girdileri çıktılarına dönüştüren açık bir sistem olarak detaylı şekilde analiz etmeye odaklanır. 1960'larda önemli bir etki yaratan bu yaklaşım, yöneticilerin şirketin çeşitli uzmanlık alanlarını ve bölümlerini birbirleriyle ve dış çevresel unsurlarla bağlantılandırmasını mümkün kılmıştır (Aydın, 2007). Durumsallık Yaklaşımı, yönetim ilke ve süreçlerinin her bir durumun kendine özgü vasıflarına göre uygulanmasıyla ilgilidir ve dış çevre, teknoloji, örgütsel vasıflar, yöneticinin nitelikleri ve astların vasıfları gibi çeşitli durumsal faktörlere dayanır (Sökmen, 2023).

1980 sonrası "İş Süreçleri Mühendisliği" terimi süreç yönetimine farklı bir bakış açısı kazandırmış, ayrıca ISO 9000 standartlarının benimsenmesi ve teknolojinin gelişmesiyle birlikte ortaya çıkan çeşitli yazılımlar süreç yönetiminin günümüzdeki halini almasında katkı sağlamıştır (Wyatt, 2018).

Süreç yönetimi, tüm süreçleri içeren ve bu süreçlerin yürütülmesinde rol oynayan teknik, teknolojik ekipman kullanımı ve yönetim şeklinin doğru bir şekilde uygulanmasını ifade eder (Eser, 2018). Süreç yönetimine göre, süreçlerin tasarımı ve sürdürülebilmesi, müşteri taleplerinin karşılanması amacıyla sürekli olarak analiz ve değerlendirilme yapılması ve geliştirilmesini gerektirmektedir (Ezcan, Işıkdag ve Kuruoğlu, 2011: 684). Başka bir tanıma göre, süreç yönetimi, iş süreçlerinde yapılandırma, iyileştirme, modelleme, otomasyon, iş akışı yönetimi ve süreç odaklı bilgi teknolojilerinin kullanımını içeren bir yönetim şeklidir (De Bruin ve Rosemann, 2005: 2).

Bu bağlamda süreç yönetimini oluşturan faaliyetlerin süreçler bazında tanımlanması ve faaliyetlerin hedefler doğrultusunda yürütülmesi sağlanmalıdır (Aras, 2005: 8).

Süreç yönetiminin başarılı bir şekilde sürdürülebilmesi amacıyla, tüm süreçlerin çalışanlar tarafından eksiksiz olarak bilinmesi, olası hedef sapmalarında iyileştirme faaliyetlerinin gerçekleştirilmesi ve işletmenin süreç odaklı bir yapıya sahip olması gerekmektedir (Eyüpoğlu, 2012: 32).

Süreç yönetimi hedeflerine dair yapılan incelemelerde, bu yönetim biçiminin temel amaçlarının müşteri memnuniyetini artırmak, maliyetleri düşürmek ve kaliteyi yükseltmek olduğu belirlenmiştir. Süreç hedefleri belirlenirken stratejik hedefler baz alınır ve stratejik hedefler süreçlere indirgenir. Bu kapsamda hedef, stratejilerden direkt olarak alınabilir. Eğer tüm süreçlere kadar yaygınlaştırılmış, etkin bir ölçüm sistemi varsa üst yönetim tarafından belirlenen kademeli bir iyileştirme oranı da hedef olarak belirlenebilir. Periyodik olarak ölçümler gerçekleştirilerek sapmalar incelenir.

Süreçlerin izlenmesini, değerlendirilmesini ve gerekli iyileştirmelerin yapılmasını ifade eden süreç yönetiminin amaçlarına yönelik farklı görüşler mevcuttur.

Selek'e (2006) göre süreç yönetiminin amaçları arasında; müşteri odaklı yönetimi teşvik etmesi, örgüt önceliklerine sistematik bir yaklaşım getirmesi, işlevsel sınırların ortadan kaldırılarak, bölümler arası ilişkilerin geliştirilmesi, katma değer yaratmayan eylemlerin belirlenmesi, örgüt kaynaklarının etkin kullanımının sağlanması, iyileştirme olanaklarının belirlenmesi, hızlı karar alma avantajı sağlanması, çalışanların sorumluluk bilincine sahip olmalarının sağlanması ve sorumlulukların açıklıkla belirlenmesi yer almaktadır.

Bezirci'ye (2006) göre süreç yönetimindeki ana amaç, çağımızın kalite, hizmet, esneklik ve düşük maliyet gibi gereksinimlerine uygun şekilde şekillendirilmiş organizasyon amaçlarına, yeni bilgi ve kaynaklar kullanılarak ya da mevcut kaynaklar farklı bir şekilde değerlendirilerek, daha çabuk ve direkt şekilde ulaşabilmektir. Bu, içinde bulunulan pazarda daha etkin, verimli, yüksek kapasitede faaliyet gösterilmesini, daha basit, yalın, küçük sistemlerin tasarlanmasını sağlar.

Aydın'a (2007) göre süreç yönetiminin amaçları, müşteri beklentilerini karşılayacak kaliteyi ve servisi sağlamak, maliyeti ve hata oranını düşürmek, yenilik ve esneklik sağlamak ve müşteri sadakatini ve karlılığı artırmaktır.

Kurt ve Dağdeviren'e göre (2020) süreç yönetiminin amaçları; işi yapmanın en ekonomik yolunu bulmak, önerilen metot ile gerekli malzeme ve araçları standart hale getirmek, belirlenmiş bir verimlilik düzeyinde çalışmak üzere eğitilmiş bir işçinin işi yapması için gerekli zamanı tespit etmek, gereksiz faaliyetlerden kurtulmak, gerekli faaliyetleri mümkün olan en ekonomik şekilde düzenlemek, iş ile ilgili doğru zaman standartlarını saptamak, metodun standart uygulamaya geçirilmesini sağlamak, üretimde kullanılan kaynaklardan yararlanma oranını artırmak, işgücünü eğitmek, ve var olan çalışma koşullarından daha iyi çalışma koşullarına geçmektir.

2.1.1. Süreç yönetiminin temel aşamaları

Süreç yönetiminin başarılı sonuçlar verebilmesi için süreç yönetiminde yer alan aşamaların doğru bir şekilde uygulanması gerekmektedir.


Bir işletmenin verimliliğini artırmak amacıyla yalnızca iyileştirme faaliyetleri yeterli olmadığından, bu sürecin doğru bir şekilde yönetilmesi de oldukça önem taşır.

Süreç yönetiminin aşamaları aşağıdaki gibi sıralanabilir (Bozkurt, 2002: 18):

- Süreç listeleme
- Süreç hiyerarşisi oluşturma
- Süreç değerlendirme kriterlerinin tespiti
- Öncelikli süreçleri belirleme
- Çalışanların süreçlerdeki rollerinin belirlenmesi

- Süreç işlemlerinin belirlenmesi
- Süreç akış diyagramının hazırlanması
- Süreç haritasının oluşturulması
- Süreç girdilerinin/çıktılarının tespit edilmesi
- Süreç tedarikçilerinin/müşterilerinin tespiti ve ilgilileriyle analiz edilmesi
- Süreç akış diyagramının ve haritasının yeniden düzenlenmesi
- Süreç iyileştirme projelerinin hazırlanması
- Süreç iyileştirme projelerinin planlanmasıdır.

Kurt ve Dağdeviren'e (2020) göre ise süreç yönetimi aşamaları aşağıdaki şekilde belirtilmiştir:



Şekil 2.1. Süreç yönetimi aşamaları (Kurt ve Dağdeviren, 2020)

2.2. Üretim Planlama

Her işletmenin temel hedefi, ürün ve hizmet üretim süreçlerini gerçekleştirmek ve bu ürünlerin pazarlamasını yapmaktır. Bu hedefe ulaşabilmek için, üretim faktörlerinin sürekli olarak devreye sokulması zorunludur. İşletmeler için binalar, makinalar, teknik donanımlar,

enerji, çalışanlar, çeşitli hizmetler ve ham maddeler gibi kaynaklar vazgeçilmezdir. Bu kaynaklar, üretim hedeflerine uygun olarak işletmenin farklı bölümlerine dağıtılır. Teorik bir bakış açısıyla, üretim faaliyetleri, mevcut üretim faktörlerinin son ürün satışa sunulana kadar süren iş birliği içindeki birleşim sürecidir (Demirdöğen ve Güzel, 2009).

Böyle bir faaliyet, önemli bir yönetim süreci olan planlamayı gerektirir. Çünkü örgütlerin en iyi hedeflerine ulaşmaları, etkili planlara bağlıdır. Etkili bir plan, uygun hedeflerin belirlenmesine, bu hedeflerin başarılması için gereken faaliyetlerin tanımlanmasına ve her faaliyetin düzgün ve etkin bir şekilde gerçekleştirilmesi için yeterli ön sürelerle dayanır. Bu nedenle, örgütler planlama faaliyetlerinde öncelikli olarak üretim planlamasına odaklanırlar (Demir ve Gümüšoğlu, 2003: 445).

Üretim planlama, müşteri memnuniyetini sağlamak amacıyla üretim kaynaklarının kullanımını ve dağıtımını düzenleyen bir yöntemdir. Üretim planlama kararları, işgücü seviyesinin belirlenmesi, üretim faaliyetlerinin sıralanması ve işlerin yüklenmesi gibi unsurları içerir (Graves, 1999).

Üretim planlamasının temel hedefi, iş gücü, malzeme, makine gibi sınırlı kaynakların, gerektiği yerde ve zamanda uygun miktarda temin edilmesini sağlamak ve bu kaynakların etkin ve verimli bir şekilde kullanılmasını optimize etmektir.

Üretim planlamasının görevleri arasında; siparişlerin veya ürünlerin müşteriye doğru zamanda teslim edilmesini sağlamak, tamamlanmış ürünler veya yarımamullere ilişkin stok seviyesini istenilen miktarda ayarlayarak üretim sürelerini olabildiğince kısaltmak ve müşteri taleplerine hızlı bir şekilde yanıt vermek bulunur. Üretim programını esnek tutmak, üretimin akışını sağlayacak malzeme tamamlama sürecini zamanında ve ekonomik bir şekilde gerçekleştirmek, optimum stok seviyesini korumak, satış seviyesine paralel olarak üretim ve stok durumunu gerekli koşullara göre ayarlamak da üretim planlamasının diğer önemli işlevleridir. Uzun vadeli üretim planlarının hazırlanmasında geçerli ve pratik bazı sağlam kriterleri esas almak, mevcut üretim kaynakları ve imkanları en iyi şekilde göz önünde bulundurmak da gereklidir (Yelken ve Demir, 1978: 38, 39).

Üretim planlamanın amaçlarına ulaşılabilmesi ve işlerin başarıyla yürütülebilmesi için ön görülen koşulları üç ana grupta toplamak mümkündür. Bunlar; etkili bilgi toplama sistemini

oluşturmakla başlar. Her fonksiyon veya bölüm, ötekileri için tamamlayıcı rol oynar. Dolayısıyla bölümler arasında sürekli bilgi alışverişi olmalıdır. Ancak böylelikle koordinasyon sağlanabilir. İşlemlerin ne kadar süreceği bilinmiyorsa, bunu gerçekleştirecek planlamanın yapılması hemen hemen olanaksızdır. Standart zamanın hesaplanmasında, çalışma sırasında ne kadar üretimin yapıldığının ve her gözlemdeki performans değerlemesinin ne olduğunun bilinmesi gereklidir. Hiçbir sistem üst kademe yöneticilerinin teşvik ve desteği olmadan yaşayamaz üretim planlaması da yukarıdan desteklenmedikçe yararlı olmaz (Yelken ve Demir, 1978: 38, 39).

Üretim planlamasının ana hedefi faaliyetleri minimum maliyetle ve zamanında tamamlayarak tüketici taleplerine cevap vermektir. Bu ana hedefe ulaşabilmek için çeşitli alt hedeflerin gerçekleştirilmesi gerekmektedir. Bu alt hedefler şunlardır; Planlama, hammadde ve yardımcı malzemelerin, üretim için gerekli olan miktar, zaman ve yerde hazır olmasını garanti etmesi, işletmedeki makine ve ekipmanların etkin kullanılması, iş akışına uygun sıralamanın yapılması ile ekonomik üretim sağlanması, tüketici araştırmaları doğrultusunda belirlenen ihtiyaçlara uygun, istenen miktar ve kalitede üretim yapılması, iş gücü verimliliğinin artırılması, üretim sistemi içindeki tüm birimler ve departmanlar arası entegrasyon sağlanarak etkili bir iletişim sistemi oluşturulması, siparişlerin zamanında ve yeterli miktarda karşılanabilmesi için üretim yapılması, işletmenin ürün stokları, pazar taleplerini karşılayacak şekilde ayarlanmasıdır. Belirtilen hedefler, bilgisayar sistemlerinin kullanımıyla kolayca sağlanıp izlenebilir, bu sayede işletmenin etkin ve verimli üretim yaparak rakiplerle rekabette öne çıkması ve pazarın büyük bir kısmını kontrol etmesiyle maksimum kar elde etmesi mümkün olur. (Akıncı, 2008)

2.3. İş Ölçümü

Süreç yönetimi çalışmaları metot etüdü ve iş ölçümü olmak üzere iki ana başlıkta incelenir. Metot etüdü ile bir işin gerçekleştirilmesi sırasında gereksiz iş unsurları elemine edilerek, gerekli iş unsurlarının en pratik ve en hızlı şekilde yapılmasının yolu bulunmaya çalışılır. Metot etüdü ile tüm çalışanların izleyeceği standart iş adımlarının belirlenmesi amaçlanır. Aslında, standartlaştırılmış bir sürecin elde edilmesi, metot etüdünün çıktılarında biri olarak değerlendirilebilir (Kurt ve Dağdeviren, 2020: 17, 18). Wierschem, Jimenez ve Mediavilla (2020) yaptıkları araştırmada, tekrarlı hareketlerin gerçekleştirildiği işletmelerde hareket etüdü çalışmaları için hareket yakalama tabanlı bir metot geliştirmişlerdir. Önerilen

bu insan hareketi analiz sistemi, üretim çalışanları ve iç lojistik çalışanları tarafından gerçekleştirilen tekrarlayan fiziksel hareketlerden veri toplamak, bu verileri dönüştürmek, depolamak ve analiz etmek amacıyla hareket yakalama teknolojisini kullanmaktadır. Sistem, istatistiksel süreç kontrolü ve veri analitiği tekniklerini kullanarak, tekrarlayan hareket kalıplarını ve bu kalıplardan istatistiksel olarak anlamlı sapmaları belirleyebilmektedir. Bu araştırma, iş ölçümü çalışmalarında standart zaman hesaplama aşamasının öncesinde kritik bir aşama olan hareket-metot etüdü için dijitalleşme ve bilgisayar destekli programların kullanımına bir örnek sunmaktadır. Endüstri 4.0'a işletmelerin hazırlık düzeylerinin belirlenmesi ve bu konuda gerekli ön hazırlıkların yapılması aşamalarında, iş ölçümü çalışmalarına sıkça başvurulduğu bilinmektedir (Ghafoorpoor, Azizi ve Hashemipour, 2018).

İş ölçümü, belirlenmiş bir işin nitelikli bir işçi tarafından belirlenen bir tempoda (çalışma hızı) yapılabilmesi için gereken zamanın saptanmasına yarayan tekniklerin uygulanmasıdır.

Kanawaty (2018)'in iş ölçümü tanımı; nitelikli bir işçinin, belli bir işi, belli bir çalışma hızıyla (performansla) yapması için gereken zamanı saptamak amacıyla gerekli tekniklerin uygulanmasıdır.


Kumar (2015: 213)'in tanımı da aynı niteliktedir: iş ölçümü; bir işi veya çalışmayı gerçekleştirmek için gereken uygun zamanı belirleme tekniğidir. İş ölçümü, nedeni ne olursa olsun verimsiz zamanın araştırılması, azaltılması ve ortadan kaldırılması ile ilgilidir. Bir operasyonun ya da bir dizi operasyonun gerçekleştirilmesinde harcanan zamanın, etkisiz zamanın ortaya çıkmasını ve ayrıştırılmasını sağlayacak şekilde ölçülmesi anlamına gelmektedir.

İş ölçümü, üretim sürelerini ve maliyetleri azaltılabileceği gibi; işletmelerin daha yalın ve rekabetçi hale gelmesine katkıda bulunabilir (Brown, 1994). İş ölçümü faaliyetlerin etkili yapılmadığı durumlarda, etkisiz zamanın incelenmesi, azaltılması veya ortadan kaldırılması ile ilgilidir ve aynı zamanda iş ölçümü çalışmaları ile işin yürütülmesi için standart zamanların hesaplanması sağlanır (Kanawaty, 2018: 244). İş ölçümü sonucunda saptanan standart zamanlara göre yapılacak iş, üretim, kontrol vb. planlar; işçiden ve/veya yönetimden kaynaklanan zaman kayıplarının en alt düzeye indirilmesini ve böylece verimliliğin artırılmasını sağlar (Timur, 1984: 25).

Metot etüdü yapılırken temel amaç, iş kapsamının azaltılması özellikle de işçi, hammadde ve ekipmanların gereksiz kullanımının önüne geçilmesi; hareketlerin azaltılması ve yeni iş uygulama biçimleri geliştirilmesidir. İş ölçümünün amacı ise, yapılan işin ne olduğuna bakılmaksızın işin yapılması sırasında beklemelerin yaşandığı (boşa harcanan) sürelerin tespitinin sağlanıp azaltılması ve mümkünse ortadan kaldırılmasıdır (Tunçbilek, 2019).

2.3.1. İş ölçümü teknikleri

İş ölçümü, üretimdeki verimliliği ölçebilmek ve izleyebilmek için yapılan çeşitli süre ölçümleri ve istatistiksel analizleri içeren çalışmaları ifade eder. İş ölçümü teknikleri, dolaylı ve dolaysız olmak üzere iki ana kategoriye ayrılır (Şekil 2.2). Bu alt başlık altında literatürde ve alan uygulamalarında en sık tercih edilen dolaylı ve dolaysız iş ölçümü tekniklerine dair bilgilere yer verilecektir.



Şekil 2.2. İş ölçüm teknikleri (Kurt ve Dağdeviren, 2020:17)

Dolaylı iş ölçümü teknikleri

Üretim veya iş planlaması yapılırken prosese ait sürelerin belirlenmiş olması gerekmektedir. Bu sürelerin doğruluğu ve güvenilirliği işletmeler için oldukça önemlidir. İşletmeler üretim planlarını bu süreler üzerinden yapmaktadır. Birçok yerde zaman etüdü yapılırken kronometre süreleri kullanılmaktadır. Klasik ölçüm yöntemi olan kronometre süreleri ancak ürün üretim esnasında ölçülebilmektedir. Üretim esnasında ölçülen sürenin uzunluğu anlık değişir. Kişinin anlık ruh haline, içinde olduğu ortama, müziğin ritmine göre değişmektedir. Bu sebeple iş planlaması yaparken kronometre süresi gibi anlık değişebilen süreler yerine daha doğru bilgi sağlayan standart bir yöntem gereklidir (Şahin, 2023).

PMTS, elle yapılan herhangi bir operasyonu analiz ederek gereken temel hareketleri belirleyen, bu temel hareketlerden her birine, onu etkileyen faktörlere göre önceden belirlenmiş standart süre hesabını içeren prosedürdür. Sentetik Zaman Sistemleri, standart süre hesabının odağını iş ölçümünden metoda çeker, hesaplamalarda önceden belirlenmiş ve zaman ölçüleri bilinen temel metotlar çalışma zamanları için ölçü niteliğindedir. Sentetik Zaman Sistemlerinde her hareket için standart bir zaman değeri belirlenmiştir, bu zamanların büyüklüğünü ise analiz edilen işte tanımlanan temel metotlara dair belirlenmiş faktörlerin saptanan sayısal değerleri ve sınıfları belirler. Sentetik Zaman Sistemlerinin bir diğer faydası evrensel olmalarıdır, hareket öğelerinin ortak kodlanmasıyla iş sürecinin uluslararası ölçekte kabul görmesi sağlanır (Şahin, 2023).

Sentetik Zaman Sistemleri iş ölçümünde klasik zaman belirleme metotlarına göre önceden çalışma metodunu tanımlayıp verilecek zamanı belirleyebilme gibi avantajlar sunar. Bu yöntem iş akışının detaylı incelenmesini gerektirir ve bu da en uygun metodu belirleme olanağını sağlar, ayrıca planlama aşamasında farklı çalışma metotlarını karşılaştırmaya ve iş akışlarını önceden planlamaya olanak tanır. Standart zamanları belirlerken, kronometreyle yapılan ölçümlerin aksine, zorluk ve performans ile olan ilişkiyi incelemeye gerek kalmaz; çünkü Sentetik Zaman Sistemlerinde belirlenmiş süreler uzun zamanlı ve geniş örneklemelerde performans ve zorluk dereceleri de göz önüne alınarak hesaplanarak kabul görmüş ortalama zamanlardır ve hesaplanacak standart zamanlar bu etkenleri dikkate alır.

İşlemleri oluşturan faaliyetler, iş parçasının şekli, kullanılan makinenin türü ve çalışma yöntemi gibi faktörlere bağlı olarak önemli farklılıklar gösterir. Laboratuvar deneyleriyle elde edilen verilerin güvenilirliği oldukça yüksek olup, maliyetleri ise düşüktür. Ancak işlemler, çalışanların gözü önünde yapılmadığı için çalışanlar, ücretlendirme esasına dayanan bu yönteme güvenmeyebilirler (Üçüncü, 2015).

Yürüme, çalıştırma, sıkıştırma ve gevşetme, yerleştirme, vb. gibi birçok faaliyette aynı şekilde tekrar eden elemanlar standart veriler olarak Standart Veri Sistemleri (SVS) yöntemi ile oluşturulan işletmeye özgü bir sistemden elde edilebilir. Bu şekilde belirlenen işlem süreleri, çeşitli varyasyonlarla tablolarda özetlenerek bir veritabanı oluşturulabilir. İş, öğelerine ayrıldıktan sonra, her öğenin normal zamanı standart veriler veritabanından alınır. Bu zamanlar toplanarak işin toplam süresi belirlenir. Normal zamana ek paylar eklenerek standart zaman belirlenir (Üçüncü, 2015). SVS kullanılarak veri eksikliği olan durumlarda

veya daha hızlı sonuçlar gerektiğinde dolaylı teknikler (tahmin ve karşılaştırma metotları) kullanılabilir. Bu kapsamda makine öğrenmesi modelleri aracılığıyla geçmiş işlem verilerinden öğrenerek gelecekteki iş süreçlerinin süreleri tahmin edilebilir. Bu modeller, veri setlerindeki kalıpları ve ilişkileri belirleyerek, standardizasyonun ötesinde, özelleştirilmiş süre tahminleri sunar. Bu, üretim planlama süreçlerindeki belirsizlikleri azaltır ve daha doğru planlamalar yapılmasını sağlar.

Karşılaştırma yöntemleri, makine öğrenmesi teknikleriyle birleştirilerek, benzer işlemler arasında daha sofistike karşılaştırmalar yapılmasına olanak tanır. Örneğin, k-means kümeleme gibi algoritmalar kullanarak benzer işlem gruplarını tespit edebilir ve bu grupların performanslarını karşılaştırılabilir. Bu tür analizler, süreçler arasındaki farklılıkları ve benzerlikleri daha detaylı ortaya koyarak, hangi süreçlerin optimizasyon için uygun olduğunun belirlenmesine yardımcı olur. Bu teknikler ile üretim süreçlerinde daha hassas ve dinamik planlama ve kontrol sağlanır. Makine öğrenmesi modellerinin uygulanması, sadece standart sürelerin hesaplanmasını değil, aynı zamanda süreçlerin sürekli iyileştirilmesini de destekler. Bu, üretim verimliliğinin artırılması ve maliyetlerin düşürülmesi gibi stratejik avantajlar sağlar.

Dolaysız iş ölçümü teknikleri

Dolaysız iş ölçümü tekniklerinden birisi olan iş örnekleme; belli bir faaliyetin oluş oranını (% olarak) istatistiki örnekleme ve rassal gözlemler yoluyla saptama yöntemidir. Yaygın olarak bir sistemin ya da sistem elemanının (işçi veya tezgâh) performansının (çalışma oranı gibi) (Güner, Küçük ve Acar, 2016), başka bir deyişle, belli bir akışın içindeki analiz edilecek özel tip akışın ortaya çıkma oranının belirlenmesi amacıyla kullanılır.


İş örnekleme, doğrudan ölçüm yöntemlerinden biri olarak özellikle tüm parametrelerin ölçümünün zor olduğu durumlarda, bir kümeden alınan örnek bir grup üzerinden bu parametrelerin tahmin edilmesini sağlayan bir tekniktir. Etkinlik örnekleme, faaliyet örnekleme, gecikme oranı analizi, rasgele gözlem yöntemi, anlık okuma yöntemi ve gözlem oranı etüdü ölçümü gibi çeşitli isimlerle de bilinir. Sürekli bir gözlem yerine, üretim sistemi içinde rastgele seçilen zamanlarda yapılan gözlemlerle çalışan veya duran makineler ve işçilerin durumları ve bunların nedenleri kaydedilir. Elde edilen veriler, istatistiksel teknikler kullanılarak belirli bir olasılık ve güvenilirlik düzeyinde oransal olarak hesaplanır. İş

örnekleme, standart zamanın hesaplanması, faaliyet ve gecikme oranlarının analizi, performans değerlendirmesinde kullanılır. Üretim, hizmet ve ofis işlerinde farklı birimlerin etkinliğinin karşılaştırılması, gruplar arasında adil iş yükü dağılımının sağlanması, aktif olmayan sürelerin tespiti ve bu sürelerin nedenlerinin analizi gibi amaçlar için yapılacak analizlerde de tercih edilen bir yöntemdir. İş örnekleme sayesinde, metot etüdünün nereye uygulanacağı, malzeme taşıma sisteminin nasıl iyileştirileceği ve hangi üretim yöntemlerinin geliştirileceği gibi verimlilik eniyilemesi hedefli yönetsel kararlar sayısal hesaplamalar ve gerçek oranlarla desteklenerek verilebilir.

İş örneklemesinin aşamaları aşağıda verilmiştir (Kanawaty, 2018: 200):

- Etüt edilecek işin seçimi ve amacının belirlenmesi.
- p ve q 'nin yaklaşık değerlerini belirlemek üzere ön gözlem yapılması.
- Seçilen güvenlik düzeyi ve kesinlik sınırlarına göre gerekli gözlem sayısının (n) belirlenmesi.
- Rassallığı arttırarak şekilde gözlem çevresinde yapılacak tur rotalarının belirlenmesi ve rasgele sayılar tablosu kullanılarak tur zamanlarının belirlenmesi.
- Etüdün amacına uygun olan kayıt formunun tasarlanması.
- Gözlemlerin yapılması ve sonuçların çözümlenmesi.

Pahalı olan, ancak pratik olmayan sürekli gözlem yönteminden farklı olarak örnekleme yöntemi, olasılık kuramına dayanmaktadır. Bu analizde gerçek zamanlı tam gözlemler yapılarak süreler tutulmadığından örnekleme yönteminin güvenlik düzeyinin belirlenmesi gerekmektedir. Örnek büyüklüğünü ya da gözlem sayısını veren bağıntı, örnek sayısının normal dağılım göstermesi halinde geçerlidir. Dolayısıyla iş örnekleme yönteminin kullanımında güvenilirlik analizleri için kullanılacak normal dağılıma uygun güvenlik düzeyleri Eş. 2.1 – Eş. 2.4 ile aşağıda gösterilmiştir (Üçüncü, 2015):



Şekil 2.3. Normal dağılım güvenlik düzeyleri (Yalçın, 2019)

$$\%90 \text{ güven düzeyi ya da eğri içindeki alanın } \%90'ı = 1,62 \sigma \quad (2.1)$$

$$\%95 \text{ güven düzeyi ya da eğri içindeki alanın } \%95'i = 1,96 \sigma \quad (2.2)$$

$$\%99 \text{ güven düzeyi ya da eğri içindeki alanın } \%99'u = 2,58 \sigma \quad (2.3)$$

$$\%99,9 \text{ güven düzeyi ya da eğri içindeki alanın } \%99,9'u = 3,30 \sigma \quad (2.4)$$

Burada; p , elemanın toplam süre içindeki % olarak payı ya da oluş yüzdesi (oluş yüzdesi dışındaki değer = q) olmak üzere; yüzde olarak " $p + q$ " değeri "100" e eşit olmalıdır. σ , eleman dağılımının standart sapmasını, S ; duyarlık ya da hata payı ($\%p$ cinsinden); n , örnek sayısını belirtmektedir. Normal dağılım için aşağıdaki eşitlik geçerlidir:

$$\sigma = \sqrt{\frac{pq}{n}} \text{ ve } n = \frac{pq}{\sigma^2} \quad (2.5)$$

Normal dağılım standart normal dağılım olarak ele alınır ve standart değer $Z = \frac{S}{\sigma}$ eşitliği ile hesaplanır. Duyarlılık, tahminlerin verilen olasılık düzeyinde güvenle gerçek değeri temsil edeceğini gösterir. Eş. 2.5'te belirtildiği üzere σ ; Standart sapmayı, p ; elemanın toplam süre içindeki % olarak payı ya da oluş yüzdesi (oluş yüzdesi dışındaki değer = q) olmak üzere, n ; deney sayısı veya örneklem büyüklüğünü ifade eder.

$$\text{Örnek Büyüklüğü} = n = Z^2 \frac{pq}{s^2} \quad (2.6)$$

Eş. 2.6.'da n ; gerekli örneklem büyüklüğü, Z ; güven düzeyine karşılık gelen Z değeri (standart normal dağılımın Z -skoru), p ; elemanın toplam süre içindeki % olarak payı ya da oluş yüzdesi (oluş yüzdesi dışındaki değer = q) olmak üzere; yüzde olarak " $p + q$ " değeri "100" e eşit olmalıdır, s ; istenilen hata payını (standart hata) ifade eder. Gözlemler sürekli yapılmayıp örnekleme yöntemi uygulandığında, bu gözlemlerin rastgele yapılması gerekmektedir. Rastgele gözlemlerin ne zaman yapılacağı rastgele sayılar tablosundan yararlanılarak belirlenir. Rastgele sayılar tablosundan, belirlenen bir sayıdan başlamak üzere gözlem sayısı kadar rastgele sayı seçilen atlama sayısına göre sıra ile belirlenir. Bu sayılardan tekrar eden sayılar ve devre sayısına eşit sayıları aşan sayılar iptal edilerek yeni sayılar seçilir. Gözlem sayısı kadar seçilen rastgele sayılar küçükten büyüğe doğru sıralanır. Her sayı, gözlem süresi ile çarpılıp referans alınan başlama zamanına eklenerek rastgele gözlem zamanı belirlenir (Üçüncü, 2015).

Bir diğer dolaysız iş ölçümü tekniği olan zaman etüdü; manuel iş yükünün iş sisteminde baskın olduğu, işçinin işi ve tezgâhı yönlendirdiği işlemler için uygulanabilen ve hem alan uygulamalarından hem de literatürde en sık kullanıldığı bilinen, gerçek zaman ölçümlerine dayalı veriler ile zaman türlerinin ve bunlara bağlı olarak da standart sürenin belirlenebildiği bir yöntemidir.

Zaman etüdü çalışmaları oldukça meşakkatli, uzun zaman ve yoğun emek gerektiren iş ölçümü uygulamalarıdır. Organizasyonların bu maliyetlere katlanmasını zaruri kılacak bazı durumlarda zaman etüdü sonuçlarının elde edilmesinin gerekliliğinin ortaya çıktığı söylenebilir. Bu durumlara örnek olarak yeni bir ürünün sisteme dahil edilmesi (Fantoni, Al-Zubaidi, Coli ve Mazzei, 2021; Ojstersek, Javernik ve Buchmeister, 2021; Ji, Pannakkong ve Buddhakulsomsiri, 2022; Palander, Pasi, Laurén ve Ovaskainen, 2024), yöntemde yapılan değişiklikler, bir işçi veya temsilcinin ayrılan süreye dair şikayeti (Peimbert-García, Gutiérrez-Mendoza ve García-Reyes, 2021; Lee, Lin, Howard ve Bao, 2023; Salimgereyev, Mukhamediyev ve Shaikh, 2024), iş akışında darboğaz oluşturan işler (Nortey ve diğerleri, 2023), performans ve teşvik programlarına geçiş (Sengupta, Das ve Cyrus, 2010; Rane ve diğerleri, 2017), makine ve ekipmanların düşük performansı veya uzun süreli boşa çalışması (Poje, Lipuzic, Bilobrk ve Pandur, 2024; Schweier, Werder ve Bont, 2024), yöntemlerin karşılaştırılması gerektiğinde (Spinelli ve diğerleri, 2022; Kiris, Eryarsoy, Zaim ve Delen,

2023; Gudlin, Hegedic, Golec ve Kolar, 2024), bir işin maliyetinin aşırı yüksek olması (Dey, Mandal ve Bhar, 2022; Murray, Hiesl, Hagan ve Baldwin, 2023; Murase ve diğerleri, 2024), önceki iş ölçüm çalışmalarıyla ilgili şikayetlerin çözülmesi (Gisondo ve diğerleri, 2022; Kristiana, Asih ve Sudiarso, 2023; Yarnoff, Wagner, Honeycutt ve Vogt, 2023; Çınar ve Esatoglu, 2024), malzeme değişikliklerinin üretim süresine etkisi (Lindhard, 2023) gibi hususlar gösterilebilmektedir.

Çalışan çok sayıda işçinin bulunduğu ortamlarda zaman etüdü uygulanacak operasyonların seçiminde analize dahil edilmesi için seçilecek işçinin nitelikli olması kritik önem taşımaktadır (Niebel ve Freivalds, 2002). Nitelikli (kalifiye) çalışan, işi belirlenen güvenlik, kalite, miktar standartlarına uygun şekilde yerine getirebilme yetisine, fiziksel kapasiteye, zekâ, eğitim, beceri ve bilgiye sahip çalışan olarak tanımlanırken, standart zaman kalifiye bir işçinin analiz edilecek işi kabul edilen belirlenmiş bir performans düzeyinde tamamlaması için ihtiyaç duyacağı süre olarak tanımlanabilmektedir.

Zaman etüdü çalışmalarında kullanılan bazı temel araçları vardır. Bunlar; kronometre, etüt tablası ve zaman etüdü formlarıdır (Kurt ve Dağdeviren, 2020).

Daha hassas ölçümlere ihtiyaç duyulacak sistemler ya da analiz amaçları söz konusu olduğunda kronometre yerine sinema makinası ve zaman etüdü makinası (şeridi) kullanılabilmekteyken, her iki ölçümde de film veya kâğıt şerit sabit bir hızla hareket ederken, şeritle ölçümede ölçüm sonunda şerit uzunluğu ölçülerek zamanlar belirlenmektedir (Kurt ve Dağdeviren, 2020).

İş ölçümünde zaman etüdü tekniğinin uygulanması aşamaları aşağıda sunulmaktadır (Kanawaty, 2018: 201).

- Zaman etüdü yapılacak işin, işçinin ve iş istasyonunun seçilmesi,
- İş, işçi ya da işin yapılmasını etkileyen çevre koşulları ile ilgili bütün mevcut bilgilerin toplanması ve kaydedilmesi,
- İşin elemanlarına ayrılması,
- En etken yöntem ve hareketlerin kullanılmasını sağlamak için ayrıntılı olarak elemanların incelenmesi,

- Kronometre ile her iş elemanının sürelerinin kaydedilmesi,
- Çalışma hızının, bir diğer deyişle performansın derecelendirilmesi, performans takdiri,
- Gözlenen zamanların temel zamanlara dönüştürülmesi,
- İşlemin temel süresine eklenecek dinlenme ve dağılım zamanı paylarının belirlenmesi ve temel zaman ve bu belirlenen paylardan hareketle dinlenme ve dağılım zamanlarının hesaplanması,
- Temel zaman, dinlenme zamanı ve dağılım zamanı sürelerinden hareketle standart zamanının belirlenmesi.

Metot etüdündeki yaklaşımlarla paralel olarak, zaman etüdü çalışmalarında da doğru seçimler yapıldıktan sonra, sistematik bir şekilde bilgiler toplanmalı ve bu bilgiler uygun standart kayıt ortamlarına aktarılmalıdır. Zaman etüdünde ele alınan bilgiler etütle ilgili genel bilgileri, işlenen parça veya ürün hakkında tanıtıcı bilgileri, kullanılan proses, üretim metodu, iş istasyonu veya tezgâh hakkında bilgileri, işçiye dair tanıtıcı bilgileri veya çalışma koşulları hakkında bilgileri içerebilmektedir (Kumaş, Sabır ve Baykal, 2016).

İşçi ve işlemle ilgili verilerin kaydı tamamlandıktan sonra, işin daha detaylı incelenebilmesi için elemanlarına ayrılarak küçük parçalar halinde analiz edilmesi gerekmektedir. Bu sayede ölçüm esnasında olası hatalar en aza indirgenebilir. Bir iş elemanı, işin analizini, gözlem ve ölçümünü kolaylaştırmak amacıyla belirlenen, o işe özgü bağımsız bir parçadır. İş döngüsü ise, bir işin tamamlanabilmesi veya bir ürün biriminin üretilmesi için gereken elemanların sıralamasını ifade etmektedir. İşlerin elemanlara ayrılması sırasında önemli olan, her bir iş elemanının belirlenebilir yapıya ve ölçülebilir süreye sahip olmasıdır (Kurt ve Dağdeviren, 2020).

İşin elemanlara ayrılmasında el ile yapılan işler ile makine kullanılarak yapılan işlerin ayrı tutulması, her döngüde tekrar eden işler ile rastgele ortaya çıkan işlerin birbirinden ayrılması ve farklı hızlarda gerçekleştirilen işlerin kendi elemanlarına bölünmesi gibi hususlara dikkat edilmelidir (Kurt ve Dağdeviren, 2020).

Ölçme sayısı veya örnek büyüklüğü yapılacak analizin hassasiyet seviyesi, yani hata oranının büyüklüğü ya da bir başka deyişle sonuçların içinde dağılması istenen güven aralığı değerine göre belirlenmelidir.

Zaman etüdü iş ölçümü yöntemi uygulamalarında süre ölçümü birikimli (sürekli) ve tek (geriye dönüşlü) olmak üzere iki türlü yapılabilir. Sürekli zamanlamada etüt süresince kronometre sürekli çalıştırılır. Ölçümü yapılacak ilk işin ilk elemanından ölçüm başlar ve etüt tamamlanıncaya kadar kronometre durdurulmaz. Her elemanın sonunda kronometre verisi kaydedilir. Her elemana ait süre, etüt tamamlandıktan sonra yapılan çıkarma işlemleri ile elde edilir. Geriye dönüşlü zamanlamada, her öğenin bitiminde kronometre sıfırlanır ve hemen tekrar başlatılır. Bu şekilde, her öğeye ait zaman doğrudan elde edilir. Etütte kaydedilen öğelerin ve diğer etkinliklerin sürelerinin, etkisiz süre ve denetleme süresiyle toplamına kaydedilen süre denir. Kaydedilen sürenin, geçen süreye eşit olması beklenir. Ancak, geriye dönüşlü zamanlamada, kronometre sıfırlanırken geçen zaman, hatalı okuma ve bazı öğelerin kaydedilmemesi nedeniyle kaydedilen süre, geçen süreden daha az çıkabilir. Geriye dönüşlü yöntem, kısa süreli öğelerde hata yüzdesini artırdığından, uzun süreli öğelerde kullanılması daha doğru sonuçlar verir. Diferansiyel zamanlama, ölçümü zor olan kısa döngülü ve kısa öğeli işlerin kesin zamanlarını elde etmek için kullanılan bir zaman ölçme yöntemidir. Bu yöntemde öğeler gruplandırılarak ölçülür (Groover, 2007: 57, 58).

Zaman etüdü iş ölçümü tekniğinin dolaylı ve dolaysız diğer iş ölçümü yöntemlerine en büyük üstünlüğü etüdünün çalışan performansının standart sürenin üzerindeki etkisini göz önünde tutabilmesine olanak sağlamasıdır. İş ölçümünde tutulan gerçek tek ya da sürekli zamanların temel zaman hesabı için kullanımında o iş ve çevrim için işçinin çalışma hızını temsil eden performans düzeylerinin (oranlarının) belirlenmesi ile hesaplanan standart süre analiz edilen iş sistemini çok daha gerçekçi olarak temsil edebilmektedir. İşçinin gerçekleştirdiği iş sırasında olması gereken performansla oranla çalıştığı hızına “tempo” denir. Normal tempo, yetkin ve eğitilmiş bir işçinin, aşırı yorgunluğa neden olmadan ve gerekli dinlenme sürelerini de dikkate alarak bir işi yaparken harcadığı süre olarak kabul edilmektedir. Makineler çalışırken genellikle sabit bir hızda işlem görürken, insanların çalışma hızı aynı koşullarda bile farklı zamanlarda değişkenlik gösterebilir ve bu hız değişikliğinin derecelendirilmesinin, etüdün doğruluğu için önemi büyüktür.

Dolaysız iş ölçümü tekniklerinden olan grup zamanlama tekniği; çok sayıda işçinin çok sayıda işlemi ortaklaşa yaptığı işlemlerde kullanılır. Grup zamanlama tekniği kronometreli bir gözlemcinin, 2-15 işçi veya makineyi bir anda gözleyerek ayrıntılı sonuçlar elde etmesini sağlayan bir iş ölçümü yöntemidir (Zandin, 2001: 17-61). İş elemanlarının sürekli olarak önceden saptanmış sabit aralıklarla gözlenmesi ve işçilerin performansının

derecelendirilmesi esasına dayanır. Bu anlamda grup zamanlama tekniği, iş örneklemesine çok benzemesine rağmen rassal bir esasa dayandırılmamıştır.

Gözlemler arasındaki zaman uzunluğu işçi ve makine sayısı ile bunların konumlarına bağlı olarak geliştirilmektedir. Ancak, zaman aralığının süresi en kısa iş elemanından daha kısa bir zaman değerine sahip olması istenmektedir (Pamir, 1984: 93).

Grup zamanlama tekniği daha çok bakım-onarım ve büro işlerinde tercih edilmektedir. Yöntemin, standartların kontrolü ve iş yükü miktarının saptanmasında kolaylık ve düşük maliyet sağlaması avantaj olarak belirtilmektedir. Çok iyi eğitilmiş gözlemciye ihtiyaç duyulmaması ve işçiler açısından grubun etüt edilmesi nedeniyle daha kolay kabul edilebilir olması yöntemin diğer avantajlarıdır (Çelikoğlu, 1989).

2.4. Makine Öğrenmesi

Makine öğrenmesi, bir problemi o probleme ait veriye göre modelleyen bilgisayar algoritmalarının genel adıdır. Mevcut veri seti ve kullanılan algoritma ile oluşturulan model, en yüksek performansı vermek üzere kurulmaktadır. Bu sebeple pek çok makine öğrenmesi yöntemi geliştirilmiş olup bunlardan bazıları; k-en yakın komşu algoritması (K Nearest Neighbour - KNN), basit (naive) Bayes sınıflandırıcı, karar ağaçları, lojistik regresyon analizi, k-ortalamalar algoritması, DVM ve YSA'dır. Bu yaklaşımların bir kısmı tahmin ve kestirim, bir kısmı kümeleme ve bir kısmı da sınıflandırma yapabilme yeteneğine sahiptir (Atalay ve Çelik, 2017).

Makine öğrenmesinin ilk adımları 1950'lerde atılmıştır fakat "Yapay zekâ kış uykusu" olarak da adlandırılan dönemde başta donanımsal kısıtlamalar ve diğer problemler sebebi ile bu alandaki çalışmalar durma noktasına gelmiştir (Şeker, Diri ve Balık, 2017).

Makine öğrenimi tarihinde ilk kez 1959 senesinde "Arthur Lee Samuel" tarafından IBM için geliştirilen dama oyununu tasarlarlarken bu terimi kullanmıştır. Makine öğrenimi için; "Bilgisayarların açıkça programlanmadan öğrenmesini sağlaması gereken bir araştırma alanıdır" denmiştir (Samuel, 1959).


1967'de KNN ile makine öğrenmesi oluşturulmuştur. Araştırmacılar 1980 ve 1990'larda beynimizin yapısından esinlenerek bir tür makine öğrenme modeli olan YSA'yı eğitmek için yeni bir algoritma sınıfı daha oluşturmuştur. 1950'li dönemlerden bu yana yapay zeka teknolojilerinde hızlı bir ilerleme görülememiş lakin zaman geçtikçe, gelişen bilgisayarlar ile birlikte yapay zeka teknolojileri de gelişmiştir. Son yirmi yılda veri kullanılabilirliği bin kata, temel algoritmaların gelişmişlik seviyesi yüz kata ve donanım hızı en az yüz kat kadar artmıştır. Günümüzde veri miktarındaki artış, çok geliştirilmiş algoritmalar ve daha güçlü bilgisayar donanımları yapay zekâ teknolojilerinin önünü epey açmıştır (Fradkov, 2020).

Makine öğrenmesinin asıl amacı gelen verilerinden yararlanarak anlamlı bir sonuca ulaşmak ve ortaya bir ürün çıkarmaktır ve bunun için veri, değişkenler (Parametreler) ve algoritma şeklinde sıralanan üç temel bileşene ihtiyaç duymaktadır (Siddiqui ve Abdullah, 2015)

Veri elde etmek için manuel ve otomatik olmak üzere iki yol vardır. Manuel veri toplama daha az hataya sahip olmasına karşın çok uzun ve maliyetli bir süreçtir. Otomatik veri toplama ise daha kısa sürede ve ucuz olmasına rağmen daha çok hata barındırır. Değişkenler, bir makine öğrenmesi modeli kurulurken bakılması ve öğrenilmesi gereken makine öğrenmesi temel bileşenidir. Örneğin; bir hisse senedinin fiyatı, müşterinin cinsiyeti, vb. gibi değişkenler bazı veri kümelerinin içerisinde bulunan değişkenlere örnek olarak verilebilir. Algoritmalar, verilerdeki kalıpları bulmak için çalıştırılan motorlardır. Her problem için farklı bir makine öğrenmesi algoritma yaklaşımı vardır. Model boyutu, performans, doğruluk, hassasiyet ve sonuç seçilen algoritmaya bağlıdır (Karakuş, 2021: 7)

Makine öğrenmesi, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme gibi birkaç öğrenme paradigmasını içeren yapay zekâ dalının bir koludur (Shirzadi ve diğerleri, 2018). Yapay zekâ, zeki makineler, özellikle de zeki bilgisayar programları oluşturan bilim ve mühendislik dalı haline gelmiştir. Temel beklenti, insan zekâsının karakteristik özelliklerini bilgisayara kazandıran algoritmalar geliştirmek ve problemlere insan gibi zeki davranışlar sergileyerek çözümler üretebilen sistemler geliştirmektir. Zaman zaman bu beklentinin de ötesine geçilerek insanoğluna hükmeden sistemler geliştirme hayallerinin kurulduğunu söylemek de yanlış olmaz. Ancak gerçekçi ve bilimsel bir bakış açısı ile yapay zekâ, tecrübelerden öğrenebilen, öğrendiklerini muhakeme edebilen; şekilleri, görüntü ve örüntüleri tanıyabilen, karmaşık problemlere çözümler üretebilen, lisanı anlayarak kelimeler ile işlem yapabilen ve bilişim dünyasına farklı bir bakış açısı kazandıran bir bilim dalıdır

(Öztemel, 2020). Birçok sektörde verinin artan büyümesiyle, uygun makine öğrenmesi algoritmalarının benimsenmesi veri analizi ve işleme verimliliğini artırabilir ve aynı zamanda bazı pratik sorunları çözebilir hale gelmiştir (Lou, Lv, Dang, Su ve Li, 2023). Makine öğrenmesi birçok araştırmada derinlemesine ele alınmıştır (Marsland, 2014: 1-430; Mohri, Rostamizadeh ve Talwalkar, 2018: 1-488). Makine öğrenmesi algoritmaları, kullanılan veriler ve hesaplama algoritmalarının işleyişine göre bazı başlıklar altında aşağıdaki şekilde görüldüğü üzere gruplanarak incelenebilmektedir.



Şekil 2.4. Makine öğrenmesi türleri

Denetimli öğrenme, algoritmanın girdi verilerinden verileri tahmin etmeyi öğrendiği anlamına gelir ve bu türde girdi ve çıktı verileri bulunur. Denetimsiz öğrenmede, algoritmanın yalnızca girdi verileri vardır ve girdi verilerinden içsel yapıyı öğrenir. Ayrıca, yarı denetimli öğrenme her iki tekniğe de (denetimli ve denetimsiz) bağlıdır. Hem etiketlenmiş hem de etiketlenmemiş verileri kullanırlar ve bu durum, bazı girdi verilerinin etiket verilerine sahip olduğu ve bazılarının ise etiket verilerine sahip olmadığı anlamına gelir. Pekiştirmeli öğrenmede, sistem çevre ile etkileşim yoluyla öğrenmeye çalışır ve istenen eylemi ödüllendirirken istenmeyenleri cezalandırır. Derin Öğrenme, her katmanın önceki katmandan bilgi aldığı ve sonucu bir sonraki katmana ilettiği şekilde birden çok algı düzeyini tutan ve birden çok katmandan oluşan bir makine öğrenme türüdür (İbrahim ve Abdulazeez, 2021).

2.4.1. Denetimli öğrenme

Denetimli öğrenme, makine öğrenmesinin en temel ve yaygın kullanılan türlerinden biridir (Bonaccorso, 2017). Bu yöntemde, bir modelin eğitim veri setindeki girdi ve çıktı arasındaki ilişkiyi öğrenmesi amaçlanır. Eğitim veri seti, etiketlenmiş veri örneklerinden oluşur, yani her girdiye karşılık gelen doğru çıktı bilinir. Denetimli öğrenme algoritmaları, eğitim veri setini kullanarak bir model oluşturur ve yeni girdiler için tahminler yapar (Bishop, 2006: 3).

Denetimli öğrenme; sisteme eğitim veri seti ve test veri setinin yüklenmesi, veri setinde her bir veri için gerekli etiketlenmenin yapılması ve bu sayede girdi veri seti ile çıktı veri seti arasında ilişki kurulması mantığına dayanır. Temel amaç sonuçları bilinen veri setinden yapılan sınıflandırmadan hareketle sonuçları bilinmeyen veri setine dair etkili tahminler yapabilmektir (Aydın ve Özkul, 2015: 38).

Denetimli öğrenmede amaç, etiketli verilerin hangi sınıfa ait olduğunu ve hangi çıktı değerine karşılık geldiğini belirlemektir. Oluşturulan model ile elde edilen sonuç arasındaki fark, hata oranını ifade eder ve bu oran her zaman en aza indirilmeye çalışılır (Kavuncu, 2018).

Denetimli öğrenmede kullanılan algoritmalar, bilinen bir veri kümesinden öğrenme gerçekleştirir. Ardından, sisteme gönderilen yeni verilerle tahminler yapılır. Eğitim için kullanılan veriler ne kadar doğru olursa, yapılan tahminler de o kadar doğru çıkar. Tahmin için kullanılan veriler etiketlenmişse, genellikle bu denetimli öğrenme yöntemlerinin kullanıldığını gösterir (Okur, 2020).

Denetimli öğrenme yöntemlerinde, veri seti genellikle eğitim verisi (training data) ve test verisi (testing data) olarak ikiye ayrılır. Eğitim verisi, kullanılacak algoritma için gözlemlerden oluşan veri kümesidir. Bu veriler kullanılarak, ele alınan algoritma ile çıkarımlar yapılır ve bir model oluşturulur. Test verisi ise, eğitim verisi ile oluşturulan modelin gerçek değerlere ne kadar yakın olduğunu, yani sistemin başarısını belirlemek amacıyla kullanılan veri kümesidir (Çağlayan, 2018). Denetimli öğrenme olarak adlandırılmasının nedeni, algoritmanın, verilerin büyük bir kısmını oluşturan eğitim verisinden öğrenme sürecini gerçekleştirmesi ve bu sürecin test verisi ile denetlenmesidir. Denetimli makine öğrenmesi, öncelikle tahmin ve kestirim problemlerine odaklanır. Bu alandaki konular, regresyon ve sınıflandırma olarak iki alt grupta incelenir (Kaya, 2015).

Regresyon ve sınıflandırma algoritmaları, belirli fonksiyonları tanımlamak amacıyla kullanılır. Regresyon algoritmalarının kullanımı için, çıktı verilerinin sürekli, yani sayısal değerler olması gerekmektedir. Kategorik veriler söz konusu olduğunda, bu veriler doğrudan regresyon modeline giremez; bu nedenle, sayısallaştırılarak modele dahil edilir. Sınıflandırma algoritmalarında ise çıktı verilerinin sınırlı sayıda olası sonuçlara sahip olması, yani kategorik bir yapıya sahip olması gereklidir (Bonaccorso, 2017).

Karar ağaçları (Breiman, Friedman, Olshen ve Stone, 1984), YSA (Haykin, 2009: 48) ve DVM (Cortes ve Vapnik, 1995) gibi algoritmalar, denetimli öğrenmenin örnekleridir. Karar ağaçları, bir veri setini ağaç yapısıyla temsil ederek sınıflandırma veya regresyon görevleri için kullanılabilir. YSA, biyolojik sinir ağlarından ilham alarak karmaşık desenleri tanımlayabilir ve geniş bir uygulama alanına sahiptir. DVM ise iki sınıf arasında optimal bir karar sınırı oluşturarak sınıflandırma yapabilir.

2.4.2. Denetimsiz öğrenme

Denetimsiz öğrenme, veri集中的i desenleri ve yapıları keşfetmek için kullanılan bir makine öğrenme yaklaşımıdır (Hastie, Tibshirani ve Friedman, 2009). Bu yöntemde, veri集中的i çıktı etiketleri bulunmaz ve algoritma, veri üzerinde yapısal analizler yaparak veri noktalarını gruplara ayırır veya veriyi boyut indirgeme gibi yöntemlerle daha basitleştirir (Bishop, 2006: 3). Yoğunluk tahmini olarak da bilinen denetimsiz makine öğrenmesi, sınıfı olmayan verilerle çalışarak, benzer özelliklere sahip verilerin gruplandırılmasını amaçlar ve girdi verileri için uygun bir gösterim biçimi belirler. Bu öğrenme türü, yalnızca girdi değerlerinden oluştuğu için girdilere karşılık gelen bir çıktı (sınıf veya etiket) değeri yoktur. Dolayısıyla, girdilerin hangi sınıfa ait olduğu bilinmemektedir (Fatima ve Pasha, 2017). Denetimsiz öğrenme algoritmaları, Birliklilik Kuralı, Kümeleme Analizi, Boyut Azaltma olarak üç grup altında incelenebilir (Çam, 2021).

Kümeleme, heterojen bir veri yapısının homojen alt gruplara ayrılması işlemidir. Başka bir deyişle, kümeleme, önceki bilgilerin bilinmediği veya sınıf sayısının belli olmadığı durumlarda, verilerin birbirine yakınlık derecesine göre, yani benzerliklerine göre gruplara ayrılmasıdır. Bu tahmin yönteminin temel amacı, sınıflandırılmamış verileri anlamlı bir şekilde gruplamaya yardımcı olmaktır. Kümeleme analizi, yalnızca makine öğrenmesinde değil, aynı zamanda veri madenciliği ve örüntü tanıma gibi birçok alanda kullanılan bir istatistiksel veri analiz tekniğidir (Kuru, 2023).

Birliklilik Kuralı, veritabanındaki değerlerin kümeleme yöntemlerinden bağımsız olarak, birbirleriyle olan bağlantılarını eş zamanlı olarak bulmaya çalışan bir veri madenciliği yöntemidir. Bu tekniğin temel amacı, değerler arasındaki ilişki potansiyelini ortaya çıkarmaktır (Malik, Al-Shehabi ve Dökeroglu, 2018).

Boyut Azaltma: Makine öğrenmesi yöntemlerinde, büyük miktardaki verilerden kullanılmayan özelliklerin tespit edilip çıkarılarak, verinin boyutunu azaltmaya yönelik bir yöntemdir. Bu süreç, daha doğru sonuçlar elde etmek için verinin boyutunu küçültmeyi amaçlar. Boyut azaltma, verinin doğru tahmin edilmesinde başarıyı artıran en önemli aşamalardan biridir. Bu aşamada, verinin tahmin edilmesinde sürecin başarımını, doğruluğunu ve etkinliğini artırmaya yardımcı olan alt kümeler oluşturularak daha net sonuçlar elde edilir. Bu öğrenme türünde, veri kümesindeki örneklerin çıktıları bilinmediğinden amaç sınıflandırma veya tanıma değildir. Denetimsiz öğrenme türlerine örnek olarak; video öneri sistemleri, arkadaş, grup ve sayfa öneri sistemleri ile ürün öneri sistemleri gibi birçok kullanım alanı gösterilebilir. Denetimsiz öğrenme türünde etiketlenmiş veri bulunmadığından, değerlendirme yapmak oldukça zordur (Çam, 2021).

Denetimli öğrenmeden farklı olarak, gözetmen yoktur ve doğru bir yanıt yoktur. Verilerdeki ilginç yapıyı keşfetmek ve sunmak, algoritmaların kendi haline bırakıldığı bir şeydir. Denetimsiz öğrenme algoritmaları, verileri kullanarak çok az özellik öğrenir. Yeni veriler tanıtıldığında, önceden öğrenilen özellikleri kullanır. Mahesh'e (2018: 383) göre esas olarak kümeleme ve özellik azaltma için kullanılır.

2.4.3. Yarı-denetimli öğrenme

Bu makine öğrenme türü hem denetimli öğrenmenin hem de denetimsiz öğrenmenin gücünden yararlanan bir teknik sağlar. Önceki iki tipte, ya tüm gözlemler için çıktı etiketleri verilir ya da hiç etiket verilmez. Bazı gözlemlerin etiketlerle sağlandığı ancak yüksek etiketleme maliyeti ve vasıflı insan uzmanlığı eksikliği nedeniyle gözlemlerin çoğunun etiketlenmemiş olduğu durumlar olabilir. Bu gibi durumlarda, yarı denetimli öğrenme, model oluşturma için en uygun olanıdır. Yarı denetimli öğrenme, sınıflandırma, regresyon ve tahmin gibi problemlerde de kullanılabilir (Alzubi, Nayyar ve Kumar, 2018:7).

2.4.4. Pekiştirmeli öğrenme

Bu makine öğrenmesi türünde denetimli öğrenme türünde olduğu gibi bir gözetim vardır. Ancak farklı olarak gözetmen girdileri tanımlarken, çıktıları makinenin üretmesini bekler. Gözetmen çıktıların doğruluğunu veya yanlışlığını gösteren sinyaller gönderir. Makine gelen sinyali dikkate alarak öğrenmeye devam eder. (Rizvanche, 2020). Pekiştirmeli

öğrenme, yazılım araçlarının kümülatif ödül kavramını en üst düzeye çıkarmak için bir ortamda nasıl hareket etmesi gerektiği ile ilgili bir makine öğrenimi alanıdır (Mahesh, 2018).

2.4.5. Derin öğrenme

Derin öğrenme türü, bir makinenin büyük miktarlarda ham verilerle beslenmesine ve de ilişkilerin keşfedilmesine izin vermektedir. Bu nedenle daha karmaşık verilerin işlenmesinde kullanılabilir. Derin öğrenme, birden çok katmanlı sinir ağlarına dayanır. Derin öğrenme denetimli veya denetimsiz olabilir. Derin öğrenme, bilgisayar işlem gücünün artması ile makine öğrenimindeki son zamanlarda temel gelişmelerin alanlarından olmuştur (Panch, Szolovits ve Atun, 2018). Derin öğrenme, YSA'ya dayalı bir makine öğrenimi konseptidir. Birçok uygulama için derin öğrenme modelleri, sığ makine öğrenimi modellerinden ve geleneksel veri analizi yaklaşımlarından daha iyi performans gösterir (Janiesch, Zschech ve Heinrich, 2021: 685).

3. LİTERATÜR ARAŞTIRMASI

Makine öğrenmesi konusu ve makine öğrenmesi temelli hesaplama teknikleri her geçen gün daha da ilgi çekmekte olsa da özellikle iş ölçümü ve standart süre tahmini konularında uzun yıllardır kullanılmakta olan geleneksel hesaplama yöntemlerine göre literatürde daha dar bir araştırma ve uygulama alanına sahiptir. Tez çalışması kapsamında gerçekleştirilen literatür araştırması sonucunda web of science veritabanında “standard time” ve “machine learning” anahtar kelimeleri ile “başlık, özet ve anahtar kelimeler” alanında yapılan literatür taraması (03.04.2024) sonucunda toplam 32 çalışmaya erişilmiş, 32 çalışmadan 24 adetinin araştırma makalesi sekiz adetinin ise konferans bildirisi olduğu görülmüştür. Yine web of science veritabanında “process management” ve “machine learning” anahtar kelimeleri ile “başlık, özet ve anahtar kelimeler” alanında yapılan literatür taraması (03.04.2024) sonucunda toplam 123 çalışmaya erişilmiş ve bunların 63’ünün araştırma makalesi, 56’sının konferans bildirisi, dördünün ise derleme makale olduğu görülmüştür. Aynı veritabanında “standard time” ve “artificial intelligence” anahtar kelimeleri ile “başlık, özet ve anahtar kelimeler” alanında yapılan literatür taraması (03.04.2024) sonucunda toplam altı çalışmaya erişilmiş, bunların beş adetinin araştırma makalesi ve birinin konferans bildirisi olduğu görülmüştür. Scopus veritabanında “başlık, özet ve anahtar kelimeler” alanları baz alınarak “standard time” ve “machine learning” kelimeleri tarandığında 52 adet çalışma listelenmektedir (21.06.2024). Bu çalışmaların yirmi yedi adeti makale, yirmi dört adeti konferans kâğıdı, bir adeti kitap bölümü kategorisindedir. Aynı zamanda Scopus veritabanında “process management” ve “machine learning” kelimeleri ile “anahtar kelime” alanında gerçekleştirilen taramada 107 adet kaynak tespit edilmiştir (21.06.2024). İlgili çalışmaların 39 adeti makale, 39 adeti bildiri, 29 adeti kitap formatındadır. Aynı veritabanında “standard time” ve “artificial intelligence” kelimeleri ile “başlık, özet ve anahtar kelimeler” alanında yapılan aramada 28 adet sonuç tespit edilmiş ilgili çalışmaların 13 adeti bildiri, sekiz adeti makale, yedi adeti kitap kategorisinde bulunmuştur. IEEE Xplore veritabanında “process management” ve “machine learning” kelimeleri ile “tüm meta veriler” alanında gerçekleştirilen taramada 142 adet kaynak tespit edilmiştir. Bu kaynakların 120 adeti bildiri, 12 adeti akademik dergi, yedi adeti IEEE rehber niteliğinde standart, üçü ise dergi ve kitap formatındadır.

Yürütülen detaylı literatür araştırmaları temelinde bugüne dek iş ölçümü ve standart süre hesabı konusunda gerçekleştirilmiş makale çalışmalarına örnek olarak Eraslan (2009)

çalışmasında bir kalıp şirketinin temizlik bölümündeki tüm ürün yelpazesi arasından benzer üretim süreçlerine sahip ürünleri seçerek bir ürün ailesi oluşturmuş, daha sonra bu ürünlerden toplanan veriler kullanılarak geri kalan ürünler için standart zaman tahmini yapılmıştır. Uygun eğitim sistemi için model, her farklı yapı için minimum hata seviyesine ulaşmak amacıyla farklı rastgele sayılarda başlayarak birkaç kez çalıştırılmıştır. İki yapılanmanın (6x4x2 ve 7x5x3) dört farklı algoritmayla (Conjugate Gradient algoritması, Broydon-Fletcher-Goldfarb-Shanno algoritması, Levenberg-Marquardt algoritması ve Bayesian regülasyonu) önceden ölçülmüş değerlere daha iyi yakınsama elde ettiği görülmüştür.

Dağdeviren, Eraslan ve Çelebi (2011) gerçekleştirdiği çalışmada YSA'ya dayalı basit ve dolaylı bir alternatif iş ölçüm yöntemi sunulmaktadır. Daha iyi bir performans elde etmek ve daha basit bir yapıyla denemeler yapıldıktan sonra, en uygun ağ konfigürasyonunun Conjugate Gradient algoritmasını kullanarak 5x5x2x1 olduğu görülmüştür.

Khalid S. ve Al-Saleh (2009) yaptığı araştırmada; araç muayenesinde iş ve çalışma sürecini iyileştirmek için basit yöntemlerin nasıl kullanılabileceğini belirlemiştir. Çalışmada, akış süreç şemaları kullanılarak kullanılan mevcut yöntemler ve her bir bileşenin ne kadar zaman aldığı belirlenmiştir. Süreçte basit değişiklikler yapılarak, akışı iyileştirilmiştir. Ayrıca ilave bir denetçinin maliyet ve faydaları da hesaplanmış ve değişiklik yapılmasıyla verimin önemli ölçüde artırılabilmesi öngörülmüştür. Önerilen basit değişikliklerin birlikte uygulanması halinde, sabit maliyetlerde hiç artış olmadan ya da çok az artışla, araç muayenesi veriminin %174,8 oranında artması öngörülmüştür.

Standart sürenin hesabında makine öğrenmesi tekniklerinin kullanıldığı yüksek lisans ve doktora tez çalışmalarına örnek olarak, Altın (2011) hazırladığı yüksek lisans tezinde benzer süreçlerde üretilen ürünler için yapay zekâ ile zaman tahmini yapmıştır. Çalışmada zaman etüdü ile veri toplayan bir firmada standart zamanı çeşitli faktörler nedeniyle ölçülemeyen diğer ürün grupları için standart zaman tahmini yapan alternatif bir iş ölçümü metodu geliştirilmiştir. Problem çözümünde geri beslemeli YSA kullanılmıştır ve kullanıcının kendi modelini tasarlayabileceği bir arayüz geliştirilmiştir. Bu yazılım kullanıcıya sonuçları detaylı bir şekilde vermektedir. Çalışmada önerilen hesaplama modeli ve karar destek sistemi sonuçları kaydetme ve grafiklerle göstermeye olanak sağlamaktadır.

Dağdeviren, Eraslan ve Çelebi (2011) yayımladığı çalışmada; Standart zamanın belirlenmesindeki eksik ve zorluklara dikkat çekmiş (Karşılaştırma ve tahmin, standart veri ve formülasyon, önceden tanımlanmış hareket-zaman sistemleri gibi dolaylı yöntemler), uygulamada daha basit ve ucuz olan YSA'ya dayalı alternatif bir dolaylı iş ölçüm yöntemi sunmuşlardır. Önerilen yöntemin uygulanması için, bir üretim şirketinde üretilen tüm ürün ailesi arasından benzer üretim süreçlerine sahip ürünler seçilmiştir. Örneklenen ürünlerin daha önce ölçülmüş olan standart zamanları kullanılmakta ve geriye kalan birkaç ürün ve yarı ürünlerin standart zamanları önerilen yöntem ile tahmin edilmiştir. Model sonuçları, önerilen yöntemin benzer ürünler üreten firmalarda doğru bir şekilde uygulanabileceğini göstermiştir.

Yusoff, Jaffar, Abbas ve Saad'ın (2012) yayımladığı makalede iş ölçüm çalışmasını, özellikle de araba koltuğu enjeksiyon hattındaki gerçek çalışma süresini ölçmek için sunmuştur. Bu yaklaşım sayesinde, zaman etüdü tekniğinin gerçek çalışma süresinin ölçülmesinde etkili bir çözüm olduğu görülmüştür.

Zhong, Huang ve Dai'nin (2013) gerçekleştirdiği çalışmada Radyo frekansı ile tanımlama RFID özellikli atölye üretim verilerinden standart operasyon sürelerinin tahmin edilmesi için dört adımlı bir veri madenciliği modeli önerilmiştir. Tahmini standart operasyon sürelerinin kullanımı, üretim planlarının ve programlarının sorunsuz bir şekilde yürütülmesi için doğruluğunu ve istikrarını artırır. Bu veri madenciliği modeli, RFID veri setlerini daha iyi atölye yönetimi için değerli kurumsal varlıklara dönüştürür. Veri madenciliği modeli kullanılarak yapılan duyarlılık analizi, işgücü becerileri ve yorgunluk ile ilgili olarak standart operasyon sürelerinin nicel özelliklerini ortaya koymuştur. Bunlar, planlama ve çizelgelemede tahmini standart operasyon sürelerinin kullanımına ince ayar yapmak için kullanılabilir. Bu makalenin birkaç önemli katkısı bulunmaktadır. İlk olarak, RFID destekli devasa üretim verilerinden paha biçilmez bilgilerin çıkarılması için bir veri madenciliği modeli önerilmektedir. İkinci olarak, standart operasyon sürelerinin ve bunların temel etki faktörleri incelenerek daha kesin ve gerçekçi tahminler elde edilebilmektedir. Bu da nihayetinde plan ve programların kalitesini artırır. Üçüncü olarak, farklı operatörler için öğrenme eğrileri başlangıçtaki zorlukları ve değişim oranını gösterir. Bu, terfi stratejileri gibi yönetim politikalarını desteklemek için önemlidir.

Puvasasvaran, Mei ve Alagendran (2013) yılında gerçekleştirdikleri çalışmada; Genel Ekipman Verimliliğini artırmak için zaman etüdü tekniğini uygulamışlar ve otoklav verimliliğini artırmışlardır.

Seifermann, Böllhoff, Metternich ve Bellaghnach (2014) gerçekleştirdikleri çalışmanın sonuçlarıyla, bir Hücrel Üretim hattının düşük maliyetle otomatikleştirilmesine yönelik bilimsel olarak sağlam bir yöntemin temelleri atılmıştır. TU Darmstadt'taki Süreç Öğrenme Fabrikası Hücrel Üretim referans hattında iş ölçümü için çeşitli yöntemlerden yararlanılarak, Hücrel Üretim için otomatikleştirilme potansiyeli gösteren farklı manuel görevler belirlenmiş ve içerilen faydaların ölçülmesine olanak sağlanmıştır. MTM-1 kullanarak iş ölçümü yapmanın, referans hattında gerçeklik, detay, etki ve çabanın değiş tokuşu göz önüne alındığında en iyi sonuçları verdiği kanıtlanmıştır. Sunulan yaklaşımın uygulanabilir olduğu kanıtlanmıştır ve diğer Hücrel Üretim hatlarında daha fazla uygulama ve doğrulama için bir temel teşkil etmektedir.

Özcan, Kumru ve Fıglalı (2018) operasyon süresini YSA ile tahmin etmeye çalışmışlardır. En iyi yapı belirlenmesi için gizli katmanda sırasıyla bir, üç ve beş nöron bulunan yapılar test edilmiştir. En iyi sonucu üç nöronlu yapı vermiştir.

Sütçü (2018)'ye ait bir başka çalışmada YSA kullanılarak siparişe göre fason üretim yapan bir firmanın kaynaklı imalat operasyon süreleri tahmin edilmiştir. Nöron sayısını deneme yanılma yolu ile değiştirerek ortalama kare hata oranını en düşük, korelasyon oranını en yüksek bulunmasıyla belirlenmektedir.

Jeong, Woo ve Park (2020) çalışmalarında gemi inşa endüstrisi için üretim verilerindeki zaman ögesi için bir ana veri sistemi kullanılarak süreç teslim süresi için yeni bir yöntem önermek üzere makine öğrenme teknolojisi kullanılarak imalat, gemi bloğu montajı, makara imalatı ve boyama için teslim süreleri tahmin edilmiştir. Veri ön işleme, açık kaynak programlama dilleri olan R ve Python kullanılarak çeşitli şekillerde gerçekleştirilmiş olup, korelasyon analizi ve değişkenlerin analizi yoluyla süreç değişkenleri, teslim süresi ile ilişkileri dikkate alınarak seçilmiştir. Tedarik süresi tahmin modellerini oluşturmak için çeşitli makine öğrenimi, derin öğrenme ve topluluk öğrenme algoritmaları uygulanmıştır. Ayrıca, önerilen makine öğrenimi metodolojisinin standart çalışma saati tahminine uygulanabilirliği, tahmin modellerinin Ortalama Mutlak Hata (Mean Absolute Error - OMH)

ve Ortalama Karekök Logaritmik Hata (Root Mean Squared Log Error) gibi değerlendirme kriterleri kullanılarak değerlendirilmesiyle doğrulanmıştır.

Kutschenreiter-Praszkiewicz (2020) çalışmalarında üretim sürecinde standart zamanların belirlenmesini tartışmıştır. Çok Katmanlı Algılayıcılar (Multi Layer Perception - MLP) sinir ağlarını kullanan bir hesaplama modeli önerilmiştir. Çalışmanın amacı montaj planlamasını kolaylaştıran standart zamanları belirleme yöntemlerini göstermektir. Makalenin özel hedefleri, montaj görevleri özelliklerinde ve geçişlerinde faydalı ortak parametrelerin bulunmasının yanı sıra montaj tanımında faydalı değer aralıklarının bulunması olarak belirtilmiştir. Ürün yaşam döngüsünün kısaltılması, yeni ürün geliştirme ve ürünün kişiselleştirilmesi, modüler, yeniden yapılandırılabilir bir montaj hattının geliştirilmesini beraberinde getirir. Esnek montaj hatlarının geliştirilmesi, tipik montaj görevleri ve araçlarıyla ilgili standartları gerektirir. Montaj hatlarının yeniden yapılandırılması ve dengelenmesi, zaman standartlarıyla ilgili bir bilgi tabanı gerektirir. Bu makale, montaj ve sökme süreçlerini kullanan ürün montajını ve değişimini planlamak için tipik görevlere, araçlara ve standart zamanlarına ilişkin örnekler sunmaktadır.

Yamashiro ve Nonaka (2021) yaptığı çalışmada, gerçek fabrika verilerinde işlem süreleri karmaşık bir şekilde dağıtıldığında işlem süresini tahmin etmek ve makineleri çizelgelemek için bir sistem önermiştir. Sistemin avantajları, işlem süreleri bilinmeyen karmaşık dağılımlı işler için çizelgeleme optimizasyonunun mümkün olması ve işlem bilgilerinin öğrenme sürecinde kullanılan makine öğrenme modeli tarafından analiz edilebilmesidir. Önerilen yöntemi doğrulamak için gerçek fabrika verilerini kullanarak işlem süreleri tahmin edildi ve çizelgeleme optimizasyonunu gerçekleştirmek için tahmin edilen işlem sürelerini kullanarak bir paralel makine çizelgeleme problemi çözüldü. İşlem süresini tahmin etmek için; Hafif Gradyan Artırma Makinesi (LightGBM), Gaus Süreci, Ridge Regresyon, YSA makine öğrenme modelleri kullanıldı. LightGBM yaklaşık 0,22 OMH değeri ile en iyi doğruluğa sahipti. Tahmin edilen LightGBM işlem süresini kullanan paralel makine çizelgeleme optimizasyonu, işlem süresini yaklaşık %30 oranında azaltmıştır. İşlem süresi için normal bir dağılım varsayan önceki çalışmaların aksine, bu çalışmada kullanılan fabrika işlem süresi normal bir dağılım izlememiştir. Bu durum, işlem süresinin bir makine öğrenimi modeli kullanılarak tahmin edilmesi gerektiğini göstermiştir.

Rodrigues ve diğerleri (2022) çalışmalarında plastik enjeksiyon kalıpları üreten bir firmada standart enjeksiyon kalıp parçaları için işleme süresi tahmin edilmiştir. Dokuz farklı model geliştirilip regresyon ve hata değerlerine bakılmıştır.

Mohsen, Mohamed ve Al-Hussein (2022) gerçekleştirdikleri çalışmada; panel imalat atölyesinde döngü süresinin doğru tahminine odaklanmışlar, gerçek zamanlı atölye kullanım verilerini kullanarak üretim süresini tahmin etmek için üretim yöneticilerinin doğru kararlar almasına yardımcı olmuşlar, siparişlerin dinamik çizelgelenmesini sağlamışlardır.

Süreç yönetiminde standart zamanın makine öğrenmesi teknikleri aracılığıyla hesaplanmasını konu edinen konferans bildirilerine örnek olarak Scholz, Howlett ve Setchi (2021) çalışmalarında el işi ayakkabı sektörü için rekabet gücünü artırmak amacıyla bir üretim sistemindeki arızaların tahmin edilmesini ve önleyici bakım faaliyetlerinin gerçekleştirilmesini sağlayacak bir model önermiştir. Üretimden numuneler alınmış ve yedi faaliyet oluşturulmuştur (kesme, dikim, ön imalat, son hazırlık, yapıştırma, montaj ve bitirme). İncelenen firma 274,53 dakikalık standart süre ile günde 90 çift parti üretmektedir. Her aşamanın standart zamanını referans alarak sürecin olası hatalarını tahmin etmek için bir DVM modeli geliştirilmiştir. Son olarak, sonuçlar DVM uygulanarak üretim sürecini optimize etmek için hataların tahmin edilmesine olanak tanımıştır.

Thapaliya, Valilai ve Wicaksono (2024) makale çalışmalarında karar ağaçları, rastgele orman, destek vektör regresyonu, aşırı gradyan artırma ve YSA olmak üzere beş makine öğrenimi regresyon modeli kullanarak Bilgisayarlı sayısal denetim (Computer Numeric Control - CNC) freze makinelerinin güç tüketimi ve işlem süresi tahminini gerçekleştirmiştir. Beş makine öğrenmesi algoritmasının hesaplama sonuçlarına göre rastgele orman regresyonunun ortalama güç tüketimini ve işlem süresini tahmin etmek konusunda en uygun model olduğu görülmüştür.

4. MATERYAL VE METODOLOJİ

Bu bölümde, çalışmada kullanılacak olan materyaller ve makine öğrenmesi yöntemleri incelenecek ve değerlendirilecektir.

4.1. Regresyon Analizi

Regresyon analizi, sebep-sonuç ilişkisi olan iki veya daha fazla değişken arasındaki ilişkiyi inceleyen ve bu ilişkiyi modellemek amacıyla kullanılan istatistiksel bir analiz yöntemidir. Bu analiz yöntemi, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi belirlemek ve bu ilişkinin gücünü ölçmek için kullanılır. Regresyon analizi, çeşitli alanlarda, özellikle ekonomi, mühendislik, tıp ve sosyal bilimlerde yaygın olarak uygulanmaktadır (Vural, 2007). Regresyon analizinde, incelenen değişkenler sürekli veya kesikli olabilir ve bu veri yapısına göre farklı regresyon modelleri uygulanabilir (Özarıcı, 1996).

Regresyon analizi genellikle doğrusal regresyon ve doğrusal olmayan regresyon modelleri olmak üzere iki başlık altında incelenir (Atasoy, 2023).

4.1.1. Doğrusal regresyon analizi

Bu model, bağımlı değişkenin tahminini doğrusal bir fonksiyon aracılığıyla gerçekleştirir. İlişki, bağımsız değişkenlerin birinci dereceden terimleri ile tanımlanır. Doğrusal regresyon analizi, bağımlı değişkenin bağımsız değişkenler tarafından ne ölçüde açıklandığını ve her bir bağımsız değişkenin bağımlı değişken üzerindeki etkisini belirlemek için kullanılır (Atasoy, 2023). Birçok istatistik çalışmasında olduğu üzere, regresyon analizinde de tüm veri kümesi yerine, bu veri kümesinden seçilen örnek veriler kullanılarak analiz yapılır. Elde edilen sonuçlar daha sonra tüm veri kümesindeki ilişkinin tahmin edilmesinde kullanılır. Veri kümesi ve örnek verilerle yapılan istatistik araştırmalarda kullanılan tekniklerin uygulanmasında bir fark yoktur. Ancak, teknikler uygulandıktan sonra örnekleme teorisinden faydalanılarak tüm veri kümesi parametrelerinin testleri ve tahminleri gerçekleştirilir. (Orhunbilge, 1996: 11).

Y bağımlı değişken ve X bağımsız değişken olmak üzere bu iki değişken arasındaki doğrusal regresyon modeli Eş. 4.1.'deki gibi belirtilir.

$$Y_i = \alpha + \beta X_i + \varepsilon_i \quad (4.1)$$

Burada α ve β modelin parametreleri, ε_i ise şansa bağlı hata değerini göstermektedir. Bu model örnek veriler için,

$$Y_i = a + bX_i + e_i \quad (4.2)$$

Eş. 4.2.'de görüldüğü gibi ifade edilir. Burada a ve b sırasıyla α ve β parametrelerinin tahminleyicileri olan istatistiklerdir (Yıldız ve Bircan, 1999: 218).

4.1.2. Doğrusal olmayan regresyon analizi

Bu modelde, ilişki doğrusal bir fonksiyonla ifade edilemez ve bağımlı değişkenin tahmini için daha karmaşık fonksiyonlar kullanılır. Bu tür regresyon modelleri, eğimlerin veya etkilerin doğrusal olmadığı durumları analiz etmek için uygundur (Atasoy, 2023). Doğrusal olmayan regresyon modelleri, doğrusal olmayan ilişkileri modellemek için çeşitli matematiksel fonksiyonlar kullanır. Bu fonksiyonlar arasında polinomlar, üstel fonksiyonlar, logaritmik fonksiyonlar, trigonometrik fonksiyonlar ve sigmoid fonksiyonlar gibi çeşitli matematiksel dönüşümler yer alır. Bu dönüşümler, bağımlı değişkenin bağımsız değişkenlerle olan ilişkisini daha doğru bir şekilde modellemek amacıyla kullanılır. (Bates ve Donald, 1988: 32-66). Aşağıda sık kullanılan bazı modellere yer verilmiştir.

Polinom regresyon

Polinom regresyon, yalnızca bağımsız bir X değişkeni ile çoklu regresyonun özel bir türüdür. Tek değişkenli polinom regresyon modeli aşağıdaki formülle ifade edilir. Bu formülde k , polinomun derecesini belirtir ve modelin sırasını ifade eder. Polinomun derecesi, modelin bağımsız değişkenle bağımlı değişken arasındaki ilişkiyi ne kadar karmaşık bir şekilde temsil edeceğini belirler. Yüksek dereceli polinomlar, daha karmaşık ilişkileri modellemek

için kullanılabilir. Etkin şekilde bu, $X_1 = X$, $X_2 = X^2$, $X_3 = X^3$ değişkenleri ile çoklu bir modele sahip olmakla aynıdır ve formülü Eş. 4.3.'te verilmiştir (Ostertagová, 2013).

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \dots + \beta_k x_i^k + \varepsilon_i, \text{ for } i = 1, 2, \dots, n \quad (4.3)$$

Lojistik regresyon

Lojistik regresyon, bir bağımlı değişkenin iki kategorik sınıf arasındaki olasılığını tahmin etmek amacıyla kullanılan bir yöntemdir. Bu yöntem, doğrusal olmayan bir sınıflandırma problemini çözmek için sigmoid fonksiyonunu kullanır. Sigmoid fonksiyonu, tahmin edilen olasılıkların 0 ile 1 arasında kalmasını sağlar ve böylece iki sınıf arasında ayrım yapılabilir (Atasoy, 2001).

Kübik spline regresyonu

Kübik spline regresyonu, bağımlı değişken ile bağımsız değişken arasındaki ilişkiyi düz eğrilerle modelleyen bir yöntemdir. Bu teknik, veri setini küçük segmentlere ayırarak her segmenti kübik polinomlarla temsil eder. Böylece, veriler daha esnek ve doğru bir şekilde modellenir. Segmentler arasındaki geçişler, pürüzsüz ve sürekli eğrilerle sağlanarak bağımlı ve bağımsız değişkenler arasındaki ilişkiyi daha karmaşık ve doğru bir şekilde ifade eder. (Şahin ve Efe, 2010).

Ridge ve lasso regresyon

Ridge regresyon ve Lasso regresyon, regresyon analizinde kullanılan iki yaygın düzenleme (regularization) yöntemidir. Her iki yöntem de modelin aşırı uyum (overfitting) sorununu çözmek ve modelin genelleme yeteneğini artırmak amacıyla kullanılır. Temel farklılıkları, kullanılan düzenleme terimleridir (Atasoy, 2023).

Ridge regresyon, bağımlı bir değişken ile bazı açıklayıcı değişkenler arasındaki doğrusal ilişkiyi modellemek için kullanılan bir istatistiksel yöntemdir. Öneri sistemleri gibi birçok öğrenme algoritmasında önemli bir yapı taşıdır ve kullanıcı profillerini geri bildirim yoluyla öğrenir, böylece kullanıcının belirgin bir soru yapmasına gerek kalmadan ilgi alanına giren öneriler sunar. Bu regresyon tekniği, toplanan verileri analiz ederek ve bunları kompakt bir

şekilde özetleyerek, bir ögenin kullanıcıyla ne kadar ilgili olduğunu belirler (Chen, Rezapour ve Tzeng, 2018)

Ridge regresyonun avantajları şunlardır; bağımsız değişkenler arasında yüksek korelasyon olduğunda bile etkili sonuçlar verir. Bu, çoklu doğrusal bağıntı (multicollinearity) durumlarında modelin performansını artırır. Katsayıları sıfıra yaklaştırarak gereksiz değişkenleri tamamen elemek yerine, onların etkisini azaltır. Bu sayede daha genelleyici ve esnek modeller oluşturur. Modeldeki katsayıların kararlılığını artırır. Bu, modelin eğitim verisine aşırı uyum sağlamasını engeller ve modelin farklı veri setlerinde daha tutarlı performans göstermesini sağlar (Atasoy, 2023).

Regresyon modelleri, aşırı risk öngörme eğilimi göstererek özellikle düşük performans sergileyebilir. Bu sorunu çözmek için düzenleme yapan Lasso regresyon uygun bir tercih olabilir. Lasso regresyon, öznel seçimini otomatik olarak yapar ve çıktı olarak daha sade bir model sunar. Amacı, tahmin hatasını en aza indiren modeli oluşturan değişkenleri ve karşılık gelen regresyon katsayılarını belirlemektir. Lasso regresyonun bazı ayarlarda standart yöntemlerden daha iyi performans gösterdiği gözlemlenmiştir. Tek tek değişkenlerin katkısının tahmini ve yorumunun doğruluğuna değil, en iyi kombine tahmine odaklandığı için, regresyon katsayılarının bağımsız risk faktörleri açısından güvenilir bir şekilde yorumlanması zordur. Bu yöntem, modelin aşırı uyumunu engelleyerek genelleme yeteneğini artırır ve böylece daha güvenilir tahminler elde edilmesini sağlar (Ranstan ve Cook, 2018).


Lasso regresyonun avantajları şunlardır; Lasso regresyon, modelde önemli olmayan değişkenleri tamamen sıfırlayarak onları modelden çıkarabilir. Bu sayede, sadece önemli olan değişkenler modelde kalır. Ridge regresyona kıyasla, Lasso regresyon daha sade ve yorumlanabilir bir model sunabilir. Gereksiz değişkenleri sıfırladığı için model daha düzenli hale gelir. Modeldeki gereksiz değişkenlerin etkisini tamamen ortadan kaldırarak modelin doğruluğunu ve genelleme yeteneğini artırır. Bu avantajlar, Lasso regresyonun değişken seçimi ve model basitleştirme konusunda güçlü bir araç olmasını sağlar (Atasoy, 2023).

4.2. Yapay Sinir Ağları

YSA, bilgisayar dünyasında insan beyninin ve sinir sisteminin davranışlarını taklit etme esası üzerine kurulmuş yeni bir bilgi işleme yaklaşımıdır. İnsan beyninin taklit edilmesiyle ortaya çıkan bu yapılar, nanosaniyeler içerisinde işlemleri yerine getirebilme kapasitesine sahip olmalarına rağmen, insan beyninin işlevsel hızına ulaşamamıştır.

Beyin, merkezi sinir sistemindeki en önemli parça olup, işleyişi hücreler arasındaki iletişim yoluyla gerçekleşmektedir. Bir insan beyninde, sinir (nöron) ve glial (glue) şeklinde iki çeşit hücre bulunmaktadır. Bu iki çeşit hücreden, beyinde toplamda yaklaşık olarak 1 trilyon adet bulunmaktadır. Bu hücrelerden de toplamda yaklaşık 100 milyar tanesi sinir hücresi olan nöronlardır. Nöronlar beyin fonksiyonları ve sinir sistemi için ana öğelerdir (Ersoy ve Karal, 2012: 188).

Biyolojik sinir hücreleri olan nöronlar, dört temel bölümden oluşmaktadır. Bunlar; sinapslar, aksonlar, dendritler ve somalardır. Hücre gövdesini ifade eden somaların görevi hücrenin faaliyetlerini yürütmek ve denetlemektir. Hücre gövdesinden dendrit ve akson olmak üzere iki çeşit uzantı çıkmaktadır. Dendritler, bilgiyi diğer hücrelerden sinapslar aracılığıyla alan ve hücre girişi olarak görev yapan yapılardır.




Şekil 4.1. Biyolojik sinir hücresi (Atalay, 2015)

Şekil 4.1.'de görüldüğü üzere hücre gövdesinden dışarı uzanan ağaç dalları biçimindedirler. Diğer nöronlardan bilgiyi iletim hatları olarak kullanılan uzun fiberlerden oluşmuş aksonlar boyunca alır ve hücre gövdesine taşırlar. Aksonlar, hücre içerisinde bilgi işlendikten sonra gövdedeki bilgiyi diğer nöronların dentritlerine taşıyan yapılardır. Akson yüzeyleri düzdür ve genellikle bir sinir hücresinde bir akson vardır. Aksonlar sinir hücre gövdesinden uzakta dallanırlar. Sinapslar ise sinir hücreleri arasındaki bağlantıları ifade etmektedir. Sinapslar fiziksel bağlantılar değildir. Bunlar bir hücreden diğerine elektrik sinyallerinin geçmesini sağlayan boşluklardır (Atalay, 2015).


Yapay sinir hücresi, YSA'nın temelini oluşturan yapılardır. Bu yapılar biyolojik sinir hücrelerinin bilgisayar ortamında programlanmasıyla oluşturulan yapılardır. Yapay sinir hücresi yapı ve işleyiş nitelikleri açısından biyolojik sinir hücrelerine oldukça benzerdir. Yapay sinir hücresinin temel amacı, giriş verilerini işleyerek çıktı üretmektir. Bu işlem, biyolojik sinir hücrelerinin dendritlerinden aldığı sinyalleri işleyip akson aracılığıyla çıktı üretmeleriyle benzerlik gösterir.

Şekil 4.2.'de yapay sinir hücresi ve biyolojik sinir hücresinin karşılaştırılmalarına ilişkin görseller verilmiştir.



Şekil 4.2. (A) Biyolojik sinir hücresi (B) Yapay sinir hücresi (C) Biyolojik sinaps (D) YSA'daki sinapslar (Konuk, 2023)

Yapay sinir hücreleri biyolojik sinir hücreleri gibi belirli temel bileşenlerden oluşmaktadırlar. Yapay sinir hücreleri mühendislik biliminde proses elemanları olarak adlandırılmakta ve beş temel bileşenden oluşmaktadır. Bu bileşenler: girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu, çıktılarıdır (Öztemel, 2006:16).



Şekil 4.3. Yapay sinir hücresinin bileşenleri (Keskenler ve Keskenler, 2017:8)

Yapay sinir hücresi ve biyolojik sinir hücresi yapı olarak birbirine benzer olması sebebiyle bu hücrelere ait elemanların görevleri de birbirine benzerdir. Çizelge 4.1.'de yapay sinir hücrelerinden meydana gelen YSA'nın biyolojik sinir sisteminde karşılıkları verilmiştir.

Çizelge 4.1. YSA elemanlarının biyolojik sinir sistemindeki karşılıkları (Konuk, 2023)

YSA Elemanları	Biyolojik Sinir Sistemi Elemanları
İşlemci Eleman	Nöron
Toplama Fonksiyonu	Dendrit
Aktivasyon Fonksiyonu	Hücre Gövdesi
YSA Çıktısı	Akson
Ağırlıklar	Sinapslar

YSA, biyolojik sinir ağlarının karakteristiklerine benzer şekilde çalışan bir bilgi işleme sistemidir (Öztemel, 2006: 29). Bir başka tanıma göre ise bir sinir ağı, basit işlem birimlerinden oluşan, deneyimsel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasını sağlayan yoğun bir şekilde paralel dağıtılmış bir işlemcidir YSA beyne iki yönüyle benzetilmektedir. Birincisi, bilgiyi öğrenerek elde eder. İkincisi ise nöronlar (sinir hücresi) arası ağırlıklar; bilgiyi saklamak için kullanılır (Haykin, 2009: 2).

YSA, insan beyninin sinir sistemiyle benzer bir şekilde çalışan ve biyolojik sinir ağları model alınarak geliştirilmiş gözetimli öğrenme algoritmalarından biridir. Bu algoritmanın amacı, insana özgü karar verme, yorum yapma, ilişki kurma, yeni bilgileri keşfetme ve üretme gibi beynin öğrenme yoluyla kazandığı yetenekleri, otomatik olarak ve yardım almadan gerçekleştirmektir. YSA, sinir hücrelerinin farklı birleşimlerinden oluşur ve genellikle katmanlar halinde düzenlenir. Ayrıca, elektronik devreler şeklinde donanım olarak da tasarlanabilir (Çam, 2021: 32). YSA, performansını değerlendirmek için çeşitli metrikler kullanır. Sınıflandırma problemleri için doğruluk, hassasiyet, geri çağırma ve F1 skoru gibi metrikler yaygın olarak kullanılır (Goodfellow, Bengio, Courville ve Bengio, 2016)

YSA, gerçekleşmiş olaylardan deneyim kazanarak öğrenmektedir. Bu nedenle matematiksel sistemlerdeki gibi bilgi toplama problemi yoktur, örneklerden yararlanır. Kullandığı örnekler sistemin öğrenmesi istenen durumları doğru bir şekilde temsil etmelidir. Ağın performansını problemin temsil şeklinin yanında yapısı, ağın öğrenme sistemi ve kuralları etkiler. Ağın içerisindeki işlemci elemanları sürekli iletişim halindedir. YSA'yı oluşturan katmanlar; girdi katmanı, gizli katman ve çıktı katmanıdır (Rizvanche, 2020: 18):


Girdi Katmanı: En az bir girdi verisi içerir. Bu katmanda verilere bir işlem uygulanmaz.

Gizli Katmanlar: Girdi katmanından gelen veriler belli başlı işlemlere tabii tutulur. Gizli katmanın yapısı YSA'nın yapısına bağlıdır, değişkenlik gösterebilir. Bir katman ya da birden çok katman içerebilir.

Çıktı Katmanı: En az bir çıktı içerir. Çıktıyı ağın içerdiği fonksiyon belirler. Burada çeşitli işlemler gerçekleştirilir ve çıktılar dış dünyaya aktarılır.

YSA birden çok basit işlemci elemanının girdilerden çıktılar ürettiği bir kara kutu olarak tanımlanmaktadır. Bahsi geçen basit yapıli hücreler hiyerarşik yapılidir (Rizvanche, 2020: 18).

YSA'yı oluşturan en temel yapı yapay sinir hücreleridir. Yapay sinir hücreleri aralarında bağlantılar kurarak YSA oluştururlar. Bkz. Şekil 4.4.'te yapay sinir hücresinin yapısı görölmektedir.



Şekil 4.4. Yapay sinir hücresinin yapısı (Çayıroğlu, 2019)

Yapay sinir hücreleri diğeri adıyla yapay nöronlar beş bileşenden oluşmaktadırlar. Bu bileşenler:

- Girdiler
- Ağırlıklar
- Toplama Fonksiyonu
- Aktivasyon Fonksiyonu
- Çıktılardır.

Girdiler, yapay nöronların çekirdeklerine gönderilen bilgilerdir. Bu durum, bilgilerin biyolojik sinir hücrelerinde dendritlerden hücre çekirdeğine gönderilmesine benzemektedir. Bilgiler ağ dışından gelebileceği gibi diğeri yapay nöron dan da gelebilmektedir (Öztemel, 2006: 52, 53).

Yapay nöronlara gönderilen bilgiler girdiler üzerinden nöron çekirdeğine ulaşmadan önce gönderildikleri bağlantıların ağırlığıyla çarpılarak nöron çekirdeğine iletilirler. Girdilerden


üretilcek olan çıktılarının üzerindeki etkiyi ayarlayabilmek amacıyla bu işlem yapılır. Ağırlıklar pozitif, negatif veya sıfır değerlerini alabilir (Çayiroğlu, 2019).

Toplama fonksiyonu yapay nöronlara ağırlıklarla çarpılarak gönderilen girdileri toplayarak nöron çekirdeğine giden net girdiyi hesaplayan fonksiyonu ifade etmektedir. Toplama fonksiyonları farklı çeşitlerde olup bu fonksiyonların belirlenmesi üzerine geliştirilmiş herhangi bir yöntem bulunmamaktadır. Diğer bir ifadeyle toplama fonksiyonları deneme yanılma yoluyla belirlenmektedir. Çizelge 4.2.'de bazı toplama fonksiyonları ve açıklamaları sunulmaktadır (Çayiroğlu, 2019). X , ilgili nöron için girdileri, W ise ilgili nöronun kendinden bir önceki nöronlarla yaptığı bağlantılardan gelen ağırlık değerlerini belirtmektedir (Konuk, 2023).

Çizelge 4.2. Bazı toplama fonksiyonları (Çayiroğlu, 2019)

Toplam $Net = \sum_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle toplanarak Net Girdi hesaplanır.
Çarpım $Net = \prod_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbiriyle çarpılarak Net Girdi hesaplanır.
Maksimum $Net = Max (X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en büyüğü Net Girdi olarak kabul edilir.
Minimum $Net = Min (X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en küçüğü Net Girdi olarak kabul edilir.
Çoğunluk $Net = \sum_{i=1}^N Sgn(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra pozitif ile negatif olanların sayısı bulunur. Büyük olan sayı hücrenin Net Girdisi olarak kabul edilir.
Kümülatif Toplam $Net = Net(eski) + \sum_{i=1}^N X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha önce hücreye gelen bilgilere yeni hesaplanan girdi değerleri eklenerek hücrenin net girdisi hesaplanır.

Aktivasyon fonksiyonları, yapay nöronlarda hesaplanan net girdileri işleyerek hücrenin çıktısının belirlenmesini sağlayan fonksiyonlardır. Toplama fonksiyonunun belirlenmesinde yaşanan problem aktivasyon problemleri için de söz konusudur. Farklı çeşitlerde aktivasyon fonksiyonları mevcut olup bunlardan hangisinin kullanılacağı kararı ağı tasarlayan kullanıcıya bırakılmıştır. Şekil 4.5.'te YSA'da yaygın olarak kullanılan aktivasyon fonksiyonlarının grafiği verilmiştir (Konuk, 2023).




Şekil 4.5. YSA'da kullanılan yaygın aktivasyon fonksiyonlarının grafikleri (Konuk, 2023)

4.2.1. YSA'nın yapılarına göre sınıflandırılması

YSA yapılarına göre ileri beslemeli YSA ve geri beslemeli YSA olmak üzere ikiye ayrılmaktadır. Bu ikili yapıyı birbirinden ayıran en büyük fark hücreler arasındaki bağlantılarda bir döngünün varlığıdır.

İleri beslemeli YSA

İleri beslemeli bir sinir ağı en basit YSA tipi olarak kabul edilmektedir. Bu tip ağlarda bilgi, giriş katmanından ara katman boyunca çıkış katmanına doğru yalnızca bir yönde hareket etmektedir. İleri beslemeli bir sinir ağında döngü hücreler arasındaki bağlantılarda bir döngü yoktur (Gültepe, 2019: 8).




Şekil 4.6. İleri beslemeli YSA (Krenker, Bester ve Kos, 2011)

İleri beslemeli YSA’da, ağın toplam davranışındaki doğrusal olmayışı, çıktı ve girdi katmanları arasında kalan ara katmanların hücrelerinin doğrusal sayılmayan etkilerini belirler. Giriş ve çıkış katmanındaki sinir hücreleri sayıları ele alınan probleme göre belirlenir fakat gizli katmanlardaki sinir hücresi sayısını belirlemek için herhangi bir aritmetik yöntem yoktur. Bu sayı deneme yanılma yöntemi ile belirlenmelidir (Akteke, 2023).

Geri beslemeli YSA

Geri beslemeli bir sinir ağında bilgi yine giriş katmanından ara katman boyunca çıkış katmanına doğru ilerler ancak bu tip sinir ağında bilgiler kendinden önceki katmanlara da iletebilmektedir. Ara katmanların herhangi birinde üretilen çıktı bir önceki katmana veya aynı katmanda bulunan diğer hücrelere iletebilmektedir (Uçarsu, 2022).

Geri beslemeli YSA çift taraflı olduğu için açıkçası giriş ve çıkışlara doğru yönelme eyleminde olduğu için problemin çözülmesinde işlemi karışık duruma sokmaktadır. Geri besleme aracılığıyla YSA’da öğrenme yeteneği artar ve sonuçlar gerçek değerlere yaklaşır (Akteke, 2023).




Şekil 4.7. Geri beslemeli YSA (Krenker ve diğerleri, 2011)

4.3. Destek Vektör Makineleri

DVM, yapısal risk minimizasyonuna göre çalıştırılan bir sınıflama yöntemi olarak bilinir. Cortes ve Vapnik tarafından 1995 yılında problemlerin çözümü ve bilinmeyen bilirliliğinin artırılması amacıyla geliştirilmiştir. DVM'nin temelleri, istatistiksel öğrenme teorisine, diğer bir deyişle Vapnik-Chervonenkis teorisine dayandırılmaktadır (Ayhan ve Erdoğan, 2014: 175).

DVM algoritması iki veri sınıfını birbirinden ayıran bir hiper düzlem vardır. Bu düzlemin her iki tarafı da “marj” adı verilen kavramın etrafında döner (Osisanwo ve diğerleri, 2017).

Veri seti (iki sınıflı) doğrusal olarak ayrıldığında, doğrusal DVM tercih edilir, iki sınıflı olarak ayıramadığı durumlarda ise takip eden bölümlerde detayı verilen çok sınıflı destek vektör makineleri yöntemleri kullanılır. Şekil 4.8’de DVM’nin genel çalışma biçimi gösterilmiştir (Türkmen, 2021).



Şekil 4.8. DVM genel yapısı (Türkmen, 2021)

DVM ile ilgili ilk makale 1964 yılında yayınlanmış olmasına rağmen, yöntem 1990'lı yıllara kadar çok ciddiye alınmamıştır. Bunun sebebi, o yıllarda makine öğrenmesi topluluğu tarafından, DVM'nin güçlü teorisine rağmen, pratikte uygulanabilir bir yöntem olmadığına dair bir inancın bulunmasıdır. Yöntem, rakam tanıma, bilgisayarla görme ve metin sınıflandırma gibi görevlerde diğer yöntemlere göre daha iyi sonuçlar verdiği görüldükten sonra ciddiye alınmaya başlanmıştır (Huang, Kecman ve Kopriva, 2006: 12). DVM yönteminin temeli İstatistiksel Öğrenme Teorisi'ne dayandırılmıştır. İstatistiksel Öğrenme Teorisi, önceleri sadece verilen bir veri kümesine uyan fonksiyon tahmini probleminin teorik analizi için kullanılmıştır. Daha sonra, bu teoriye dayanan DVM yönteminin önerilmesiyle, teorik analizlerin yanı sıra yeni öğrenme algoritmalarının oluşturulmasında da kullanılabileceği görülmüştür (Vapnik, 1999: 988).

İstatistiksel Öğrenme Teorisi, makine öğrenmesinin matematiksel altyapısını oluşturmaya çalışır. Teori temelde “Genel olarak hangi öğrenme görevleri bilgisayarlar tarafından yerine getirilebilir?”, “Makine öğrenmesinin başarılı olabilmesi için hangi varsayımlar yapılmalıdır?”, “Bir öğrenme algoritmasının başarılı olabilmesi için hangi temel özelliklere ihtiyacı vardır?”, “Öğrenme algoritmasının sonuçları üzerinde hangi performans garantileri verilebilir?” gibi soruları cevaplamaya çalışır (Luxburg ve Schölkopf, 2011: 653).


4.3.1. Doğrusal DVM

Doğrusal DVM problemlerinin karmaşıklığı, kullanılan özelliklerin sayısına bağlı olarak değişir. DVM'nin karmaşıklık düzeyi ne olursa olsun, yani boyutsallık ve sınıflandırma

problemleri ne kadar karmaşık olursa olsun, kullanılan hiperdüzlemin düz olması ve eğri olmaması anlamında genellikle doğrusaldır (Pisner ve Schnyer, 2020).

Doğrusal olarak ayrılabilme durumu

DVM'nin bu durumu sadece doğrusal olarak ayrılabilen veriler için geçerlidir ve gerçek hayatta bu durumdaki problemlerle nadiren karşılaşılabilinmektedir. Doğrusal olarak ayrılabilen problemler DVM'nin temelini oluşturur (Ankaralı, Aydın ve Saraçlı, 2013).



Şekil 4.9. Doğrusal olarak ayrılan sınıflama problemi (Ankaralı, Aydın ve Saraçlı, 2013).

Şekil 4.9'daki veriler doğrusal olduğundan, bu iki sınıfı birbirinden ayırabilen birden çok hiper düzlem çizilebilmektedir. Ancak DVM'nin amacı, burada en az hatayı sağlayan en iyi ayırıcı hiper düzlemi seçmektir. Seçilen bu hiper düzlem, her iki sınıfa da eşit uzaklıkta olmalıdır (Ankaralı, Aydın ve Saraçlı, 2013).

Her N elemandan oluşan verinin $X = \{x_i, y_i\}$ $i=1,2,3,\dots, N$ olduğunu varsayalım. Burada $y_i \in \{-1, 1\}$ değerleri ve $x_i \in \mathcal{R}$ özellikler vektörüdür. Bu iki veri doğrusal olarak ayrılabilme durumunda doğrudan aşırı düzlem ile ayrılacaktır. DVM'nin burada amacı bu aşırı düzlemin iki gruba eş uzaklıkta olmasını sağlamaktır (Ankaralı, Aydın ve Saraçlı, 2013).


DVM öncelikle doğrusal olarak ayrılamayan verileri, yüksek boyutlu bir formdaki verilere dönüştürür. Bu yüksek boyut, başlangıçtaki verinin özelliklerinin boyutundan daha büyük olacaktır. Bu işlemin amacı, verilerin ayırıcı bir hiper düzlem ile ayrılabilmesini sağlamaktır.

Aşırı düzlem üzerindeki bir x noktası, w aşırı düzlemin normali ve $|b|/|w|$ uzayının orjine dik uzaklığı olmak üzere $w \cdot x + b = 0$ koşulunu sağlar (Ankaralı, Aydın ve Saraçlı, 2013).

Bu koşulda w hiper düzlemin normalini ve b yanlılığı gösteren bir değerdir. X ise bu düzlem üzerinde herhangi bir noktadır. Burada $w \cdot x$ çarpımı bir iç çarpımı göstermektedir. DVM’de iki sınıfı optimal şekilde ayıran hiper düzlemi bulmak için, kareli optimizasyon probleminin çözümünde Lagrange çarpanlarını kullanır. Lagrange çarpanları, minimizasyon tipindeki problemi dual bir probleme dönüştürerek bu problemin daha basit bir şekilde çözülmesini sağlar (Ankaralı, Aydın ve Saraçlı, 2013).

Doğrusal olarak ayrılama durumu

Gerçek dünyadaki problemlerde verilerin doğrusal olarak ayrılabilmesi nadiren karşılaşılan bir durumdur. Bu yüzden, birçok problem doğrusal olarak ayrılabilen DVM’ler ile çözülemez. Verilerin çizilen hiper düzlem sınırına düşmesi gibi durumlar, yanlış ayrılma olarak adlandırılır (Küçüksille ve Ateş, 2013).



Şekil 4.10. Doğrusal olarak ayrılama verilerin yüksek dereceli uzaya aktarılması (Güneren, 2015)

Yukarıdaki şekilde görüldüğü üzere, DVM doğrusal olarak ayrılama problemlerle karşılaştığında, verileri doğrusal olmayan bir haritalama yöntemiyle n boyutlu girdi uzayından daha yüksek boyutlu bir nitelik uzayına taşır. Bu nitelik uzayında, DVM en iyi marjini bulabilmek için doğrusal sınıflandırma kuralını uygular. Nitelik uzayında doğrusal olan bu kural, ilk girdi uzayına izdüşüm yapıldığında doğrusal değildir. Doğrusal olmayan

DVM, bu şekilde nitelik uzayına taşındığında, burada doğrusal DVM gibi davranarak en iyi ayıran hiper düzlemi bulmaya çalışır (Küçüksille ve Ateş, 2013).

Çekirdek (Kernel) fonksiyonları

Çekirdek fonksiyonları, iki vektörün iç çarpımlarının hesaplanmasına dayandırılmaktadır. Doğrusal ayrılamayan x girdi vektörlerini doğrusal olmayan haritalama yöntemi kullanarak $\phi(x)$ özellik vektörüne dönüştüren çekirdek fonksiyonları, daha yüksek boyutta yeniden biçimlendirmeye çalışır (Fletcher, 2008, 14; Ayhan ve Erdoğan, 2014). Çekirdek çoğunlukla yüksek boyutlu özellik uzayında bir noktanın çarpımına denk gelir (Hofmann, Schölkopf ve Smola, 2008). Çekirdek, veriler doğrusal olduğunda verileri bölmek için bir ayırıcı hiperdüzlem kullanılmasına olanak tanır. Ancak çoğu zaman veriler doğrusal ayrılamamakta ve veri kümelerinin birbirinden ayrılamaz olduğu durumlar mevcuttur. Bu durumda, girdi verilerini yüksek boyutlu bir uzaya doğrusal olmayan bir şekilde eşlemek için çekirdek kullanılır. Bu sayede, eşleme doğrusal ayrılabilir hale gelir (Jakkula, 2006). Çekirdek fonksiyonlarında temel fikir doğrusal bir algoritma verildiğinde, önce giriş uzayında yer alan X verileri doğrusal olmayan eşleme $\phi(x)$ aracılığıyla H 'ye (Hilbert Uzayı) yani özellik uzayına eşlenir. $X \rightarrow H$ akabinde algoritma verinin vektör temsili olan $\phi(x)$ üzerinde çalışır. $\Phi(x)$ haritasının amacı, verilerin doğrusal olmayan yapılarını H 'deki doğrusal yapılara çevirmektir (Karatzoglou, Smola, Hornik ve Zeileis, 2004; Pérez Cruz ve Bousquet, 2004). DVM'de çekirdek fonksiyonu ve çekirdek fonksiyonuna ait uygun parametre değerinin seçimi DVM'in sınıflandırma performansını etkileyen önemli bir faktördür (Smola, Schölkopf ve Müller, 1998; Güran, Uysal ve Doğrusöz, 2014).

$$k: X \times X \rightarrow \mathbb{R}, (x, x_0) \mapsto k(x, x_0) \quad (4.4)$$

Eş. 4.4.'de k ; çekirdek fonksiyonunu ifade eder, X ; veri kümesini, $\mathbb{R}$; reel sayılar kümesini temsil eder. Çekirdek fonksiyonunun çıktısı bir reel sayı olacaktır ve tüm $x, x_0 \in X$ olsun.

$$k(x, x_0) = \langle \phi(x), \phi(x_0) \rangle \quad (4.5)$$

Eş. 4.5.'de ϕ fonksiyonu, verileri daha yüksek boyutlu bir özellik uzayına eşleyen bir fonksiyondur. $\phi(x), \phi(x_0)$ veri noktasının bu yüksek boyutlu uzaydaki karşılığıdır.

k benzerlik ölçüsü, genelde çekirdek olarak tanımlanır (Ben-Hur, Ong, Sonnenburg, Schölkopf ve Rätsch, 2008; Hofmann, Schölkopf ve Smola, 2008; Lampert, 2009; Nanda, Seminar, Nandika ve Maddu, 2018).

Doğrusal çekirdek fonksiyonu

Çekirdek fonksiyon türlerinden en basit olanıdır ve $(x.y)$ iç çarpımı ile ifade edilmektedir. Bu fonksiyon, daha fazla özelliğe sahip verilerde diğer fonksiyonlara göre daha iyi sonuçlar verebilir (Küçüksille ve Ateş, 2013).

Doğrusal çekirdek fonksiyonu aşağıdaki formül ile ifade edilmektedir.

$$K(x, y) = x.y \quad (4.6)$$

Polinomial çekirdek fonksiyonu

Polinomial çekirdek fonksiyonu digger çekirdek fonksiyonlarına göre daha fazla parametre içermekte, hesaplanması, uygulanması daha kolaydır ve aşağıdaki formül ile ifade edilmektedir. (Küçüksille ve Ateş, 2013).

$$K(x, y) = [(x, y) + c]^d \quad (4.7)$$

Eş. 4.7’de $(x.y)$ iç çarpımını, c sabit terimi ve d ise polinom derecesini ifade etmektedir.

Sigmoid çekirdek fonksiyonu

Sigmoid çekirdek fonksiyonu aşağıdaki formül ile ifade edilmektedir (Lin ve Lin, 2003).

$$K(x, y) = \tan(\alpha x, y + c) \quad (4.8)$$

Eş 4.8.’de c sabit terimi, α eğimi, $(x.y)$ ise iç çarpımı ifade etmektedir.

Döngüsel temelli çekirdek fonksiyonu (Radial basis function - RBF)

RBF, sınıflandırmada en çok tercih edilen çekirdek fonksiyonları arasında yer almaktadır. DVM, sınıflandırma veya tahmin yaparken, RBF çekirdeği sayesinde rastgele veri noktalarını kullanarak veri kümesini parçalayabilir (Cho, Yu, Lee, Chee ve Kim, 2008; Fletcher, 2008).

Eğer çekirdek genişliği çok küçükse, uzaklıkları çekirdek genişliğine yakın olan örnekler etkilenecektir. Aksi durumda, uzaklıkları çekirdek genişliğinden çok daha büyük olan örnekler mevcutsa ifadenin değeri kademeli olarak sıfıra yaklaştırılır (Gartner, 2008: 59; Hofmann ve diğerleri, 2008; Song, Ding, Guo, Li ve Xia, 2008).

ANOVA çekirdek fonksiyonu

ANOVA çekirdeklerini oluşturmak için bazı G kümeleri $X = \mathcal{G}N$ ve $G \times G$ üzerindeki k çekirdekleri dikkate alınır. Burada;

$$i = 1, \dots, N \text{ için } P = 1, \dots, N \quad (4.9)$$

ANOVA çekirdeği aşağıdaki gibi oluşturulur (Hofmann ve diğerleri, 2008):

$$k_p(x, x') := \sum_{1 \leq i < \dots < i_p \leq N} \prod_{p=1}^P k^{i_p}(x_{i_p}, x'_{i_p}) \quad (4.10)$$

Eş. 4.10'da ANOVA çekirdeği x ve x' veri noktaları arasındaki benzerliği ifade eder ve p dereceli bir çekirdek fonksiyonudur.

Pearson VII evrensel işlev çekirdeği

Pearson VII fonksiyonunun genel formu aşağıdaki gibi ifade edilmektedir (Cılasun ve Yalçın, 2016)

$$f(x) = \frac{H}{\left[1 + \left(\frac{2(x-x_0)\sqrt{\frac{1}{2W}-1}}{\sigma} \right)^2 \right]^W} \quad (4.11)$$

Eş. 4.11’de w ve σ parametreleri, Pearson VII fonksiyonunun genişliğini, H ise tepe değerleri arasındaki maksimum tepe seviyesini ifade eder. DVM kullanmak için hem çekirdek parametreleri hem de DVM normalizasyon sabiti C ’nin kullanıcı tarafından tanımlanması gerekir (Kavzoğlu ve Çölkesen, 2010).

Pearson VII işlev çekirdeği hem sağlam hem de DVM’lerin eşit veya daha iyi genelleştirme performansına yol açan standart çekirdek işlevleriyle karşılaştırıldığında eşit veya daha güçlü eşleme gücüne sahiptir (Zhang ve Ge, 2013).

4.3.2. Çok sınıflı DVM

DVM’nin birden fazla sınıflı problemi ayırması için temel olarak kullanılan iki yaklaşım vardır. Bunlardan birincisi, DVM için kullanılan Lagrange fonksiyonudur. Bu yöntemde, sınıf sayısı arttıkça hataların artmaya başlaması nedeniyle bu yöntem çok tercih edilmemektedir. İkincisi, DVM’nin ikili sınıflar şeklinde sınıflandırma yapacak şekilde çalıştırılmasını sağlamaktır. Bu kullanımda bire karşı bir, bire karşı hepsi ve döngüsel olmayan yaklaşımlar kullanılmaktadır (Çomak, 2008).

Bire-karşı-bir

Algoritma, N sınıflarının bütün ikili kombinasyonlarından $N(N - 1)/2$ iki sınıflı sınıflandırıcılar oluşturarak çalışır ve her bir sınıflandırıcı, örneklerin eğitilmesiyle elde edilir. Algoritma N adet sınıfın tüm ikili kombinasyonlarını kullanarak sınıflandırma yapar. Her sınıflandırıcı, örnekler kullanılarak eğitilir (Hsu ve Lin, 2002; Madzarov, Gjorgjevikj ve Chorbev, 2008). Tüm sınıflandırıcılar eğitildikten sonra test için bir oylama stratejisi uygulanır. Etiketlenmemiş örnek en çok oyu alan sınıfa atanır (Qian, Mao, Xiang ve Wang, 2010).

Bire-karşı-hepsi

Bire-karşı-hepsi yöntemi, DVM’nin çok sınıflı sınıflandırıcısı için en eski uygulamalarından biridir. Bu yöntemde, her bir DVM eğitilirken tüm örnekler dikkate alınır (Qian ve diğerleri, 2010).

N sınıflı problemlere ($N>2$) uygulanan bu yöntem, N adet ve iki sınıflı DVM sınıflandırıcısından oluşturulur. Her DVM o sınıftaki örnekleri pozitif örnekler olarak ve geri kalan tüm örnekleri negatif olarak etiketleyerek eğitilir (Madzarov ve diğerleri, 2008; Qian ve diğerleri, 2010; Hsu ve Lin, 2002).

Yönlendirilmiş asiklik grafik DVM (Direct acyclic graph – DAG DVM)

Yönlendirilmiş döngüsel olmayan grafik kullanan DVM Bire-Karşı-Bir yöntemi ile aynı şekilde $N(N-1)/2$ adet sınıflandırıcıyı eğitir ve her bir sınıf için model kurar (Platt, Cristianini ve Shawe-Taylor, 2000; Qian ve diğerleri, 2010).

4.4. Karar Ağaçları

Karar Ağaçları çok sınıflı doğrusal olmayan bir sınıflandırıcıdır (Al Banna ve diğerleri, 2020). Çok sınıflı veri kümeleri için idealdir ve ayrıca iki kümelik veri kümelerinde de kullanılır. Veri, ait olduğu sınıfı bulana kadar birden fazla karar verme aşamasından geçirilir. Bu süreçte öznitelik alanı ilgili sınıflar için farklı alanlara bölünür. Oluşan ağaç yapısı, yapılan kararlar tarafından oluşturulan düğümlerden meydana gelir. Ağaç yapıları, çok sınıflı yapılar için avantaj sağlar. Yapısı kolay anlaşılır olmasına rağmen, ezbere öğrenme problemi yaşanabilir.

İki sınıflı bir karar ağacı oluşturmak için her bir düğüm, eğitim kümesi X 'in belirli bir X_t alt kümesiyle ilişkilendirilir. Düğüm ayırma işlemi, X_t alt kümesini X_tN ve X_tY olarak ikiye bölmeyi içerir.

$$X_tY \cap X_tN = \emptyset \quad (4.12)$$

$$X_tY \cup X_tN = X_t \quad (4.13)$$

Bir ayırma işlemi sonucunda, w_1 ve w_2 sınıfları X_tY alt kümesine, w_3 ve w_4 ise X_tN alt kümesine ait sınıfları oluşturur. Düğümleri en iyi şekilde ayırmak için bir ayırma kriteri belirlenir. Düğüm oluşumu ve dallanma sonucu elde edilen düğümlerin saf olmama oranını en düşük seviyeye indirmek amaçlanır. $P(w_i|t)$, X_t alt kümesindeki bir vektörün, t

düğümündeki w_i , $i = 1, 2, \dots, M$ sınıflarına ait olasılığını temsil eder. Düğümün saf olmaması, $I(t)$ olarak aşağıda ifade edilmiştir.


$$I(t) = -\sum_{i=1}^M P(W_i|t) \log_2 P(W_i|t) \quad (4.14)$$

Saf olmama oranındaki düşüşü bulmak için, $X_t Y$ düğümündeki olasılık N_{tY}/N_t ve $X_t N$ düğümündeki olasılık N_{tN}/N_t olarak alınır. Saf olmamadaki düşüş aşağıda verilmiştir.

$$\Delta I(t) = I(t) - (N_{tY}/N_t) * I(t_Y) - (N_{tN}/N_t) * I(t_N) \quad (4.15)$$

Bir düğüm oluşturulduktan sonra, düğümün hangi sınıfa ait olduğu aşağıdaki eşitlikteki gibi çoğunluk kuralı ile belirlenir.

$$j = \arg \max_i P(w_i|t) \quad (4.16)$$



Şekil 4.11. Karar ağacı genel yapısı

Şekil 4.11’de gösterildiği üzere karar ağacı; kök, iç karar düğümleri, dal ve uç yapraklardan meydana gelmektedir. Verilerin test edildiği ve dalların hangi yöne eğileceklerini belirleyen iç karar düğümleridir. Eğilmesine yön verecek olan sorulara cevap verecek olan dallardır. Bulunduğu etiket ise uç yapraklar olarak tanımlanmaktadır.

Ağacın karmaşıklığı, ağacın doğruluğuyla ilişkilidir. Ağaç karmaşıklığı toplam düğüm sayısı, toplam dal sayısı, ağaç derinliği ve öznitelik sayısı gibi etmenlere bağlıdır (Pedregosa ve diğerleri, 2011).

Veri madenciliği teknikleri aşırı uyum (overfitting) karşılama ihtimali olduğu için ağacın budanması gerekmektedir. Karışıklık parametresi hesaplanıp, fazla karmaşıklığı olan alt ağaçlar budanmaktadır. En yaygın bilinen algoritmalar ID3 (Iterative Dichotomiser 3), C4.5, C5.0, SLIQ (Supervised Learning in Quest), SPRINT (Scalable Parallelizable Induction of Decision Trees), CART (Classification and Regression Trees), CHAID (Chi-Squared Automatic Interaction Detector), CLS (Concept Learning System) olarak sıralanabilir (Çınar, 2019). Bu algoritmalar aşağıda detaylı olarak açıklanacak ve hesaplama mekanizmaları tanıtılacaktır.

4.4.1. ID3 algoritması

1986 yılında Ross Quinlan tarafından açıklanan algoritma, makine öğrenimi ve doğal dil işleme alanlarında yaygın olarak kullanılmıştır. Bu algoritma, C4.5 algoritmasının öncülü olup, bölen özneliğin seçilmesinde entropi veya gini indeksi kullanmaktadır (Akpınar, 2000). Ağaçtaki her bir düğüm, kökten itibaren dikkate hiç alınmamış özellikler içinden en kazançlı olanı seçilerek belirlenir. Bu sayede bir kaydın hangi sınıfa ait olduğu, birkaç soruyla oluşturulan küçük karar ağaçları ile belirlenebilir (Altıntaş, 2010). Basit bir yapıdaki ID3 algoritması hem akademik hem de endüstriyel alanlarda farklı sorunların çözümü için geliştirilmiş ve yaşadığı değişimlerle yaygın bir kullanım alanına sahip olmuştur (Gülpınar, 2008).

4.4.2. C4.5 algoritması

1993 yılında yine Ross Quinlan tarafından yayımlanan algoritmada, verilerin yinelemeli olarak alt kümelerine ayrılmasıyla bir sınıflama ağacı oluşturulur. (Sezer, 2008; Kıran, 2010). Bu algoritma, ID3 algoritmasına ek olarak hem kategorik hem de sürekli öznelik değerlerini işleyebilir, kayıp verileri hesaba katmaz ve böylece daha duyarlı ve anlamlı kurallar çıkartabilen bir ağaç üretebilir (Akpınar, 2000).

4.4.3. C5.0 algoritması

C5.0 algoritması, kendisinin öncülü niteliğinde olan ID3 ve C4.5 algoritmalarına göre gözle görülür bir şekilde hızlı bir yapıya sahiptir. Küçük karar ağaçlarının üretilmesinde C5.0'ın daha etkin bellek kullanımı ve faydasız öznelikleri elemesi için winnowing özelliği,

algoritmanın önceki algoritmalarından ayıran en önemli özelliklerdir. (Akpınar, 2000). Ayrıca C5.0 büyük veri tabanlarında C4.5'e göre daha etkili sonuçlar üretmektedir (Gülpınar, 2008).

4.4.4. SLIQ algoritması

Hem sayısal hem de kategorik verilerin sınıflandırılmasında kullanılan algoritma, ağaç oluşturma sürecinde verileri değerlendirirken maliyeti azaltmak için sıralama tekniğini kullanır. Sıralama ile ağacı en iyi dallara ayırma kriterini bulma hedeflenir. Bu algoritma, ağacı dallara ayırma sürecinde hızlı olmasının yanı sıra çok iyi sonuçlar veren karar ağaçları da üretebilir (Sezer, 2008; Kıran, 2010; Silahtaroglu, 2013: 58).

4.4.5. SPRINT algoritması

SPRINT algoritması, sınıf ve kayıt numaralarını tutan farklı bir liste ile değişkenlere ait bir sınıf ve sıra numarası belirler (Sezer, 2008). Ağaç oluşturma sürecinde eğitim kümelerinden elde edilen ilk listeler, sınıflandırma köküyle ilişkilendirilir. Ağaç büyüdükçe ve düğümler yeni dallara bölündükçe, düğümlere ait değişken listeleri de bölünerek yeni dallarla ilişkilendirilir. (Silahtaroglu, 2013: 59).

4.4.6. CART algoritması

CART ya da C&RT adlarıyla bilinen bu algoritma, ikili ağaçlar üreterek hangi düğümün kök veya düğüm olacağına karar verir ve belirlenen düğümün hangi noktadan ikiye ayrılacağını hesaplar. Algoritma bu süreçte hem en uygun değişkeni bulmakta hem de değişken iki veya daha fazla farklı türde değerler taşıyorsa, bu değerleri nasıl iki gruba ayıracağını belirler (Silahtaroglu, 2013: 58).

Genellikle tıp, mühendislik ve endüstri alanlarına kullanılan algoritma ağacının oluşturulması, budanması ve en uygun ağaç seçimi basamaklarıyla yürütülmektedir (Chang ve Wang, 2006). CART algoritması, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkinin yapısını araştırmakla kalmaz, aynı zamanda bağımsız değişkenlerin birbirleriyle olan etkileşimlerini de ortaya koyar. Bu algoritma, bağımsız değişkenlerin bağımlı değişkenle ilişkisini değerlendirme ve model içindeki etkileşim durumunu belirleme konusunda

etkilidir (Kıran, 2010). Ayrıca, algoritmanın oluşturduğu modelin sınanmasına ve optimal modelin seçilmesine olanak tanınması, önemli bir avantajıdır (Ulusoy, 2013).

4.4.7. CHAID algoritması

1980 yılında ortaya atılan algoritma, parametrik olmaması, verilerin normal dağılımı gibi bir zorunluluğun olmaması, eksik değerleri ayrı bir kategoride analiz edebilmesi gibi oldukça avantajlı esnekliklere sahiptir (Rokach ve Maimon, 2008: 81; Akpınar, 2000). En popüler karar ağacı algoritmalarının başında gelen CHAID, analizlerde çapraz tablolar ve istatistiksel önem oranlarından faydalanmaktadır (Pehlivan, 2006). Karar ağacının istatistikte bilinen ki kare testine dayanarak oluşturulması, algoritmaya hem bir karar ağacı algoritması hem de istatistiğe dayalı bir algoritma olma özelliği vermektedir (Silahtaroğlu, 2013, 104). CHAID algoritmasının çoklu ağaçlar türetebilmesi, algoritmayı ikili ağaçlar türeten ID3, C4.5 ve CART algoritmalarından ayıran en önemli farklılıktır (Türe ve Tokatlı, Kurt, 2009). CHAID algoritması, sürekli ve kategorik tüm değişken türleriyle çalışabilir ve sürekli tahmin edici değişkenleri analizin gerekliliklerine uygun şekilde otomatik olarak kategorize edebilir.

5. UYGULAMA

Bu tez çalışmasında savunma sanayiinde kompozit ürün üreten bir işletme için yürütülen gerçek hayat problemi kapsamında manuel işçilik oranları yüksek, çevrim süreleri ve parça çeşitliliği yüksek, değişken sipariş ile çalışan ve verimlilik oranları düşük olan bir üretim sürecinde standart süre hesabı tahmin ve karşılaştırması makine öğrenmesi algoritmaları ve regresyon analizi kullanılarak gerçekleştirilmiştir.

5.1. Problem Tanımı


Çalışma, havacılık, uzay ve savunma sanayinde faaliyet gösteren bir kompozit ürün imalat şirketinde gerçekleştirilmiştir. Firmanın ürün gamında yaklaşık 900 çeşit ürün bulunmakta ve 250 personel ile yıllık yaklaşık 35000 adet ürün üretmektedir. Bunun yanı sıra Türkiye'nin önde gelen savunma sanayilerinin Ar-Ge süreçlerine destek olmak amacıyla her yıl müşterilerinden aldığı yeni tip ürünleri üreterek ürün çeşitliliğini artırmakta, yurt içi ve yurt dışındaki havacılık ve savunma sanayileri için üretim yapmaktadır.

Çalışma kapsamında incelenen üretim süreci, karmaşıklığı, insan gücüne bağımlılığı ve parça çeşitliliğinin fazla olması nedeniyle uzun ölçüm süreleri gerektirmektedir. Bu nedenle doğrudan iş ölçüm teknikleri uygulanamamakta ve kesin standart süreler belirlenememekte, verimlilik ölçümleri doğru sonuçlar vermemekte ve üretim planlama faaliyetlerinin başarı oranları düşük olmaktadır.

Üretim süreci, kalıp atölyesinde kalıpların hazırlanması ve malzemelerin kesilmesi ile başlar ve temiz odada serme, otoklav, kenar kesim, kalite ve depolama süreçleri ile devam eder. Çalışmada ele alınan serme süreci tüm üretim sürecinin işçilik maliyetlerinin %70'ini kapsamaktadır, dolayısıyla yapılacak iyileştirmelerde büyük katkı sağlamaya adaydır. Standart sürelerin doğru bir şekilde belirlenmesi, üretim kapasitelerinin doğru bir şekilde tahmin edilmesi, kaynak tahsislerinin optimize edilmesi ve teslimat sürelerinin rasyonel bir şekilde planlanması için önemlidir. Ancak geleneksel standart zaman hesaplama yöntemleri, üretim süreçlerinin karmaşık ve dinamik yapısı nedeniyle karar vericilerin ve yöneticilerin uygulamada çeşitli kısıtlamalarla karşılaşmasına neden olabilmektedir. Özellikle yüksek partili işler, değişken sipariş miktarları ve ürün yapıları, el işçiliğinin yüksek olduğu ürünler


ve uzun iş akışına sahip işler söz konusu olduğunda, standart sürenin doğrudan veya dolaylı geleneksel yöntemlerle belirlenmesi yoğun emek ve yatırım gerektirmekte, buna rağmen çoğu zaman doğru hesaplamalar yapmak mümkün olmamaktadır. Bu bağlamda, ele alınan gerçek hayat çalışmasında standart sürelerin, iş örnekleme gibi geleneksel doğrudan iş ölçümü teknikleri veya PMTS gibi dolaylı iş ölçümü teknikleri kullanılarak hesaplanması yerine, standart sürelerin hesaplanması için karşılaştırma ve tahmin yönteminde makine öğrenmesi tekniklerinin uygulanması etkinlik, kullanılabilirlik ve doğruluk açısından analiz edilmiştir.

Çalışma kapsamında seçilen parçaların üretim rotası Şekil 5.1’de belirtilmiştir.



Şekil 5.1. Parça ailesi üretim rotası

Çalışma, aşağıda Şekil 5.2'de gösterildiği gibi dört ana aşamadan oluşmaktadır: araştırma, veri toplama, yürütme ve analiz. İlk aşama olan araştırma aşamasında literatür taraması yapılarak kullanılacak algoritmalar hazırlanmıştır. İkinci aşamada, parçaların teknik resimleri incelenmiş ve özellikleri kaydedilmiştir. Üçüncü aşamada ise, geleneksel yöntemler ile makine öğrenmesi teknikleri olan DVM, karar ağacı ve YSA kullanılarak çalışmalar gerçekleştirilmiştir. Son aşamada ise, tahmin edilen sonuçlar analiz edilmiştir.



Şekil 5.2. Önerilen çözüm yaklaşımı akış diyagramı

5.2. Verilen Toplanması ve Veri Özellikleri

Gerçekleştirilen literatür taramaları doğrultusunda belirlenen beş ana faktör (tasarım geometrisi, prepreg kat sayısı, prepreg çeşidi, prepreg miktarı ve vakum sayısı), ürünlerin üretiminde kullanılan malzemelerin özellikleri ile üretim süreçleri arasındaki ilişkilere odaklanmaktadır. Gözlemler sırasında, hangi faktörlerin üretim sürecini nasıl etkilediği detaylı olarak incelenmiştir. Örneğin, karmaşık tasarımlara sahip ürünlerin üretim süreçleri daha uzun sürmekte ve daha fazla el işçiliği gerektirmektedir. Bu nedenle, kullanılan malzemelerin özellikleri, miktarları, uygulama yapılan yüzeyin zorluğu ve uygulama sayısı gibi faktörlerin belirlenmesi, standart sürelerin hesaplanmasında kritik bir rol oynamaktadır. Çizelge 5.1.'de ürüne yönelik faktörlerin listesi, açıklamaları ve literatürde benzer faktörlerin kullanıldığı çalışmalar verilmiştir.

Çizelge 5.1. Gerçek hayat uygulaması faktörleri ve açıklamaları

Faktör	Açıklama	Örnek Çalışma	Çalışmada Geçen Faktörler
Tasarım Geometrisi	Kalıp üzerinde serme işlemi yapılacak bölümlerin sayısını ifade eder.	Kutschenreiter (2008), Eraslan (2009).	Parça zorluğu, hacim, ağırlık, parça şekli, parça boyutu
Prepreg Kat Sayısı	Her parçanın serme işlemi yapılacak prepreg sayısı değişmektedir. Prepreg kat sayısı serme işlemi yapılacak prepreglerin miktarını ifade eder.	Dağdeviren, Eraslan ve Çelebi (2011), Kutschenreiter (2020), Çakıt ve Dağdeviren (2023), Rodrigues ve diğerleri (2022).	Operasyon/işlem sayısı, delik sayısı, uzaklık, bağlantılı eleman sayısı
Prepreg Çeşidi	Serme işleminde kullanılan prepreglerin çeşitlerini ifade eder. Prepreg çeşitleri serme işleminin zorluğunu etkilemektedir.	Susanto, Tanaya, Soembagijo (2012), Onaran ve Yanık (2019).	Zorluk, malzeme tipi, uygulama için gerekli güç miktarı
Prepreg Miktarı	Prepreglerin ne kadar miktarda kesildiğini ifade eder. m ² cinsinden dikkate alınacaktır.	Dağdeviren, Eraslan ve Çelebi (2011), Çakıt ve Dağdeviren (2023).	Yüzey alanı, bağlantılı eleman uzunluğu
Vakum Sayısı	Serilen prepreglerin kalıpta boşluk bırakmamasını sağlamak amacıyla yapılan işlemi ifade etmektedir. Vakum sayısı parçaya göre farklılık göstermektedir.	-	-

Çalışma kapsamında 443 parça incelenmiş ve ilgili parçaların 26 tip özelliği değerlendirilmiştir. Bu özellikler ürünün tasarım geometrisi, üretilen parçalarda 12 çeşit malzemenin kullanıldığı kat sayısı, 12 çeşit malzemenin kullanıldığı katlardaki kullanım miktarı ve vakum işlem sayısıdır. Girdi verilerinin çokluğu nedeniyle tüm veriler Zenodo açık arşiv platformuna yüklenmiş olup, izin dahilinde kullanıcılara erişim yetkisi verilebilmektedir (Akdoğan, 2024).

Çalışmaya ilişkin derlenen ve Zenodo açık erişim platformu üzerinden sunulan veri setinde tüm girdi verileri ve bunlara ilişkin parametre değerleri yer almaktadır. Bu veriler şu şekilde okunabilmektedir; örneğin, ilk satırda bulunan 1 numaralı parçanın tasarım geometrisi “1” değerini almıştır, yani parça teknik resimlerinden hareketle tek yüzeyli bir parça olarak değerlendirilmiştir. Bu parçanın üretiminde 27 kat Hammalzeme1, 13 kat Hammalzeme2, 10 kat Hammalzeme3, 10 kat Hammalzeme4, 13 kat Hammalzeme5 serilirken, 27,17 m² Hammalzeme1, 13,08 m² Hammalzeme2, 10,06 m² Hammalzeme3, 10,06 m² Hammalzeme4, 13,08 m² Hammalzeme5 tipi malzeme kullanılmış, 5 kez vakum işlemi yapılmış, son olarak, ilgili parça 17,85 saatte üretilmiştir. Ele alınan problem kapsamında yürütülen gerçek hayat uygulamasında incelenen süreç için standart zamanlar 443 örnek genişliğinde oluşturulan başlangıç veri seti kullanılarak tahmin edilmiştir. İlgili çalışmayı gerçekleştirmek için önerilen yaklaşımda veri ayrıştırma, ölçekleme, model kurulumu, eğitim, tahmin, performans değerlendirme ve sonuçlandırma aşamalarında doğrusal regresyon analizi, polinom regresyon analizi, YSA, DVM ve karar ağacı algoritmaları kullanılmıştır. Model geliştirme için Python/Jupyter Notebook kullanılmış ve scikitlearn paketleri ile uygulanmıştır (Scikit-Learn: Machine Learning in Python, 2021). Çalışmalar, 16 GB 2667 MHz DDR4 RAM, 2,6 GHz 6 çekirdekli Intel Core i7 işlemci ve AMD Radeon Pro 5300M 4 GB grafik kartına sahip, macOS Sonoma 14.5 işletim sistemi yüklü bir MacBook Pro (16 inç, 2019) bilgisayarda gerçekleştirilmiştir.

Literatürde, eğitim ve test veri setlerinin belirlenmesine yönelik çeşitli öneriler bulunmaktadır. Pek çok araştırmacı, %90-%10, %80-%20 veya %70-%30 oranlarını temel alan yöntemleri kullanmaktadır (Zhang, Patuwo ve Hu, 1998). Kurulan modellerin yapısının ve özelliklerinin belirlenmesinin yanı sıra, uygulama öncesinde eğitim ve test verilerinin hazırlanması da büyük önem arz etmektedir. Özellik ve hedeflerin belirlenerek verilerin eğitim ve test olarak iki parçaya ayrılması aşamasında yürütülen çalışma kapsamında test

veri boyutu %20 olarak belirlenmiştir. 443 kayıttan 88'i, verinin %20'si kullanılarak test veri kümesi, 355'i ise kalan %80'i kullanılarak eğitim veri kümesi olarak sınıflandırılmıştır.

Bu çalışmada, oluşturulan modellerin etkinliğini değerlendirmek amacıyla modelin doğruluğu test edilmiştir. Tahmin modelleri için; OMH, kök ortalama karesel hata (KOKH), ortalama kare hatası (OKH) değerleri düşük olduğunda çıktı değerleri daha doğru olarak kabul edilir, burada daha yüksek belirleme katsayısı (R^2) değerleri eğitim ve test verileri arasında daha iyi bir eşleşme anlamına gelir. Modellerin başarısını değerlendirmek amacıyla çeşitli performans ölçütleri kullanılmıştır ve kullanılan her bir performans ölçütüne ait hesaplama formülleri aşağıda Eş. 5.1 – Eş. 5.4 (Çakıt ve Dağdeviren, 2023) ile sunulmaktadır.

$$KOKH = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2} \quad (5.1)$$

$$OKH = \frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2 \quad (5.2)$$

$$OMH = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (5.3)$$

$$R^2 = 1 - \left(\frac{\sum_{i=1}^n (P_i - A_i)^2}{\sum_{i=1}^n A_i^2} \right) \quad (5.4)$$

Yukarıda yer alan " A_i " ve " P_i " sırasıyla ölçülen ve tahmin edilen parametreleri, e_i ; tahmin hatasını; n ; toplam test verisi sayısını ve i ($i=1, 2, 3, \dots, n$) ölçüm verilerini temsil etmektedir.

5.3. Geleneksel Tahmin Yöntemleri Algoritması ve Hesaplamaları

Çalışma kapsamında hazırlanan modeller; programlama dili, kodu ve komutu kullanmadan, genel kelimelerle araştırmacılara akışın anlatıldığı kaba kod (pseudocode) formatında sunulmuştur (Doğan, Aslan ve Yıldırım, 2017).

Regresyon analizi hesaplama algoritmalarına dair oluşturulan kaba kod (pseudocode) aşağıda sunulmaktadır,

```

Import LinearRegression, StandardScaler, train_test_split, PolynomialFeatures
Import mean_squared_error, mean_absolute_error, r2_score
Import Pandas

```

```

Procedure GelenekselTahmin(data_path)

```

```

    // Veriyi yükle
    data_path ← 'veri_dosyası.xlsx'
    train_data ← load_data(data_path)

    // Özellikleri ve hedef değişkeni ayır
    x ← seçilen_sütunlar(train_data)
    y ← train_data['Zaman']

    // Veriyi eğitim ve test setlerine ayır
    x_train, x_test, y_train, y_test ← train_test_split(x, y, test_size=0.2)

    // Verileri ölçeklendir
    scaler ← StandardScaler()
    x_train_scaled ← scaler.fit_transform(x_train)
    x_test_scaled ← scaler.transform(x_test)

    // Regresyon modelini oluştur
    if Polinom_regresyon:
        poly_features ← PolynomialFeatures(degree=d)
        x_train_scaled ← poly_features.fit_transform(x_train_scaled)
        x_test_scaled ← poly_features.transform(x_test_scaled)

    else if Linear_regresyon:
        model ← LinearRegression()

    End if

    // Modeli eğit
    model.fit(x_train_scaled, y_train)

```

```

// Tahmin yap
y_train_pred ← model.predict(x_train_scaled)
y_test_pred ← model.predict(x_test_scaled)

// Eğitim verisi performans metriklerini hesapla
mae_train ← mean_absolute_error(y_train, y_train_pred)
mse_train ← mean_squared_error(y_train, y_train_pred)
rmse_train ← sqrt(mse_train)
r2_train ← r2_score(y_train, y_train_pred)

// Test verisi performans metriklerini hesapla
mae_test ← mean_absolute_error(y_test, y_test_pred)
mse_test ← mean_squared_error(y_test, y_test_pred)
rmse_test ← sqrt(mse_test)
r2_test ← r2_score(y_test, y_test_pred)

Print PerformansMetrikleri(mae_train, mse_train, rmse_train, r2_train, mae_test,
mse_test, rmse_test, r2_test)

End Procedure

```

5.3.1. Regresyon modeli uygulama sonuçları

Geliştirilen doğrusal ve polinom regresyon modelinin performansı çalışma için seçilen ve Alt bölüm 5.2 Eş. 5.1 – Eş. 5.4 ile sunulan performans metrikleri çerçevesinde değerlendirilmiş ve elde edilen sonuçlar Çizelge 5.2’de sunulmuştur.

Çizelge 5.2. Regresyon modeli sonuçlarının performans değerlendirmesi

Regresyon Modeli / Performans Kriteri	OMH	OKH	KOKH	R ²
Doğrusal Regresyon	0,610	0,721	0,849	0,821
Polinom Regresyon	0,631	0,808	0,899	0,799

Doğrusal regresyon modeli, genellikle daha düşük hata metriklerine ve daha yüksek bir R^2 değerine sahiptir. Bu, doğrusal regresyon modelinin tahminlerinde daha istikrarlı ve veriye daha iyi uyum sağladığını göstermektedir. Polinom regresyon modeli daha karmaşık bir model olmasına rağmen, bu durumda Doğrusal regresyon modeline kıyasla daha fazla hata yapmış ve veriye daha az uyum sağlamıştır. Tahmin ve istatistiki analiz literatüründe genellikle daha efektif sonuçlar verdiği gözlemlenen polinom regresyon yerine doğrusal regresyon modelinin ele alınan probleme ilişkin gerçek hayat verileri temelinde daha iyi sonuç vermiş olması da mevcut bilimsel yazın bilgileri ve veri tipi özellikleri temelinde incelenmelidir. Ele alınan problem temelinde yapılacak standart süre hesaplamalarında göz önünde tutulması için literatür araştırmaları ve mevcut yazından hareketle belirlenen faktörlerin tümünün çıktı verisi ile doğrusal bir ilişkide olduğu; problemde belirlenen ve standart zamana etki eden tüm faktörlerin standart sürenin artmasına etki ettiği görülmektedir. Bu durum iki geleneksel tahmin modeli, sonuçları temelinde hesaplanan performans metrikleri çerçevesinde karşılaştırıldığında, ürün standart süresine etki eden faktörler ile çıktı verisi arasında doğrusal bir ilişki olduğunu ortaya koymaktadır.

Elde edilen tahmin sonuçlarının ileri analizi çerçevesinde, doğrusal regresyon modeli performans sonuçlarının test ve eğitim verilerine bağlı olarak hesaplanan performans metrikleri değerleri ise Çizelge 5.3'te belirtilmiştir.

Çizelge 5.3. Doğrusal regresyon modeli test ve eğitim verileri performans değerleri kıyaslaması

Veri Tipi / Performans Kriterleri	OMH	OKH	KOKH	R^2
Test Verileri	0,610	0,721	0,849	0,821
Eğitim Verileri	0,552	0,649	0,806	0,825

Eğitim ve test verilerine ilişkin performans metrikleri regresyon modelinin aşırı ya da yetersiz öğrenme yapmasının kontrolü için değerlendirilmiştir. Bu karşılaştırma sonucunda; eğitim verileri hesaplamalarındaki hataların test verileri hesaplamalarında elde edilen hata oranlarına göre biraz daha düşük olduğu, ancak, aradaki farkın kabul edilebilir düzeyde olduğu görülmektedir. Bu durum, modelin eğitim verisine iyi uyum sağladığını ve aynı zamanda genelleme yeteneğinin de yeterli olduğunu göstermektedir. Eğitim verisi R^2 skoru (0,825), modelin eğitim verisini öğrendiğini, test verisi R^2 skoru (0,821) ise modelin genelleme yeteneğinin iyi olduğunu gözler önüne sermektedir. Model, eğitim verisi

üzerindeki performansını test verisi üzerinde büyük ölçüde koruyabilmiştir. Dolayısıyla; aşırı öğrenme riskinin düşük olduğu ve modelin genelleme yeteneğinin iyi olduğu ortaya çıkmıştır. Hem eğitim hem de test hataları makul seviyelerde olduğu için, modelin yetersiz öğrenme yapmadığını ve verideki temel kalıpları öğrendiğini yorumlayabiliriz. Bu değerlendirmeler ışığında, doğrusal regresyon modelinin aşırı öğrenme veya yetersiz öğrenme yapmadığı anlaşılmaktadır.

5.4. YSA Algoritması ve Hesaplamaları

YSA algoritması hesaplamalarına ilişkin kaba kod (pseudocode) aşağıda sunulmaktadır.

```
Import MLPregressor, StandardScaler, train_test_split, mean_absolute_error,
mean_squared_error, r2_score
Import Pandas
```

```
Procedure YSAAlgoritmasi(data_path)
```

```
    // Veriyi yükle
```

```
    data_path ← 'veri_dosyası.xlsx'
```

```
    train_data ← load_data(data_path)
```

```
    // Özellikleri ve hedef değişkeni ayır
```

```
    x ← seçilen_sütunlar(train_data)
```

```
    y ← train_data['Zaman']
```

```
    // Veriyi eğitim ve test setlerine ayır
```

```
    x_train, x_test, y_train, y_test ← train_test_split(x, y, test_size=0.2)
```

```
    // Verileri ölçeklendir
```

```
    scaler ← StandardScaler()
```

```
    x_train_scaled ← scaler.fit_transform(x_train)
```

```
    x_test_scaled ← scaler.transform(x_test)
```

```
    // YSA modelini oluştur
```

```
model ← MLPRegressor(
    hidden_layer_sizes=katman_boyutları, //Çalışma kapsamında farklı katman boyutları
    denenmiştir.
```

```
    activation='relu',
    solver='adam',
    alpha=0.005,
    learning_rate_init=0.005,
    max_iter=1500, //Çalışma kapsamında farklı iterasyon sayıları denenmiştir.
    shuffle=True,
    tol=0.0001,
    random_state=42
)
```

```
// Modeli eğit
```

```
model.fit(x_train_scaled, y_train)
```

```
// Eğitim verisi üzerinde tahmin yap
```

```
y_train_pred ← model.predict(x_train_scaled)
```

```
// Test verisi üzerinde tahmin yap
```

```
y_test_pred ← model.predict(x_test_scaled)
```

```
// Eğitim verisi için performans metriklerini hesapla
```

```
mae_train ← mean_absolute_error(y_train, y_train_pred)
```

```
mse_train ← mean_squared_error(y_train, y_train_pred)
```

```
rmse_train ← sqrt(mse_train)
```

```
r2_train ← r2_score(y_train, y_train_pred)
```

```
// Test verisi için performans metriklerini hesapla
```

```
mae_test ← mean_absolute_error(y_test, y_test_pred)
```

```
mse_test ← mean_squared_error(y_test, y_test_pred)
```

```
rmse_test ← sqrt(mse_test)
```

```
r2_test ← r2_score(y_test, y_test_pred)
```

Print PerformansMetrikleri(mae_train, mse_train, rmse_train, r2_train, mae_test, mse_test, rmse_test, r2_test)

End Procedure

Çalışma kapsamında yürütülen YSA uygulamalarında girdi verisini en iyi şekilde işleyerek en yüksek performanslı tahmin sonuçlarının elde edilmesi amacı ile farklı nöron sayılarında farklı sayıda katmanlarla farklı hesaplama algoritmaları kullanan altı adet YSA yapısı oluşturulmuştur. En iyi sonucu veren YSA modelinin belirlenmesi amacıyla farklı kombinasyonlarda geliştirilen modeller aynı girdi verileri ile çalıştırılarak Çizelge 5.4'te sunulan sonuçlar elde edilmiştir.

Çizelge 5.4. YSA katman sayısı değişimlerinin tahmin performansına etkisi

Model No.	Katman Sayısı	Nöron Sayısı	Performans Kriterleri			
			OMH	OKH	KOKH	R ²
Model 1	1	32	0,585	0,626	0,791	0,845
Model 2	1	48	0,558	0,637	0,798	0,841
Model 3	2	16-16	0,614	0,804	0,897	0,8
Model 4	2	32-16	0,653	1,068	1,033	0,735
Model 5	3	48-16-8	0,556	0,672	0,82	0,833
Model 6	3	32-16-8	0,542	0,610	0,781	0,849

Çizelge 5.4 göstermektedir ki üç katmanlı ve “32-16-8” nöronlu yapı (Model 6) girdi veri seti temelinde en iyi hesaplama performansını göstermektedir. Bu model hem düşük hatalarla tahmin yapabilmekte hem de yüksek R² değeri ile ispat edildiği gibi verinin büyük bir kısmını açıklayabilmektedir. Mevcut alan yazınında da belirtilmektedir ki yüksek R² değerine sahip olan modeller, verinin büyük kısmını açıklayarak daha öngörülebilir ve güvenilir sonuçlar sunabilmektedir (Ozili, 2022). Özellikle 0,70 ile 0,90 arasında hesaplanan R² değeri sonuçlarının modellerin verileri iyi bir şekilde açıkladığını ve oluşturulan modelin girdi verisine iyi bir uyum sağladığını gösterdiği kabul edilmektedir (Türkan, Bozdağ, Karkınlı ve Ulucan, 2023). OMH, OKH ve KOKH gibi tahmin hata değerleri için, R² değerinde olduğu gibi kesin bir iyi veya kötü aralığı bulunmamakla birlikte, mevcut alan yazınında bu hata değerlerinin modelin kullanım amacına göre mümkün olduğunca düşük tutulması gerektiği vurgulanmaktadır. Bu bağlamda, modelin doğruluğunu artırmak ve

tahmin başarısını iyileştirmek adına bu hata değerlerinin minimize edilmesi esastır (Alexander, Tropsha ve Winkler, 2015). Tek katmanlı modeller (Model 1 ve Model 2) tüm metrikler temelinde oldukça iyi performans göstermektedir ve çok katmanlı modellere kıyasla (Model 3, Model 4 ve Model 5) daha basit yapılarıyla iyi sonuçlar vermektedir. İki katmanlı modeller (Model 3 ve Model 4) diğer modellere göre daha zayıf performans sergilemektedir, tahmin performansları karşılaştırmalı olarak analiz edildiğinde özellikle Model 4'ün (32-16 nöronlu yapı) diğer tüm model yapılarından daha düşük performans gösterdiği izlenmiştir. Gerçekleştirilen karşılaştırmalı analizlerden elde edilen bulgular YSA hesaplamalarında kurulan modellerin katman ve nöron sayılarının doğru belirlenmesinin model tahmin performansını önemli ölçüde etkilediğini göstermektedir. Çizelge 5.4'te sunulan model parametreleri ve performans metrikleri temelinde ölçülen tahmin dereceleri değerlendirildiğinde görülmektedir ki daha karmaşık modeller her zaman daha iyi performans göstermeyebilmektedir; doğru yapılandırılmış üç katmanlı model (Model 6) en iyi tahmin sonuçlarını verirken, tek katmanlı yapıların da (Model 1 ve Model 2) oldukça rekabetçi olduğu görülmektedir.


Bu bulgular ışığında gerçek hayat uygulama hesaplamalarında YSA uygulamasına ilişkin hesaplamalarda nöron ve katman sayılarına göre en yüksek performansı gösteren Model 6 ile geliştirilen YSA yapısının kullanılmasına karar verilmiştir. YSA hesaplamalarının bu aşamasında bir sonraki adımda algoritma hesaplamaları için en uygun iterasyon sayısının belirlenmesi üzerinde denemeler gerçekleştirilmiştir. Mevcut literatür ışığında belirlenen beş farklı iterasyon sayısı temelinde koşumlar gerçekleştirilerek hangi iterasyon sayısından sonra sonuçlarda belirgin iyileşmenin sağlanamadığı ve girdi veri setine ilişkin iyi tahmin değerlerinin nasıl elde edilebileceği Altbölüm 5.2 Eş. 5.1 – Eş. 5.4 ile sunulmuş olan performans metrikleri temelinde incelenmiş, elde edilen veriler Çizelge 5.5'te sunulmuştur.

Çizelge 5.5. YSA iterasyon sayısı değişimlerinin tahmin performansına etkisi

İterasyon Sayısı	OMH	OKH	KOKH	R ²
100	0,504	0,505	0,71	0,874
200	0,55	0,646	0,803	0,84
250	0,554	0,658	0,811	0,837
1500	0,542	0,61	0,781	0,849
15000	0,542	0,61	0,781	0,849

İterasyon sayısı, YSA modelinin performansını belirleyen önemli bir faktördür (Haykin, 2009: 111). Çizelge 5.5'e bakıldığında, modelin belirli bir iterasyon sayısından sonra yakınsadığı ve daha fazla iterasyonun model performansını iyileştirmediği görülmektedir. Optimum iterasyon sayısının 1500 civarında olduğu ve bu sayının üstüne çıkmanın tahmin performansı açısından ek bir fayda sağlamadığı görülmektedir. Bu noktada, gereksiz hesaplama maliyetlerinden kaçınmak için iterasyon sayısı 1500 olarak belirlenmiştir.

En iyi tahmin performansına sahip olan Model 6'nın YSA yapısı Şekil 5.3'te sunulmuştur. Şekildeki ilk katman girdi katmanını, takip eden üç katman; gizli katmanları, son katman ise çıktı katmanını temsil etmektedir.



Şekil 5.3. Geliştirilen YSA modelinin yapısı

5.4.1. YSA uygulama sonuçları

Geliştirilen YSA modelinin (Model 6) performansı çalışma için seçilen performans metrikleri Alt bölüm 5.2 Eş. 5.1 – Eş. 5.4 çerçevesinde değerlendirilmiş ve elde edilen sonuçlar Çizelge 5.6'da sunulmuştur.

Çizelge 5.6. YSA sonuçlarının performans değerlendirmesi

OMH	OKH	KOKH	R^2
0,542	0,610	0,781	0,849

YSA modelinin performans metrikleri değerlendirildiğinde, OMH, OKH ve KOKH değerlerinin kabul edilebilir düzeyde olduğu görülmektedir. R^2 değerinin 0,849 olması, modelin veri setindeki değişkenliğin %84,9'unu açıkladığını göstermektedir. Alt bölüm 5.4'te de belirtildiği gibi; elde edilen yüksek R^2 değeri modelin tahminlerinde oldukça başarılı olduğunu ve veriye iyi bir uyum sağladığını işaret etmektedir. YSA performans sonuçlarının test ve eğitim verilerinin kıyaslanması amacıyla elde edilen sonuçlar ise Çizelge 5.7'de belirtilmiştir.

Çizelge 5.7. YSA test ve eğitim verileri performans değerleri kıyaslaması

Veri Tipi / Performans Kriterleri	OMH	OKH	KOKH	R^2
Test Verileri	0,542	0,610	0,781	0,849
Eğitim Verileri	0,297	0,172	0,415	0,954

Eğitim ve test verileri arasındaki performans metrikleri karşılaştırıldığında, eğitim verisinde hesaplanan hataların test verilerine göre daha düşük olduğu gözlenmektedir. Eğitim veri seti ile hesaplanan R^2 değeri (0,954), modelin eğitim verisini çok iyi öğrendiğini ve verideki kalıpları iyi yakaladığını göstermektedir. Test veri seti ile hesaplanan R^2 değeri (0,849) ise modelin genelleme yeteneğinin yeterli olduğunu ortaya koymaktadır. Bu sonuçlar, YSA modelinin eğitim verisi üzerinde gösterdiği yüksek performansı test verisi üzerinde büyük ölçüde koruyabildiğini göstermektedir. Bu durum, modelin aşırı öğrenme yapmadığını ve genelleme yeteneğinin tatmin edici olduğunu işaret eder. Eğitim ve test hatalarının her ikisi de düşük seviyelerde olduğu için, modelin yetersiz öğrenme yapmadığı ve verideki temel kalıpları başarıyla öğrendiği sonuçlarına varılmaktadır.

Sonuç olarak, YSA modelinin hem eğitim hem de test verileri üzerindeki performansı, tahmin sonuçlarının güvenilir olduğunu ve genel uyum yeteneğinin yeterli düzeyde olduğunu göstermektedir.

5.5. DVM Algoritması ve Hesaplamaları

DVM hesaplama algoritmasına dair oluşturulan kaba kod (pseudocode) aşağıda sunulmaktadır.

```
Import SVR, StandardScaler, train_test_split, GridSearchCV
```

```

Import mean_absolute_error, mean_squared_error, r2_score
Import Pandas

```

```

Procedure DVMAgoritması(data_path)

```

```

// Veriyi yükle
data_path ← 'veri_dosyası.xlsx'
train_data ← load_data(data_path)

// Özellikleri ve hedef değişkeni ayır
x ← seçilen_sütunlar(train_data)
y ← train_data['Zaman']

// Veriyi eğitim ve test setlerine ayır
x_train, x_test, y_train, y_test ← train_test_split(x, y, test_size=0.2)

// Verileri ölçeklendir
scaler ← StandardScaler()
x_train_scaled ← scaler.fit_transform(x_train)
x_test_scaled ← scaler.transform(x_test)

// Hiperparametre ızgarasını tanımla
param_grid ← {
    'C': [0.1, 1, 10, 100],
    'epsilon': [0.01, 0.1, 0.2, 0.5],
    'kernel': ['linear', 'rbf'] //Çalışma kapsamında farklı çekirdek fonksiyonları denenmiştir.
}

// GridSearchCV ile model hiperparametrelerini optimize et
grid_search ← GridSearchCV(SVR(), param_grid)
grid_search.fit(x_train_scaled, y_train)

// En iyi parametrelerle model oluştur
best_model ← grid_search.best_estimator_()

```

```

// Eğitim verisi üzerinde tahmin yap
y_train_pred ← best_model.predict(x_train_scaled)

// Test verisi üzerinde tahmin yap
y_test_pred ← best_model.predict(x_test_scaled)

// Eğitim verisi için performans metriklerini hesapla
mae_train ← mean_absolute_error(y_train, y_train_pred)
mse_train ← mean_squared_error(y_train, y_train_pred)
rmse_train ← sqrt(mse_train)
r2_train ← r2_score(y_train, y_train_pred)

// Test verisi için performans metriklerini hesapla
mae_test ← mean_absolute_error(y_test, y_test_pred)
mse_test ← mean_squared_error(y_test, y_test_pred)
rmse_test ← sqrt(mse_test)
r2_test ← r2_score(y_test, y_test_pred)

// Performans metriklerini ekrana yazdır
Print PerformansMetrikleri(mae_train, mse_train, rmse_train, r2_train, mae_test,
mse_test, rmse_test, r2_test)

End Procedure

```

Çalışma kapsamında yürütülen DVM uygulamalarında girdi verisini en iyi şekilde işleyerek en yüksek performanslı tahmin sonuçlarının elde edilmesi amacı ile farklı çekirdek fonksiyonları kullanılan beş farklı DVM yapısı oluşturulmuştur. En iyi sonucu veren DVM modelinin belirlenmesi amacıyla farklı kombinasyonlarda geliştirilen modeller aynı girdi verileri ile çalıştırılarak Çizelge 5.8’de sunulan sonuçlar elde edilmiştir.

Çizelge 5.8. DVM çekirdek fonksiyonu değişimlerinin tahmin performansına etkisi

Model No.	Çekirdek Fonksiyonu	Performans Kriterleri			
		OMH	OKH	KOKH	R ²
Model 1	Polinom	0,633	1,077	1,038	0,733
Model 2	Sigmoid	0,731	3,6	1,897	0,106
Model 3	RBF	0,57	0,654	0,809	0,838
Model 4	Doğrusal	0,57	0,768	0,877	0,809
Model 5	Doğrusal ve Döngüsel Temelli Karma Model	0,542	0,559	0,748	0,861

Çizelge 5.8'de DVM modellerinde kullanılan farklı çekirdek fonksiyonlarının tahmin performansına etkisi detaylı olarak incelenmiştir. Eğitim ve test verileri üzerinde elde edilen performans metrikleri, modellerin aşırı veya yetersiz öğrenme yapıp yapmadığını değerlendirmek amacıyla analiz edilmiştir. Polinom çekirdek fonksiyonunun kullanıldığı Model 1, R² değeri 0,733 ile veriyi diğer modellere nazaran orta seviyede açıklayabilmesine rağmen, OMH, OKH ve KOKH değerlerinin diğer modellere göre yüksek olması, modelin hata oranlarının yüksek olduğunu ve performansının göreceli olarak düşük kaldığını göstermektedir. Sigmoid çekirdek fonksiyonu kullanılan Model 2 en düşük R² değeri (0,106) ile zayıf bir genelleme yeteneğine sahip olduğunu göstermiştir. Bu modeldeki yüksek hata oranları, sigmoid çekirdek fonksiyonunun bu veri seti için uygun olmadığını ortaya koymaktadır. RBF (döngüsel temelli) çekirdek fonksiyonunun kullanıldığı Model 3 hem eğitim hem de test verisi üzerinde düşük hata oranları ile yüksek bir R² değeri (0,838) elde etmiş ve bu durum modelin hem iyi bir genelleme yeteneğine sahip olduğunu hem de veriye iyi uyum sağladığını göstermiştir. Benzer şekilde, doğrusal çekirdek fonksiyonunun kullanıldığı Model 4 de yüksek R² değeri (0,809) ve düşük hata oranları ile iyi bir performans sergilemiştir. Buradan hareketle, diğer modellere göre yüksek performans gösteren Model 3 ve Model 4 seçilerek yeni bir karma model hazırlanmıştır. Doğrusal ve döngüsel temelli çekirdek fonksiyonlarının bir arada kullanıldığı bu karma modelle (Model 5) en yüksek R² değeri (0,861) ile veriyi en iyi şekilde açıklayan model elde edilmiştir. Model 5 aynı

zamanda, en düşük OMH, OKH ve KOKH değerleri ile hem eğitim hem de test verileri üzerindeki en iyi performansı göstermiştir. Özellikle RBF ve doğrusal çekirdek fonksiyonları da yüksek performans sergilerken, sigmoid çekirdek fonksiyonu bu veri seti için uygun bir seçenek olmamıştır. Bu bulgular, DVM modelinin çekirdek fonksiyonunun dikkatli bir şekilde seçilmesi gerektiğini ve veri setinin özelliklerine göre modelin optimize edilmesinin önemli olduğunu vurgulamaktadır. Çalışma kapsamında gerçekleştirilen bu araştırmalara dair bulgular ışığında DVM hesaplamalarında en iyi sonuçların elde edildiği Model 5 üzerinden devam edilmiştir.

5.5.1. DVM uygulama sonuçları

Önerilen DVM modelinin (Model 5) performans değerlendirmesi sonuçları Çizelge 5.9’da belirtilmiştir.

Çizelge 5.9. Doğrusal ve döngüsel temelli DVM performans sonuçları

OMH	OKH	KOKH	R^2
0,542	0,559	0,748	0,861

DVM performans sonuçlarının test ve eğitim verilerinin kıyaslanması amacıyla elde edilen sonuçlar ise Çizelge 5.10’da belirtilmiştir.

Çizelge 5.10. DVM test ve eğitim verileri performans değerleri kıyaslaması

Veri Tipi / Performans Kriterleri	OMH	OKH	KOKH	R^2
Test Verileri	0,542	0,559	0,748	0,861
Eğitim Verileri	0,415	0,272	0,522	0,926

Çizelge 5.10’da belirtilen sonuçlara dayanarak, modelin eğitim verisi üzerindeki performansının yüksek olduğu, ancak test verisi üzerindeki performansın biraz düştüğü gözlemlenmektedir. Bu durum, modelin eğitim verisini aşırı öğrenip öğrenmediğini veya test verisi üzerindeki tahminlerinin yeterli düzeyde olup olmadığını değerlendirmek için önemlidir. Eğitim veri seti ile hesaplanan R^2 değeri oldukça yüksektir (0,926), bu da modelin eğitim verisine çok iyi uyum sağladığını göstermektedir. Ancak, test veri seti ile hesaplanan R^2 değeri (0,861) eğitim verisine göre daha düşüktür. Bu fark, modelin eğitim verisine aşırı uyum sağlayıp test verisinde performans kaybı yaşadığına işaret edebilir. OMH ve KOKH

değerlerinin de test verisinde daha yüksek olması bu durumu destekler niteliktedir. Mevcut yazında belirtildiği üzere bu durum modelin eğitim verisi üzerindeki performansı çok yüksek olduğu için, yüksek OMH, OKH ve KOKH değerlerinin elde edilmesi durumunda modelin yetersiz öğrenme eğiliminde olduğu sonucu çıkarılabilir. Tahmin performansının uygun düzeyde olup olmadığını değerlendirirken, özellikle test verisi üzerindeki performans metriklerine dikkat edilmelidir. Test verisindeki R^2 skoru (0,861) ve diğer hata parametreleri (OMH, OKH, KOKH) değerleri modelin genelde iyi bir performans sergilediğini, ancak bazı iyileştirmelere ihtiyaç duyulabileceğini göstermektedir.

5.6. Karar Ağaçları Algoritması ve Hesaplamaları

Oluşturulan karar ağaçları hesaplama algoritmasına ilişkin kaba kod (pseudocode) aşağıda sunulmaktadır.

```
Import DecisionTreeRegressor, StandardScaler, train_test_split, GridSearchCV
Import mean_absolute_error, mean_squared_error, r2_score
Import Pandas
```

Procedure KararAgaciAlgoritmasi(Sklearn, Pandas, data_path)

```
// Veriyi yükle
data_path ← 'veri_dosyası.xlsx'
train_data ← load_data(data_path)

// Özellikleri ve hedef değişkeni ayır
x ← seçilen_sütunlar(train_data)
y ← train_data['Zaman']

// Veriyi eğitim ve test setlerine ayır
x_train, x_test, y_train, y_test ← train_test_split(x, y, test_size=0.2)

// Verileri ölçeklendir
scaler ← StandardScaler()
x_train_scaled ← scaler.fit_transform(x_train)
```

```

x_test_scaled ← scaler.transform(x_test)

// Hiperparametre ızgarasını tanımla
param_grid ← {
  'max_features': ['sqrt', 'log2', None],
  'max_depth': [10, 20, 30, None],
  'min_samples_split': [2, 5, 10],
  'min_samples_leaf': [1, 2, 4]
}

// GridSearchCV ile model hiperparametrelerini optimize et
grid_search ← GridSearchCV(DecisionTreeRegressor(), param_grid)
grid_search.fit(x_train_scaled, y_train)

// En iyi parametrelerle model oluştur
best_model ← grid_search.best_estimator_()

// Eğitim verisi üzerinde tahmin yap
y_train_pred ← best_model.predict(x_train_scaled)

// Eğitim verisi için performans metriklerini hesapla
train_mae ← mean_absolute_error(y_train, y_train_pred)
train_mse ← mean_squared_error(y_train, y_train_pred)
train_rmse ← sqrt(train_mse)
train_r2 ← r2_score(y_train, y_train_pred)

Print PerformansMetrikleri(train_mae, train_mse, train_rmse, train_r2)

// Test verisi üzerinde tahmin yap
y_test_pred ← best_model.predict(x_test_scaled)

// Test verisi için performans metriklerini hesapla
test_mae ← mean_absolute_error(y_test, y_test_pred)
test_mse ← mean_squared_error(y_test, y_test_pred)

```

```

test_rmse ← sqrt(test_mse)
test_r2 ← r2_score(y_test, y_test_pred)

// Performans metriklerini ekrana yazdır
Print PerformansMetrikleri(test_mae, test_mse, test_rmse, test_r2)
End Procedure

```

Çalışma kapsamında yürütülen karar ağaçları hesaplamalarında en yüksek performanslı tahmin sonuçlarının elde edilmesi amacı ile farklı derinlikler kullanan altı farklı karar ağacı yapısı oluşturulmuştur. En iyi sonucu veren karar ağacı modelinin belirlenmesi amacıyla farklı kombinasyonlarda geliştirilen modeller aynı girdi verileri ile çalıştırılarak Çizelge 5.11’de sunulan sonuçlar elde edilmiştir.

Çizelge 5.11. Derinlik değişimlerinin tahmin performansına etkisi


Model No.	Derinlik Sınırı	Performans Kriterleri			
		OMH	OKH	KOKH	R ²
Model 1	5	0,676	1,293	1,137	0,679
Model 2	10	0,548	0,694	0,833	0,828
Model 3	20	0,642	1,171	1,082	0,709
Model 4	30	0,557	0,772	0,878	0,808
Model 5	Derinlik Sınırlaması Yok (Sonsuz Derinlik)	0,557	0,772	0,878	0,808
Model 6	None, 10, 20, 30	0,548	0,694	0,833	0,828

Çizelge 5.11’de yer alan karar ağacı modellerinde farklı derinlik sınırlarının performansa etkisi detaylı bir şekilde incelenmiştir. Bu analizde de Alt bölüm 5.2’de belirtildiği gibi OMH, OKH, KOKH ve R² gibi performans kriterleri kullanılarak modellerin genelleme yeteneği ve öğrenme kapasiteleri değerlendirilmiştir.

Beş seviyeli derinliğe sahip Model 1’in OMH (0,676), OKH (1,293), KOKH (1,137) ve R² (0,679) değerleri, modelin veriyi yeterince iyi öğrenemediğini ve bu nedenle genelleme

yeteneğinin zayıf olduğunu göstermektedir. Bu düşük performans, modelin karmaşıklığının yetersiz kalmasına bağlanabilir ve verinin önemli özelliklerini kaçırmasına neden olmuştur. On seviyeli derinliğe sahip Model 2, OMH (0,548), OKH (0,694), KOKH (0,833) ve R^2 (0,828) değerleriyle en iyi performansı sergileyen model olmuştur. Bu sonuçlar, modelin veriyi daha iyi öğrendiğini ve genelleme yeteneğini koruduğunu ortaya koymaktadır. Bu model, verinin yeterince iyi öğrenilmesi ve aynı zamanda genelleme yeteneğini muhafaza etme konusunda optimum dengeyi sağlamaktadır. Yirmi seviyeli derinliğe sahip Model 3 OMH (0,642), OKH (1,171), KOKH (1,082) ve R^2 (0,709) değerleri incelendiğinde, modelin daha karmaşık hale gelmesine rağmen genelleme yeteneğinin azaldığı ve performansının düştüğü görülmektedir. Bu, modelin gereğinden fazla karmaşık hale gelmesiyle birlikte aşırı öğrenme riskinin arttığını göstermektedir. Hem 30 seviyeli derinlikteki Model 4 hem de sonsuz derinlikteki Model 5, OMH (0,557), OKH (0,772), KOKH (0,878) ve R^2 (0,808) değerleriyle benzer performanslar sergilemiştir. Bu modellerin performansları, aşırı karmaşıklık nedeniyle gereksiz yere artan hata oranları ve azalan genelleme yeteneği temelinde sınırlı kalmıştır. Model 6, farklı derinlik sınırlarının (*None, 10, 20, 30*) kombinasyonunu deneyerek, en iyi sonuçları sağlayan derinlik seviyesi olan 10 seviyesini optimize etmiştir. Bu model, Model 2 ile aynı R^2 değerine (0,828) sahip olup, en düşük OMH, OKH ve KOKH değerleriyle genelleme yeteneğini en iyi şekilde koruyan model olmuştur. Bu durum, karma modelin (Model 6) genelleme yeteneğini optimize etme ve aşırı öğrenme riskini minimize etme amacıyla en uygun derinliği seçtiğini ve bu seçimin 10 seviyeli derinlik ile örtüştüğünü göstermektedir. Karar ağacı modelleri arasında, 10 seviyeli derinliğe sahip Model 2 ve Model 6, en iyi performansı sergileyen ve genelleme yeteneğini en iyi şekilde koruyan modeller olarak öne çıkmıştır. Bu modeller, verinin yeterince iyi öğrenilmesi ve aynı zamanda genelleme yeteneğinin korunması için optimum dengeyi sağlamaktadır. Buna karşın, daha düşük derinlikteki Model 1'in veriyi yetersiz öğrenmesi, daha yüksek derinliklerdeki Model 3, Model 4 ve Model 5'in ise aşırı öğrenme riskini artırarak genelleme yeteneğini düşürmesi, derinlik seçiminin model performansı üzerinde ne denli önemli olduğunu ortaya koymaktadır. Bu bulgular, modelin karmaşıklığını artırırken, genelleme yeteneğinin korunmasının kritik olduğunu ve bu dengenin en iyi Model 2 ve Model 6 tarafından sağlandığını göstermektedir. Elde edilen sonuçlar incelendiğinde; derinliğin artması her zaman performans iyileşmesiyle sonuçlanmadığından, modelin veri setine en uygun hale getirilmesi için çeşitli derinlik seviyelerinin dikkatlice test edilmesi gerekliliği gözler önüne serilmiştir.

Hazırlanan çalışmanın gerçek hayat uygulamalarında farklı problemleri çözmek amacıyla kullanılmaya devam edebilmesi için, standart süre hesaplarında kullanılmak üzere farklı derinliklerde elde edilen en iyi sonuçları sağlayan Model 6 tercih edilmiştir. Geliştirilen karar ağacı modeli ile ilgili örnek gösterim Şekil 5.4'teki gibidir.



Şekil 5.4. Geliştirilen karar ağacı modeli yapısı

5.6.1. Karar ağacı uygulama sonuçları

Geliştirilen karar ağacı modelinin (Model 6) performansı, çalışma için seçilen performans metrikleri Alt bölüm 5.2 Eş. 5.1 – Eş. 5.4 çerçevesinde değerlendirilmiş ve elde edilen sonuçlar Çizelge 5.12’de sunulmuştur.

Çizelge 5.12. Seçilen modelin performans sonuçları

OMH	OKH	KOKH	R ²
0,548	0,694	0,833	0,828

Karar ağacı performans sonuçlarının test ve eğitim verilerinin kıyaslanması amacıyla elde edilen sonuçlar ise Çizelge 5.13’te belirtilmiştir.

Çizelge 5.13. Karar ağacı test ve eğitim verileri performans değerleri kıyaslaması

Veri Tipi / Performans Kriterleri	OMH	OKH	KOKH	R ²
Test Verileri	0,548	0,694	0,833	0,828
Eğitim Verileri	0,364	0,267	0,517	0,928

Çizelge 5.13'te sunulmakta olan sonuçlara dayanarak, eğitim veri seti hesaplamalarında oldukça yüksek bir R^2 değeri (0,928) elde edilmiştir. Bu durum modelin eğitim verisindeki varyansın %92,8'ini açıkladığını gösterir. Test veri seti hesaplamalarında ise R^2 değeri (0,828) daha düşük bulunmuş olmakla birlikte yine de Altbölüm 5.4'te sunulan alan yazın çalışmalarına göre kabul edilebilir seviyede yüksek bir değere ulaşılmıştır (Türkan ve diğerleri, 2023). Bu durum, modelin test verisindeki varyansın %82,8'ini açıkladığını göstermektedir. Eğitim ve test verileri arasındaki performans farkı nispeten düşük olduğundan, modelin aşırı öğrenme eğiliminde olmadığını görülmektedir. Eğitim verisindeki OMH, OKH ve KOKH değerleri sırasıyla 0,364; 0,267 ve 0,517'dir. Bu düşük hata değerleri, modelin eğitim verisinde oldukça iyi performans gösterdiğini gösterir. Test verisindeki OMH, OKH ve KOKH değerleri ise sırasıyla 0,548; 0,694 ve 0,833'tür. Bu değerler eğitim verisine göre biraz daha yüksek olmasına rağmen, kabul edilebilir seviyededir. Kurulan model, eğitim ve test verileri üzerinde iyi bir performans sergilemiştir. Eğitim ve test verisi arasındaki performans farkı, modelin biraz fazla uyum sağladığını gösterse de bu fark önemli düzeyde değildir ve modelin aşırı öğrenme eğiliminde olmadığını göstermektedir. Modelin tahmin performansları, uygun düzeydedir ve güvenilir sonuçlar sunmaktadır.

5.7. Bulgular ve Tartışma

Tez çalışması kapsamında ele alınan ürün ailesi için standart sürelerin tahminine yönelik geliştirilen modellerin performans sonuçları derlenerek model tahmin performanslarının karşılaştırılmasında kolaylık sağlamak amacıyla sonuçlar aşağıdaki Çizelge 5.14'te verilmiştir.

Çizelge 5.14. DVM, YSA, karar ağaçları ve regresyon modelleri performans değerleri kıyaslaması

Model / Performans Metrikleri	OMH	OKH	KOKH	R^2
Polinom regresyon modeli	0,631	0,808	0,899	0,799
Doğrusal regresyon modeli	0,610	0,721	0,849	0,821
DVM	0,542	0,559	0,748	0,861
YSA	0,542	0,610	0,781	0,849
Karar ağacı	0,548	0,694	0,833	0,828

DVM, R^2 değeri 0,861 olup, bu değer DVM modelinin eğitim verisindeki varyansın %86,1'ini açıkladığını göstermektedir. OMH, OKH ve KOKH değerleri de standart süre hesaplamalarında kullanılmış olan diğer tüm yöntemlere ilişkin oluşturulan modellere kıyasla düşük seviyelerdedir, bu da DVM'nin test verisi üzerindeki genel tahmin performansının da yüksek olduğuna işaret etmektedir. YSA modeli, DVM ile benzer OMH değerine (0,542) sahip olmasına rağmen, bu model sonuçları ile hesaplanan OKH (0,610) ve KOKH (0,781) değerleri biraz daha yüksektir. Çizelge 5.14'te görüldüğü gibi hesaplanan R^2 değeri 0,849 olan YSA modeli, eğitim verisindeki varyansın %84,9'unu açıklayabilmektedir ki, bu durum modelin genelleme yeteneğinin iyi olduğunu göstermektedir. Ancak, YSA'nın test verisi üzerindeki performansı DVM modeline kıyasla biraz daha düşüktür. Karar ağacı modeli, diğer iki modelden daha yüksek OMH (0,548), OKH (0,694) ve KOKH (0,833) değerlerine sahiptir. R^2 değeri 0,828 olan bu model, eğitim verisindeki varyansın %82,8'ini açıklayabilmektedir ve bu durum modelin genelleme yeteneğinin diğer iki modele kıyasla biraz daha düşük olduğunu göstermektedir. Ancak, karar ağacı modeli de kabul edilebilir bir performans sergilemiştir. Doğrusal regresyon modeli ise, diğer modellere kıyasla yüksek OMH (0,610), OKH (0,721) ve KOKH (0,849) değerlerine sahiptir. Ancak hesaplanan R^2 değeri 0,821 olup, bu modelin eğitim verisindeki varyansın yalnızca %82,1'ini açıkladığını göstermektedir. Polinom regresyon modelinde gerek OMH (0,631), OKH (0,808), KOKH (0,899) gerekse R^2 değeri açısından tüm modellere nazaran en düşük performans sonuçları elde edilmiştir. Bu sonuç, polinom regresyon modelinin, tüm modellere kıyasla veriyi açıklayamadığını ve genelleme yeteneğinin de zayıf kaldığını göstermektedir. Bu durum, doğrusal ve polinom regresyon modellerinin genelleme yeteneğinin DVM, YSA ve karar ağaçları modellerine kıyasla daha zayıf olduğunu ortaya koymaktadır. Ayrıca, regresyon modellerinin performansı diğer modellere kıyasla; daha düşük olup, özellikle test verisi üzerindeki performansı tatmin edici düzeyde değildir.

Bu değerlendirmeler ışığında tez çalışmasında incelenen gerçek hayat örneğinde de görüldüğü üzere; makine öğrenmesi temelli yöntemler, veri işleme ve kullanılabilir sonuçlar üretme konusunda geleneksel yöntemlere göre daha etkilidir. Bu çalışmada, DVM, karar ağacı ve YSA modellerinin yüksek performansı, özellikle tahmin çalışmalarında makine öğrenmesi yöntemlerinin geleneksel yöntemlere kıyasla üstün performans sergilediğini ve gerçek dünya uygulamalarında daha güvenilir sonuçlar üretebildiğini ortaya koyarak, standart süre tespitine dair yapılan araştırmalara da ayrıca önemli bir katkı sağlamaktadır.

Geliştirilen modeller ve yapılan hesaplamalar sonucunda elde edilen standart süreler ve bu çıktılarına dair hesaplama performans ölçüt değerleri farklı makine öğrenme algoritmalarının ele alınan problem verileri için standart süre hesabında uygulanmasının etkinlik ve güvenilirliğinin karşılaştırmalı analiz edilmesi açısından da incelenmiştir. Bu bağlamda, DVM algoritmasının diğer modellere göre daha üstün bir performans sergilediği söylenebilmektedir (Bkz. Çizelge 5.14). Ancak, her üç model de belirli düzeylerin üzerinde (geleneksel modellerden daha yüksek) başarılı tahminler yapabilmektedir ve genelleme yetenekleri kabul edilebilir seviyededir. Gelecek çalışmalarda, bu modellerin performanslarını artırmak için hiperparametre optimizasyonu ve veri setinin genişletilmesi gibi teknikler kullanılabilir.

DVM modelinin genel performansı iyi görünse de test verisi üzerindeki performansın daha da iyileştirilmesi için aşağıdaki öneriler ilerideki çalışmalarda göz önünde tutulabilir. Bu öneriler doğrultusunda modelin performansı daha dengeli hale getirilebilir ve genelleme riski minimize edilebilir.

- Veri setinin boyutunu ve çeşitliliğini artırarak modelin genelleme kabiliyetini artırmak mümkün olabilir.
- Modelin aşırı öğrenme yapmasını önlemek için düzenleme (regularization) teknikleri kullanılabilir. Örneğin, ‘C’ parametresinin değerleri ile daha farklı kombinasyonlar uygulanabilir.
- Modelin farklı veri setleri üzerindeki performansını değerlendirmek için çapraz doğrulama teknikleri kullanılabilir.

Gerçekleştirilen çalışma neticesinde, yüksek güvenilirlik oranları ile belirlenen standart zamanlar sayesinde, müşterilerden siparişleri topluca aktarılan ürünlerin taahhüt edilen tarihlerde teslim edilebilmesi amacıyla kapasite planlarının gerçekçi hazırlanmasını ve doğru üretim planı yapılmasını sağlayacak araçlar geliştirilmiştir. Bu sayede müşteri hat duruşlarının önüne geçilecektir.

6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında parça karmaşıklığı, insan gücüne bağımlılığı ve parça çeşitliliğinin yüksek olması nedeniyle uzun ölçüm süreleri gerektiren, değişken sipariş zamanlı ve uzun çevrim süreli bir üretim sürecinde gözlemlenen üretim planlama verimliliği problemi ele alınmış, standart sürelerin doğru belirlenmesi ile verimlilik oranlarında hedeflenen iyileştirmesinin gerçekleştirilmesi amaçlanmıştır. Üretim sistemi, süreçleri ve parça özellikleri nedeni ile standart sürenin tespitinde doğrudan iş ölçüm tekniklerinin uygulanamadığı ve kesin standart zamanın belirlenemediği tespit edilmiştir. Bu durum, verimlilik ölçümlerinin doğru sonuçlar vermemesine ve üretim planlama faaliyetlerinin başarı oranlarının düşük olmasına yol açmaktadır. İş sisteminin dolaysız iş ölçümü yöntemleri kullanılarak sürelerin belirlenmesine izin vermemesi nedeniyle, dolaylı iş ölçümü tekniklerinden tahmin ve karşılaştırma yöntemi kullanılmış, hesaplamalar hem geleneksel tahmin yöntemlerinden doğrusal regresyon modeli kullanılarak, hem de derin literatür araştırmaları ve veri seti analizleri sonucunda belirlenen farklı makine öğrenmesi algoritmaları ile yürütülmüştür.

Doğrusal regresyon modeli tasarımında, 443 adet veri kullanılmış olup, bu verilerin 355 adeti modeli eğitmek, 88'i ise modeli test etmek amacıyla kullanılmıştır. Modelin, R^2 ölçütüyle değerlendirilen performansı %82,1 doğruluk seviyesinde tespit edilmiştir.

Polinom regresyon modeli tasarımında, 443 adet veri kullanılmış olup, bu verilerin 355 adeti modeli eğitmek, 88'i ise modeli test etmek amacıyla kullanılmıştır. Modelin, R^2 ölçütüyle değerlendirilen performansı %79,9 doğruluk seviyesinde tespit edilmiştir.

YSA tasarımında, 443 adet veri kullanılmış olup, bu verilerin 355 adeti ağı eğitmek, 88'i modeli test etmek amacıyla kullanılmıştır. Tasarlanan ağ; toplam 56 nöronlu 3 gizli katmandan oluşmaktadır ve optimizasyon algoritması 1500 iterasyonda koşulmuştur. Modelin, R^2 ölçütüyle değerlendirilen performansı %84,9 doğruluk seviyesinde tespit edilmiştir.

DVM tasarımında, 443 adet veri kullanılmış olup, bu verilerin 355 adeti modeli eğitmek, 88'i ise modeli test etmek amacıyla kullanılmıştır. Modelin hiperparametre optimizasyonu

için GridSearchCV kullanılarak en iyi parametreler belirlenmiştir. Kullanılan parametreler arasında C (0,1; 1; 10; 100), epsilon (0,01; 0,1; 0,2; 0,5) ve kernel (*rbf*, *linear*) yer almaktadır. En iyi parametreler belirlendikten sonra, model bu parametrelerle eğitilmiştir. Modelin, R^2 ölçütüyle değerlendirilen performansı %86,1 doğruluk seviyesinde tespit edilmiştir.

Karar ağacı tasarımında, 443 adet veri kullanılmış olup, bu verilerin 355 adeti modeli eğitmek, 88'i ise modeli test etmek amacıyla kullanılmıştır. Modelin hiperparametre optimizasyonu için GridSearchCV kullanılarak en iyi parametreler belirlenmiştir. Kullanılan parametreler arasında maksimum özellikler için karekök, log2 ve hiçbir (None) değerleri; maksimum derinlik için 10, 20, 30 ve sonsuz değerleri; minimum örnek bölme sayısı için 2, 5 ve 10 değerleri ve minimum yaprak örnek sayısı için 1, 2 ve 4 değerleri yer almıştır. En iyi parametreler belirlendikten sonra, model bu parametrelerle eğitilmiştir. Modelin, R^2 ölçütüyle değerlendirilen performansı %82,8 olarak tespit edilmiştir.

Bu çalışmada kullanılan modeller dışında, diğer makine öğrenmesi algoritmalarının da incelenmesi yararlı olabilir. Örneğin, Rastgele Ormanlar (Random Forest), Gradyan Artırma (Gradient Boosting) ve XGBoost gibi daha kompleks algoritmaların kullanımı, model performansını artırabilir. Model performansını iyileştirmek amacıyla mevcut parametrelerin yanı sıra ek parametreler de dikkate alınabilir. Hiperparametre optimizasyonunun daha geniş bir parametre aralığı ile yapılması, modelin performansının optimize edilmesine olanak tanır.

Kullanılan veri setinin boyutu ve çeşitliliği, modelin genelleme kabiliyetini önemli ölçüde etkilemektedir. Daha büyük ve daha çeşitli veri setleri kullanarak modelin performansı artırılabilir. Ayrıca, veri setine yeni özellikler eklenerek modelin tahmin gücü artırılabilir. Modelin geçerliliğini ve güvenilirliğini artırmak için, yapılan tahminlerin gerçek hayat verileri ve geleneksel tahmin yöntemleri ile karşılaştırılması önemlidir. Bu karşılaştırmalar, modelin gerçek dünyada ne kadar başarılı olduğunu ortaya koyabilir ve modelin güvenilirliğini ispat edebilir. Ayrıca, gerçek ölçümler ve hesaplama değerleri arasındaki farkların İnsan Faktörleri ve Ergonomi verileri de gözetilerek nasıl değiştiği incelenebilir. Bu analizler, modelin pratikteki geçerliliğini ve kullanım alanını genişletebilir.

Modelin performansını daha güvenilir bir şekilde değerlendirmek için çapraz doğrulama (cross-validation) teknikleri kullanılabilir. Ayrıca, modelin bağımsız test verileri üzerinde de değerlendirilmesi, genelleme yeteneğinin daha iyi anlaşılmasına yardımcı olabilir. Çalışmada kullanılan performans metriklerinin yanı sıra, farklı performans metrikleri de dikkate alınarak modelin başarısı daha kapsamlı bir şekilde değerlendirilebilir. Bu yaklaşım, modelin çeşitli açılardan incelenmesini ve daha derinlemesine bir performans analizi yapılmasını sağlar.

Bu kısıtlamalar ve öneriler doğrultusunda, çalışmanın kapsamı genişletilebilir ve elde edilen sonuçların geçerliliği artırılabilir. Gelecek çalışmalarda, bu noktalar dikkate alınarak daha kapsamlı ve güvenilir modeller oluşturulabilir.

Geliştirilen yöntemin, imalat süreçlerinde zaman tahmininin doğruluğunu ve verimliliğini artırabileceği üzerinde durulmuş, bu tekniklerin endüstriyel uygulamalarda işletmelerin planlama ve kaynak yönetimindeki etkinliğini artırabileceği öngörülmüştür. Ayrıca, geliştirilen makine öğrenmesi modellerinin firma tarafından kullanılan Kurumsal Kaynak Planlaması (Enterprise Resource Planning - ERP) sistemine entegre edilmesi durumunda, doğru parametrelerin girilmesiyle zaman tahminlerinin otomatik olarak güncellenebileceği, ERP sistemi entegrasyonu ile üretim süreçlerindeki değişikliklerin hızlı bir şekilde değerlendirilebileceği ve güncel verilere dayalı tahminlerin yapılabilmesi, bu sayede iş süreçlerine büyük katkı sağlayabileceği vurgulanmıştır.

Bu çalışma ile hiçbir ek maliyet getirecek yatırım yapılmadan, parça üretim sürelerini dakikalar içerisinde belirleyecek bir sistem kurulmuştur. Bu sayede, her yıl firma bünyesine yeni katılan yaklaşık 200 çeşit parçanın geleneksel yöntemlerle belirlenmesi için gereken 6000 saatlik işçilik süresi, oluşturulan modeller aracılığıyla birkaç dakikaya indirilmiştir. Doğru standart sürenin hesaplanması ile üretim planlama ve kontrol süreçlerinde iyileştirmeler sağlanmıştır. Bu yöntemler hem süreçlerin hızlandırılmasına hem de üretim kapasitesinin doğru kullanılmasına katkıda bulunmuş, aşırı veya atıl iş yüklemesi yapılmasının önüne geçilmiştir.

Sonuç olarak, bu çalışma, yatırım gerektirmeyen çözümlerle büyük ölçüde doğru planlama yapılabilmesi için kapasitenin etkin kullanımını sağlayacak standart sürelerin yüksek

doğruluk oranlarında belirlenebileceğini göstermekte ve bu alanda literatüre değerli bir katkı sunmaktadır.

KAYNAKLAR

- Acı, M. ve Doğanşoy, G.A. (2022). Demand Forecasting for e-Retail Sector Using Machine Learning and Deep Learning Methods. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (3): 1325-1339.
- Akıncı, E. (2008). *Bir Tersanenin Üretim Planlamasının Hazırlanması*, Yayınlanmış Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Akpınar, H. (2000). Veri Tabanlarında Bilgi Keşfi ve Veri Madenciliği. *İ.Ü. İşletme Fakültesi Dergisi*, 29(1), 1-22.
- Akşehirli, Y. Ö., Ankaralı, H., Aydın, D. ve Saraçlı, Ö. (2013). Tıbbi Tahminde Alternatif Bir Yaklaşım Destek Vektör Makineleri. *Türkiye Klinikleri Journal of Biostatistics Biostat*, 5(1), 19-28.
- Akteke, O. (2023). *İlaç Endüstrisinde Yapay Sinir Ağları ile Talep Tahmini Uygulaması*, Yayınlanmış Yüksek Lisans Tezi, İstanbul Üniversitesi Cerrahpaşa Lisansüstü Eğitim Enstitüsü, İstanbul.
- Al Banna, M. H., Taher, K. A., Kaiser, M. S., Mahmud, M., Rahman, M. S., Hosen, A. S. and Cho, G. H. (2020). Application of Artificial Intelligence in Predicting Earthquakes: State-Of-The-Art and Future Challenges. *IEEE Access*, 192880-192923.
- Alexander, D. L. J., Tropsha, A., & Winkler, D. A. (2015). Beware of R²: Simple, unambiguous assessment of the prediction accuracy of QSAR and QSPR models. *Journal of Chemical Information and Modeling*, 55(7), 1316-1322.
- Altın, S. Ş. (2011). *Benzer Süreçlerde Üretilen Ürünler İçin Yapay Zeka ile Zaman Tahmini*. Yayınlanmış Yüksek Lisans Tezi, Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Altıntaş, Y. (2010). *Veri Madenciliğinin Tıpta Kullanımı ve Bir Uygulama: Hemodiyaliz Hastaları İçin Risk Seviyelerine Göre Risk Faktörlerinin Etkileşimlerinin İncelemesi*, Yayınlanmış Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Alzubi, J., Nayyar, A. and Kumar, A. (2018). Machine Learning from Theory to Algorithms: An Overview. *Journal of Physics: Conference Series*, 11(42), 1-15.
- Aras, A. A. (2005). *Sürdürülebilir Süreç Yönetimi* (1. Baskı). İstanbul: KALDER, 8.
- Atalay, M. (2015). *Zaman Serilerinde Yapay Sinir Ağları ve Bulanık Mantığa Dayalı Tahmin ve Bir Uygulama*, Yayınlanmış Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Atalay, M. ve Çelik, E. (2017). Büyük Veri Analizinde Yapay Zeka ve Makine Öğrenmesi Uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.

- Atasoy, D. (2001). *Lojistik regresyon analizinin incelenmesi ve bir uygulaması*, Yayınlanmış Yüksek Lisans Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.
- Atasoy, D. (2023). *Optimizasyon ve Regresyon Modelleri ile Meteorolojik Tahminleme Denemesi*, Yayınlanmış Doktora Tezi, Iğdır Üniversitesi Lisansüstü Eğitim Enstitüsü, Iğdır.
- Atıgan, F. (2011). *Yönetim ve Organizasyon* (1. Baskı). Ankara: Nobel Yayın Dağıtım Tic. Ltd. Şti., Ocak 2011, 25.
- Aydın, O. F. (2007). *Süreç İyileştirmede Bilgi Yönetimi Uygulamalarının Kullanılması Üzerine Bir Vaka Analizi*, Yayınlanmış Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Aydın, S. ve Özkul, A. E. (2015). Veri Madenciliği ve Anadolu Üniversitesi Açıköğretim Sisteminde Bir Uygulama. *Eğitim ve Öğretim Araştırmaları Dergisi*, 4(3), 38.
- Ayhan, S. ve Erdoğan, Ş. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyon Seçimi. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 9(1), 175-198.
- Bates, D. M., & Watts, D. G. (1988). *Nonlinear Regression Analysis and Its Applications* (First Edition). New York: John Wiley, 32-66.
- Ben-Hur, A., Ong, C. S., Sonnenburg, S., Schölkopf, B. and Rätsch, G. (2008). Support Vector Machines and Kernels For Computational Biology. *PLoS Computational Biology*, 4(10).
- Bezirci, G. (2006). *Hizmet İşletmelerinde Süreç İyileştirme ve Bir Uygulama*, Yayınlanmış Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning* (First Edition). New York: Springer, 3.
- Bonaccorso, G. (2017). *Machine Learning Algorithms* (First Edition). Birmingham: Packt Publishing Ltd., 9.
- Bozkurt, R. (2002). *Süreç İyileştirme* (1. Baskı). Ankara: MPM Yayınları No:661, 18.
- Breiman, L., Friedman, J., Olshen, R. and Stone, C. (1984). *Classification and Regression Trees* (First Edition). New York: Wadsworth.
- Brown, S. (1994). The Role of Work Study in TQM. *The TQM Magazine*, 6(3), 9-15.
- Certo, C. (2003). *Modern Management-Adding Digital Focus* (Ninth Edition). New Jersey: Prentice Hall, 31.

- Chang, L. Y., Wang and H. W. (2006). Analysis Of Traffic Injury: An Application Of Non-Parametric Classification Tree Techniques. *Accident Analysis Prevention*, 38, 1019-1027.
- Chen, Y. R., Rezapour, A., ve Tzeng, W. G. (2018). Privacy-preserving ridge regression on distributed data. *Information Sciences*, 451, 34-49.
- Cho, B. H., Yu, H., Lee, J., Chee, Y. J., Kim, I. Y. and Kim, S. I. (2008). Nonlinear Support Vector Machine Visualization For Risk Factor Analysis Using Nomograms and Localized Radial Basis Function Kernels. *IEEE Transactions on Information Technology in Biomedicine*, 12(2), 247-256.
- Cılasun, H., & Yalçın, H. (2016, 16-19 May). *A deep learning approach to EEG based epilepsy seizure determination*. 24th Signal Processing and Communication Application Conference (SIU), Zonguldak.
- Cortes, C. and Vapnik, V. (1995). Support-Vector Networks. *Machine learning*, 20(3), 273-297.
- Çakıt, E. and Dağdeviren, M. (2023). Comparative Analysis of Machine Learning Algorithms for Predicting Standard Time in A Manufacturing Environment. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, pp. 1-12.
- Çam, K. (2021). *Küçük ve Orta Ölçekli Firmalar İçin Makine Öğrenmesi Destekli Karar Destek Sistemi*, Yayınlanmış Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, Samsun.
- Çelikoğlu, C. C. (1989). *Zaman Etüdünde Yeterlilik Problemine Bir Yaklaşım*, Yayınlanmış Doktora Tezi, Anadolu Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir.
- Çınar, A. (2019). Veri Madenciliğinde Sınıflandırma Algoritmalarının Performans Değerlendirmesi ve R Dili ile Bir Uygulama. *Öneri Dergisi*, 14(51), 90-111.
- Çınar, C., & Esatoğlu, A. E. (2024). Productivity Improvement in Pathology Laboratories Using Motion and Time Study Techniques. *Turkish Journal of Pathology*, 40(1), 27-36.
- Çomak, E. (2008). *Destek Vektör Makinelerinin Etkin Eğitimi için Yeni Yaklaşımlar*, Yayınlanmış Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Dağdeviren, M., Eraslan, E. and Çelebi, F. V. (2011). An Alternative Work Measurement Method and Its Application to a Manufacturing Industry. *Journal of Loss Prevention in the Process Industries*, 24(5), 563-567.
- De Bruin, T., & Rosemann, M. (2005, 26-28 Mayıs). *Towards a Business Process Management Maturity Model*. ECIS 2005 Proceeding of the 13th European Conference on Information Systems, Regensburg.
- Demir, H. ve Gümüsoğlu, Ş. (2003). *Üretim Yönetimi* (6. Baskı). İstanbul: Beta Yayınları, 445.

- Demirdöğen, O. ve Güzel, D. (2009). Üretim Planlama ve İş Yükleme Metotları. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 23(4), 43-59.
- Dey, S., Mandal, S. K., & Bhar, C. (2022). Application of MR and ANN in The Prediction of The Shovel Cycle Time, Thereby Improving the Performance of The Shovel-Dumper Operation: A Case Study. *Journal of the Southern African Institute of Mining and Metallurgy*, 122(10), 597-606.
- Eraslan, E. (2009). The Estimation of Product Standard Time by Artificial Neural Networks in the Molding Industry. *Mathematical Problems in Engineering*, 1-12.
- Eren, E. (2011). *Yönetim ve Organizasyon (Çağdaş ve Küresel Yaklaşımlar)* (10. Baskı). İstanbul: Beta Basım A.Ş., 24.
- Ersoy, E. ve Karal, Ö. (2012). Yapay Sinir Ağları ve İnsan Beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 188-205.
- Eser, P. (2018). *Tedarik Zinciri Yönetiminde Süreç Yönetimi ve Süreç İyileştirmesi Üzerine Uygulama*, Yayınlanmış Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, İzmir.
- Eyüpoğlu, F. (2012). *Süreç Yönetimi ve Süreç İyileştirme* (2. Baskı). İstanbul: Sistem Yayıncılık, 32.
- Ezcan, V., Işıkdag, Ü., & Kuruoğlu, M. (2011, 2-4 Şubat). *İnşaat Sektöründe Süreç Yönetimi*. XIII. Akademik Bilişim Konferansı, İnönü Üniversitesi, Malatya.
- Fantoni, G., Al-Zubaidi, S. Q., Coli, E., & Mazzei, D. (2021). Automating The Process of Method-Time-Measurement. *International Journal of Productivity and Performance Management*, 70(4), 958-982.
- Fatima, M. and Pasha, M. (2017). Survey of Machine Learning Algorithms for Disease Diagnostic. *Journal of intelligent Learning Systems and Applications*, 9, 1-16.
- Fradkov, A. L. (2020). Early History of Machine Learning. *Institute for Problems in Mechanical Engineering Russian Academy of Sciences*, 1385-1390.
- Fu, X., Wu, X. and Liu, N. (2021). Statistical Machine Learning Model for Uncertainty Planning of Distributed Renewable Energy Sources in Distribution Networks. *Frontiers in Energy Research*, 9, 820254.
- Gartner, T. (2008). *Kernels for structured data*. (First Edition). Danvers: World Scientific Publishing, 59.
- Ghafoorpoor Yazdi, P., Azizi, A. and Hashemipour, M. (2018). An Empirical Investigation of the Relationship between Overall Equipment Efficiency (OEE) and Manufacturing Sustainability in Industry 4.0 with Time Study Approach. *Sustainability*, 10(9), 3031.

- Gisondo, C., Lawrence, C., Cham, P., Weiner, G., Vartanian, R. J., & Ellsworth, L. (2022). An Observational Time Study of Neonatal Intensive Care Unit Multidisciplinary Rounds. *American Journal of Perinatology*, 41(Suppl 01), e689-e693.
- Groover, M. P. (2007). *Work Systems: The Methods, Measurement and Management of Work* (First Edition). London: Pearson Education Limited, 57, 58.
- Gudlin, M., Hegedic, M., Golec, M., & Kolar, D. (2024). Improving Time Study Methods Using Deep Learning-Based Action Segmentation Models. *Applied Sciences-Basel*, 14(3).
- Güçlü, N. (2003). Stratejik Yönetim. G.Ü. *Gazi Eğitim Fakültesi Dergisi*, 23(2), 61-85.
- Gülpınar, V. (2008). *Avrupa Birliği Ülkeleri ile Türkiye'nin Ekonomik Göstergelerinin Karar Ağacı Yöntemi ile Karşılaştırılması*, Yayımlanmamış Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Gültepe, Y. (2019). Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 8-15.
- Güner, M., Küçük, M. ve Acar, E. (2016). Üniversite Öğrencilerinin Ders Esnasındaki Davranışlarının İş Örneklemesi Yöntemiyle Değerlendirilmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 15-22.
- Güneren, H. (2015). *Destek Vektör Makineleri Kullanarak Gömülü Sistem Üzerinde Yüz Tanıma Uygulaması*, Yayımlanmış Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Güran, A., Uysal, M. ve Doğrusöz, Ö. (2014). Destek Vektör Makineleri Parametre Optimizasyonunun Duygu Analizi Üzerindeki Etkisi. *Mühendislik Bilimleri Dergisi*, 16, 48-87.
- Gürüz, D. ve Gürel, E. (2009). *Yönetim ve Organizasyon-Bireyden Örgüte Fikirden Eyleme* (2. Baskı). Ankara: Nobel Yayın Dağıtım, 78.
- Hammer, M. and Champy, J. (1996). *Değişim Mühendisliği*. (Çev. S. Gül). İstanbul: Sabah Kitapları, 31.
- Hastie, T., Tibshirani, R. and Friedman, J. (2009). *The Elements of Statistical Learning – Data Mining Inference and Prediction* (Second Edition). Stanford: Springer, 485.
- Haykin, S. (2009). *Neural Networks and Learning Machines* (Third Edition). New Jersey: Pearson, 2, 48, 111.
- Hofmann, T., Schölkopf, B. and Smola, A. J. (2008). Kernel Methods In Machine Learning. *Annals of Statistics*, 36(3), 1171-1220.
- Hsu, C. W. and Lin, C. J. (2002). A Comparison of Methods For Multiclass Support Vector Machines. *IEEE Transactions on Neural Networks*, 13(2), 415-425.

- Huang, T., Kecman, V. and Kopriva, I. (2006). *Kernel Based Algorithms for Mining Huge Data Sets Supervised Semi-supervised and Unsupervised Learning*. Netherlands: Springer, 12.
- Ibrahim, I. M. and Abdulazeez, A. M. (2021). The Role of Machine Learning Algorithms for Diagnosing Diseases. *Journal of Applied Science and Technology Trends*, 2(1), 10-19.
- İnternet: Akdoğan, H. E. (2024). Yüksek Lisans Tez Verisetim. URL: <https://doi.org/10.5281/zenodo.13369684>, Son Erişim Tarihi: 27.08.2024.
- İnternet: Culkin, R. and Das, S. R. (2017). Machine Learning in Finance: The Case of Deep Learning for Option Pricing. URL: <https://srdas.github.io/Papers/BlackScholesNN.pdf>, Son Erişim Tarihi: 02.05.2024.
- İnternet: Çayiroğlu, İ. (2019). İleri Algoritma Analizi-5 Hafta Yapay Sinir Ağları. URL: https://www.academia.edu/18464282/Ileri_Algoritma_Analizi_5_Hafta_Yapay_Sinir_Aglari, Son Erişim Tarihi: 11.07.2024.
- İnternet: Doğan, S., Aslan, O., & Yıldırım, İ. S. (2017). Sözde Kod Oluştururken Öğrencilerin Zihinsel Süreçlerindeki Farklılıklar: Bilişsel Etnografi Çalışması. URL: <https://hdl.handle.net/11511/83993>, Son Erişim Tarihi: 21.07.2024.
- İnternet: Fletcher, T. (2008). Support Vector Machines Explained. URL: https://www.csd.uwo.ca/~xling/cs860/papers/SVM_Explained.pdf, Son Erişim Tarihi: 19.05.2024.
- İnternet: Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning* (MIT Press). URL: <http://www.deeplearningbook.org>, Son Erişim Tarihi: 21.07.2024.
- İnternet: Graves, C. S. (1999). Manufacturing Planning and Control. URL: http://www.ime.unicamp.br/~moretti/ms715/IS_2007/ProdPlanCh.pdf, Son Erişim Tarihi: 01.05.2024.
- İnternet: IBM (2020). Makine Öğrenmesi. URL: <https://www.ibm.com/tr-tr/cloud/learn/machine-learning>, Son Erişim Tarihi: 22.05.2024.
- İnternet: Jakkula, V. (2006). Tutorial On Support Vector Machine (SVM). URL: <https://course.ccs.neu.edu/cs5100f11/resources/jakkula.pdf>, Son Erişim Tarihi: 03.05.2024.
- İnternet: Karakuş, C. (2021). Makine Öğrenmesi Temelleri Ders Notu. URL: <https://ckk.com.tr/ders/ML/ML%20000%20Makine%20Öğrenmesi%20Giriş.html>, Son Erişim Tarihi: 16.06.2024.
- İnternet: Sökmen, P. (2023). Modern yönetim teorisi. URL: <https://slideplayer.biz.tr/slide/12180077/>, Son Erişim Tarihi: 10.07.2024.

- İnternet: Şahin, Z. (2023). Metot Zaman Ölçümü (MTM) Nedir? Çeyrek Mühendis. URL: <https://www.ceyrekmuhendis.com/metot-zaman-olcumu-mtm-nedir/>, Son Erişim Tarihi: 01.07.2024.
- İnternet: Üçüncü, K. (2015). END3009 İş Etüdü - 6. İş Ölçümü. URL: <https://avesis.ktu.edu.tr/resume/downloadfile/kucuncu?key=43bfd314-8f5e-41d7-bbca-ba067dad9a3d&announcementId=d527da74-c2f4-4e07-9421-7c9060ca9cbe>, Son Erişim Tarihi: 10.06.2024.
- İnternet: Wyatt, F. J. (2018). A brief history of process management to the modern day. On Business Process Management and Workflow Automation. URL: <https://medium.com/business-process-management-software-comparisons/a-brief-history-of-process-management-to-the-modern-day-2f90d12d8e99>, Son Erişim Tarihi: 14.06.2024.
- İnternet: Yalçın, M. (2019). Normal Dağılım ve Veri Bilimi'ndeki Yeri. URL: <https://medium.com/datarunner/normaldagilim-589846bb850a>, Son Erişim Tarihi: 12.06.2024.
- Janiesch, C., Zschech, P. and Heinrich, K. (2021). Machine Learning and Deep Learning. *Electronic Markets*, 31, 685-695.
- Jeong, J. H., Woo, J. H. and Park, J. G. (2020). Machine Learning Methodology for Management of Shipbuilding Master Data. *International Journal of Naval Architecture and Ocean Engineering*, 12, 428-439.
- Ji, J., Pannakkong, W., & Buddhakulsomsiri, J. (2022). A Computer Vision-Based Model for Automatic Motion Time Study. *Computers, Materials & Continua*, 30, 30418.
- Joung, J. and Kim, H. (2023). Interpretable machine learning-based approach for customer segmentation for new product development from online product reviews. *International Journal of Information Management*, 70, 102641.
- Kanawaty, G. (2018). *İş Etüdü*. (Çev. Z. Akal). Ankara: MPM Ankara, 185, 200, 201, 244.
- Karatzoglou, A., Smola, A., Hornik, K. and Zeileis, A. (2004). Kernlab an S4 package for kernel methods in R. *JSS Journal of Statistical Software*, 11, 15-9.
- Kavuncu, S. K. (2018). *Makine Öğrenmesi ve Derin Öğrenme: Nesne Tanıma Uygulaması*, Yayımlanmış Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.
- Kavzoğlu, T. ve Çölkesen, İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi*, 76, 73-82.
- Kaya, T. (2015). *Makine Öğrenme Yöntemleri ile Trafik Kazaları İçin Risk Tahmini Yapabilen Web Tabanlı Bir yazılım*, Yayımlanmış Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara.

- Keskenler, M. F. ve Keskenler, E. F. (2017). Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. *Takvim-i Vekayi*, 5(2), 8-18.
- Khalid, S. (2011). Productivity Improvement Of A Motor Vehicle Inspection Station Using Motion and Time Study Techniques. *Journal of King Saud University-Engineering Sciences*, 23, 33-41.
- Kılıç, Ş. ve Aydın, C. (2015). Sağlık Kurumlarında Süreç Yönetimi Uygulamaları. *İşletme Araştırmaları Dergisi*, 2(26), 143-172.
- Kıran, Z. (2010). *Lojistik Regresyon ve C&RT Analizi Yöntemleriyle Sosyal Güvenlik Kurumu İlaç Provizyon Sistemi Üzerinde Bir Uygulama*, Yayınlanmış Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Kiris, S. B., Eryarsoy, E., Zaim, S., & Delen, D. (2023). An Integrated Approach for Lean Production Using Simulation and Data Envelopment Analysis. *Annals of Operations Research*, 320(2), 863-886.
- Koçel, T. (2014). *İşletme Yöneticiliği* (15. Baskı). İstanbul: Beta Basım Yayım Dağıtım A.Ş., 243.
- Konuk, C. (2023). *İstatistiksel Kalite Kontrol Kartlarında Yapay Sinir Ağları ile Örüntü Tanıma*, Yayınlanmış Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Krenker, A., Bester, J., & Kos, A. (2011). *Artificial neural networks - Methodological advances and biomedical applications* (First Edition). Rijeka: Intech, 3-19.
- Kristiana, S. P. D., Asih, A. M. S., & Sudiarso, A. (2023). Designing Simulation to improve Production Efficiency of Batik Industry. *Simulation & Gaming*, 54(6), 730-759.
- Kumar, P. (2015). *Industrial Engineering and Management* (First Edition). Chennai and Delhi: Pearson India Education Services Pvt. Ltd, 213.
- Kumaş, Z., Sabır, E. C. ve Baykal, P. D. (2016). Konfeksiyon İşletmesinin Verimliliği için İş Etüdü Tekniği Kullanımı. *Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 31(1), 175-189.
- Kurt, M. ve Dağdeviren, M. (2020). *İş Etüdü* (1. Baskı). Ankara: Dünya Tıp Kitabevi, 17,18.
- Kuru, E. (2023). *Makine Öğrenmesi Algoritmalarıyla Gıda Sektöründe Karar Destek Sistemlerinin Oluşturulması*, Yayınlanmış Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, İzmir.
- Kutschenreiter-Praszkiewicz, I. (2020). Neural Network Application for Time Standards Setting in Assembly and Disassembly. *Journal of Machine Engineering*, 20(3), 106-116.

- Küçüksille, E. U. ve Ateş, N. (2013). Destek Vektör Makineleri ile Yaramaz Elektronik Postaların Filtrelenmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 6(1).
- Lampert, C. H. (2009). Kernel Methods In Computer Vision. *Foundations and Trends in Computer Graphics and Vision*, 4(3), 193-285.
- Lee, W. N., Lin, J. H., Howard, N. and Bao, S. P. (2023). Physiological Responses, Trunk Posture, And Work Pace in Commercial Building Cleaning in Washington State: An Observational Field Study. *Journal of Safety Research*, 86, 107-117.
- Lim, Z., Yusof, U. and Shamsudin, H. (2019, 19-21 November). *Manufacturing Lead Time Classification Using Support Vector Machine*. 6th International Visual Informatics Conference, Bangi.
- Lin, H. T. and Lin, C. J. (2003). A Study On Sigmoid Kernels For SVM and The Training Of Non-Psd Kernels By Smo-Type Methods. *Neural Computation*.
- Lindhard, S. M. (2023). Applying Work Measurements to Identify Productivity Potentials: The Case of Prefabricated Concrete Elements. *International Journal of Construction Management*.
- Lou, R., Lv, Z., Dang, S., Su, T. and Li, X. (2023). Application Of Machine Learning In Ocean Data. *Multimedia Systems* 29, 1-10.
- Luxburg, U. V., Schölkopf, B. (2011). *Handbook of the History of Logic* (First Edition). Oxford: Elsevier, 653.
- Madzarov, G., Gjorgjevikj, D. and Chorbev, I. (2008). A Multi-Class SVM Classifier Utilizing Binary Decision Tree. *Informatica*, 33, 225-233.
- Mahesh, B. (2018). Machine Learning Algorithms - A Review. *International Journal of Science and Research*, 381-386.
- Malik, Z. M. M., Al-Shehabi, S. ve Dökeroglu, T. (2018). Gözetimsiz makine öğrenme teknikleri ile miktara dayalı negatif birliktelik kural madenciliği. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6, 1119-1138.
- Marsland, S. (2014). *Machine Learning: An Algorithmic Perspective* (Second Edition). Florida: CRC Press, 1-430.
- Matijašević, T., Antić, T. and Capuder, T. (2022). A Systematic Review of Machine Learning Applications in The Operation of Smart Distribution Systems. *Energy Reports*, 8, 12379-12407.
- Mohri, M., Rostamizadeh, A. and Talwalkar, A. (2018). *Foundations of Machine Learning* (Second Edition). Cambridge: MIT Press, 1-488.

- Mohsen, O., Mohamed, Y., & Al-Hussein, M. (2022). A machine learning approach to predict production time using real-time RFID data in industrialized building construction. *Advanced Engineering Informatics*, 52, 101631.
- Murase, M., Fujita, H., Oki, M., Yoshioka, F., Nishiyama, Y., Ohyama, T., Matsumoto, C., Usui, S., Sato, Y., & Sado, T. (2024). Time-Study Research on Maxillofacial Prosthetic Treatment. *Japanese Dental Science Review*, 60, 73-80.
- Murray, J., Hiesl, P., Hagan, D., & Baldwin, R. (2023). Assessing Productivity and Cost of Timber Harvesting During Longleaf Pine Ecosystem Restoration. *International Journal of Forest Engineering*, 34(2), 117-129.
- Namir, K., Labriji, H. and Lahmar, E. H. B. (2022). Decision support tool for dynamic inventory management using machine learning, time series and combinatorial optimization. *Procedia Computer Science*, 198, 423-428.
- Nanda, M. A., Seminar, K. B., Nandika, D., & Maddu, A. (2018). A comparison study of kernel functions in the support vector machine and its application for termite detection. *Information*, 9(1), 3.
- Nortey, G., Koch, N., Chadwick, S. J., Lang, S., Parker, S., Farmer, F., Mandelkehr, L., Raynor, M., & Smith, A. (2023). Improving Staff Workflow in Urology Procedure Clinic Using the Model for Improvement. *Urology*, 177, 89-94.
- Of, M. ve Kılıçaslan, İ. (2020). Yönetim Düşüncesinin Tarihsel Gelişimi. *Journal of Social and Humanities Sciences Research*, 7(62), 3517-3527.
- Ojstersek, R., Javernik, A and Buchmeister, B. (2021). The Impact of the Collaborative Workplace On The Production System Capacity: Simulation Modelling vs. Real-World Application Approach. *Advances in Production Engineering & Management*, 16(4),
- Okur, H. (2020). *Makine Öğrenmesi Yöntemleriyle Kredi Riski Tahmini*, Yayımlanmış Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Onaran, E. and Yanık, S. (2019). Predicting cycle times in textile manufacturing using artificial neural network. In *Intelligent and fuzzy techniques in big data analytics and decision making* (pp. 305-312)
- Orhunbilge, N. (1996). *Uygulamalı regresyon ve korelasyon analizi* (1. Baskı). İstanbul: İstanbul Üniversitesi İşletme Fakültesi Yayını (Yayın No: 267), 11.
- Osisanwo, F. Y., Akinsola, J. E. T., Awodele, O., Hinmikaiye, J. O., Olakanmi, O., & Akinjobi, J. (2017). Supervised machine learning algorithms: classification and comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48(3), 128-138.
- Ostertagová, E. (2012). Modelling using polynomial regression. *Procedia Engineering*, 48, 500-506

- Ozili, P. K. (2023). The acceptable R-square in empirical modelling for social science research. *Social Research Methodology and Publishing Results*.
- Özarıcı, Ö. (1996). *Farklı Not Sistemlerinde Öğrencinin Başarılı Olma Olasılığının Probit Regresyon Analiziyle Değerlendirilmesi*, Yayınlanmış Yüksek Lisans Tezi, Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir.
- Özcan, B., Kumru, P. Y. ve Fırlalı, A. (2018). Forecasting operation times by using Artificial Intelligence. *International Advanced Researches and Engineering Journal*, 2(2), 109-116.
- Öztemel, E. (2006). *Yapay sinir ağları* (2. Baskı). İstanbul: Papatya Yayıncılık. 16, 29, 52, 53.
- Öztemel, E. (2020). Yapay zekâ ve insanlığın geleceği. *Bilişim teknolojileri ve iletişim: Birey ve toplum güvenliği*, 95-112.
- Öztürk, T. (2007). *Üretim Planlamasında Çok Hedefli Doğrusal Hedef Programlama ve Bir Tekstil İşletmesinde Uygulama*, Yayınlanmış Yüksek Lisans Tezi, Uludağ Üniversitesi Sosyal Bilimler Enstitüsü, Bursa.
- Palander, T., Pasi, A., Laurén, A. and Ovaskainen, H. (2024). Comparison of Cut-to-Length Harvesting Methods in Tree Plantations in Brazil. *Forests*, 15(4), 666.
- Pamir, T. C. (1984). *İş Etüdü* (1. Baskı). Ankara: SEGEM Yayınları, 93.
- Panch, T., Szolovits, P. and Atun, R. (2018). Artificial Intelligence Machine Learning and Health Systems. *Journal of Global Health*, 8(2), 1-8.
- Pedregosa, A., Prettenhofer, F., Thirion, P., Vanderplas, J., Varoquaux, G. and Weiss, R. (2011). Scikit-learn: Machine Learning In Python. *Journal Of Machine Learning Research*, 12, 2826-2830.
- Pehlivan, G. (2006). *CHAID Analizi ve Bir Uygulama*, Yayınlanmış Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Peimbert-García, R. E., Gutiérrez-Mendoza, L. M. and García-Reyes, H. (2021). Applying Lean Healthcare to Improve the Discharge Process in A Mexican Academic Medical Center. *Sustainability*, 13(19), 10911.
- Pérez-Cruz, F. and Bousquet, O. (2004). Kernel Methods and Their Potential Use In Signal Processing. *IEEE Signal Processing Magazine*, 21(3), 57-65.
- Pisner, D. A. and Schnyer, D. M. (2020). *Machine Learning* (First Edition). Austin: Academic Press. 101-121.
- Platt, J. C., Cristianini, N. and Shawe-Taylor, J. (2000). Large Margin Dags For Multiclass Classification. *Advances in Neural Information Processing Systems*, 547-553.

- Poje, A., Lipuzic, B., Bilobrk, I., & Pandur, Z. (2024). Time Composition, Efficiency, Workload, and Noise Exposure During Tree Felling and Processing With Petrol and Battery-Powered Chainsaws in Mixed High Forest Stands. *Forests*, 15(5), 798.
- Puvanasvaran, A. P., Mei, C. Z. and Alagendran, V. A. (2013). Overall Equipment Efficiency Improvement Using Time Study in an Aerospace Industry. *Procedia Engineering*, 68, 271-277.
- Qian, H., Mao, Y., Xiang, W. and Wang, Z. (2010). Recognition of Human Activities Using SVM Multi-Class Classifier. *Pattern Recognition Letters*, 31(2), 100-111.
- Rane, A. B., Sunnapwar, V. K., Chari, N. R., Sharma, M. R. and Jorapur, V. S. (2017). Improving Performance of Lock Assembly Line Using Lean and Simulation Approach. *International Journal of Business Performance Management*, 18(1), 101-124.
- Ranstam, J. ve Cook, J. A. (2018). LASSO regression. *Journal of British Surgery*, 105(10), 1348.
- Rizvanche, S. (2020). *Talep tahmininde makine öğrenmesi ve zaman serileri temelli bir karar destek sistemi*, Yayınlanmış yüksek lisans tezi, Eskişehir Teknik Üniversitesi, Eskişehir.
- Rodrigues, A., Silva, F., Sousa, V., Pinto, A., Ferreira, L. and Pereira, T. (2022). Using an Artificial Neural Network Approach to Predict Machining Time. *Metals*, 1-15.
- Rokach, L., & Maimon, O. (2008). *Data mining with decision trees - Theory and applications* (Second Edition). Singapore: World Scientific, 81.
- Salimgereyev, N., Mukhamediyev, B. and Shaikh, A. A. (2024). Measuring The Routine and Non-Routine Task Contents: A Comparative Study Between State and Industrial Sector Employees. *International Journal of Productivity and Performance Management*.
- Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 44(1), 210-229.
- Scholz, S. G., Howlett, R. J., & Setchi, R. (2021, 15-17 September). *Smart Innovation, Systems and Technologies*. 8th International Conference on Sustainable Design and Manufacturing, Split.
- Schweier, J., Werder, M., & Bont, L. G. (2024). Productivity and Cost Analysis of Cable Yarding Operations in Flat Terrain in The Canton of Aargau in Switzerland. *International Journal of Forest Engineering*, 1-16.
- Seifermann, S., Böllhoff, J., Metternich, J., & Bellagnach, A. (2014). Evaluation of Work Measurement Concepts for a Cellular Manufacturing Reference Line to Enable Low Cost Automation for Lean Machining. *Procedia CIRP*, 17, 588-593.

- Selek, İ. (2006). *Süreç Yönetiminin Başarısında Ekip Çalışmasının Etkisi ve Funika Tekstil A.Ş.'de Bir Uygulaması*, Yayımlanmış Yüksek Lisans Tezi, Anadolu Üniversitesi Sosyal Bilimler Enstitüsü, Eskişehir.
- Sengupta, A. K., Das, B., & Cyrus, J. P. (2010). Performance Improvement Analysis of a Supermarket Checkstand: A Computer Simulation Approach. *International Journal of Productivity and Performance Management*, 59, 37-50.
- Sezer, Ü. (2008). *Karar Ağaçlarının Birlikte Kuralları ile İyileştirilmesi*, Yayımlanmış Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- Shirzadi, A., Soliamani, K., Habibnejhad, M., Kavian, A., Chapi, K., Shahabi, H., Chen, W., Khosravi, K., Thai, P. B., Pradhan, B. and Tien Bui, D. (2018). Novel GIS Based Machine Learning Algorithms For Shallow Landslide Susceptibility Mapping. *Sensors*, 18, 3777.
- Siddiqui, T. A. and Abdullah, Y. (2015). Developing a Nonlinear Model To Predict Stock Prices In India: An Artificial Neural Networks Approach. *IUP Journal of Applied Finance*, 21(3), 36.
- Silahtaroglu, G. (2013). *Veri Madenciliği Kavram ve Algoritmaları* (2. Basım). İstanbul: Papatya Yayıncılık, 58, 59, 104.
- Smola, A. J., Schölkopf, B. and Müller, K. R. (1998). The Connection Between Regularization Operators and Support Vector Kernels. *Neural Network*, 11, 637-649.
- Song, H., Ding, Z., Guo, C., Li, Z. and Xia, H. (2008, 12 – 14 December). *Research On Combination Kernel Function Of Support Vector Machine*. International Conference on Computer Science and Software Engineering, Wuhan.
- Spinelli, R., Magagnotti, N., De Francesco, F., Kovác, B., Heger, P., Heilig, D., Heil, B., Kovács, G., & Zemánek, T. (2022). Cut-to-length Harvesting Options for the Integrated Harvesting of The European Industrial Poplar Plantations. *Forests*, 13(9), 1478.
- Susanto, S.J., Tanaya, P.I., & Soembagijo, A. (2012). Formulating standard product lead time at a textile factory using artificial neural networks. *2012 2nd International Conference on Uncertainty Reasoning and Knowledge Engineering*, 99-104.
- Sütçü, E. (2018). Kaynaklı İmalat Operasyon Sürelerinin Matlab Yapay Sinir Ağları ile Tahmin Edilmesi. *Gazi Mühendislik Bilimleri Dergisi*, 4(1), 16-24.
- Şahin, M., ve Efe, E. (2010). Kübik Spline Regresyonların Süt Sığırcılığında Laktasyon Eğrilerinin Modellenmesinde Kullanımı. *KSU Doğa Bilimleri Dergisi*, 13(2), 17-22.
- Şeker, A., Diri, B. ve Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3(3), 47-64.

- Thapaliya, S., Valilai, O. F., & Wicaksono, H. (2024). Power Consumption and Processing Time Estimation of CNC Machines Using Explainable Artificial Intelligence (XAI). *Procedia Computer Science*, 232, 861-870.
- Timur, H. (1984). *İş Ölçümü İş Planlaması Verimlilik: Kuramsal ve Örnek Uygulamalı* (1. Baskı). Ankara: Türkiye ve Ortadoğu Amme İdaresi Enstitüsü Yayınları, 25.
- Tunçbilek, O. (2019). *İş ve Zaman Etüdünün Verimliliğe Etkisi ve Bir Mobilya Fabrikasında Uygulamalı Çalışma*, Yayınlanmış Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta.
- Türe, M., Tokatlı, F. and Kurt, İ. (2009). Using Kaplan-Meier Analysis Together with Decision Tree Methods (C&RT CHAID QUEST C4.5 and ID3) In Determining Recurrence-Free Survival of Breast Cancer Patients. *Expert Systems with Applications*, 36, 2017-2026.
- Türkan, M., Bozdağ, A., Karkınlı, A. E., & Ulucan, A. G. (2023). Kent ölçeğinde konutlara ilişkin toplu değer değişiminin makine öğrenim algoritmaları ile analizi. *Türkiye Arazi Yönetimi Dergisi*, 5(2), 66-77.
- Türkmen, E. (2021). *Makine Öğrenmesi Yöntemleri ile Banka Pazarlama Tahmini*, Yayınlanmış Yüksek Lisans Tezi, İstanbul Kültür Üniversitesi Lisansüstü Eğitim Enstitüsü, İstanbul.
- Uçarsu, O. (2022). *Yapay Sinir Ağları Kullanarak Dolar Kuru Gelecek Değer Tahmini Yapılması*, Yayınlanmış Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- Ulusoy, G. (2013). *Karar Ağacı Analizi ile AB Genişleme Kriterlerinin Değerlendirilmesi*, Yayınlanmış Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Vapnik, V. N. (1999). An Overview of Statistical Learning Theory. *IEEE Transactions on Neural Networks*, 10(5).
- Vural, A. (2007). *Aykırı Değerlerin Regresyon Modellerine Etkileri ve Sağlam Kestiriciler*, Yayınlanmış Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Wierschem, D. C., Jimenez, J. A. and Mediavilla, F. A. M. (2020). A Motion Capture System for the Study of Human Manufacturing Repetitive Motions. *The International Journal of Advanced Manufacturing Technology*, 110(3), 813-827.
- Yıldız, N. ve Bircan, H. (1999). *İstatistiğe Giriş* (İkinci Baskı). Erzurum: Aktif Yayınevi, 218.
- Yamashiro, H., & Nonaka, H. (2024). Estimation of processing time using machine learning and real factory data for optimization of parallel machine scheduling problem. *Operations Research Perspectives*, 12, 102394.

- Yarnoff, B., Wagner, L., Honeycutt, A., & Vogt, T. (2021). Analysis of school-day disruption of administering school-located vaccination to children in three local areas, 2012–2013 school year. *The Journal of School Nursing*, 39, 105984052110385.
- Yelken, N. ve Demir, H. (1978). *Üretim Planlaması ve Kontrolü* (1. Baskı). İzmir: Ege Üniversitesi İşletme Fakültesi Yayınları, 38, 39.
- Yusoff, N., Jaffar, A., Abbas, N. M., & Saad, N. H. (2012). Work measurement for process improvement in the car seat polyurethane injection manufacturing line. *Procedia Engineering*, 41, 1800-1805.
- Zandin, K. B. (2001), *Maynard's Industrial Engineering Handbook* (Fifth Edition). New York: McGraw-Hill. 17-61.
- Zhang, G. and Ge, H. (2013). Support Vector Machine with a Pearson VII function Kernel for Discriminating Halophilic and Non-Halophilic Proteins. *Computational Biology and Chemistry*, 46, 16-22.
- Zhang, G., Patuwo, B.E and Hu, M.Y. (1998). Forecasting with artificial neural Networks: The state of art. *International Journal of Forecasting*, 14, 35-62.
- Zhong, R. Y., Huang, G. Q., & Dai, Q. (2013, June 19-21). *Mining Standard Operation Times for Real-time Advanced Production Planning and Scheduling from RFID-enabled Shopfloor Data*. 7th IFAC Conference on Manufacturing Modelling, Management, and Control, Saint Petersburg.



Gazili olmak ayrıcalıktır