



**T.C.
KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TORNALANMA İŞLEMİNDE KESME SICAKLIKLARININ
MAKİNE ÖĞRENMESİ YOLU İLE TAHMİN EDİLMESİ**

EBRU ADIYAMAN

MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**DANIŞMAN
Dr. Öğr. Üyesi Ali Osman ER**

KIRIKKALE-2024



**T.C.
KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TORNALANMA İŞLEMİNDE KESME SICAKLIKLARININ
MAKİNE ÖĞRENMESİ YOLU İLE TAHMİN EDİLMESİ**

EBRU ADIYAMAN

MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**DANIŞMAN
Dr. Öğr. Üyesi Ali Osman ER**

KIRIKKALE-2024

Ebru ADIYAMAN tarafından hazırlanan “TORNALANMA İŞLEMİNDE KESME SICAKLIKLARININ MAKİNE ÖĞRENMESİ YOLU İLE TAHMİN EDİLMESİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Ana Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Ali Osman ER

Makine Mühendisliği, Kırıkkale Üniversitesi

İmza:.....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Başkan: Prof. Dr. Yusuf USTA

Makine Mühendisliği, Gazi Üniversitesi

İmza:.....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Üye: Dr. Öğr. Üyesi Oğuz ERDEM

Makine Mühendisliği, Kırıkkale Üniversitesi

İmza:.....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi: 14/08/2024

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Recep ÇALIN

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYANI

Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

o Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,

o Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,

o Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,

o Kullanılan verilerde herhangi bir değişiklik yapmadığımı,

o Bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarımı kabullendiğimi beyan ederim.

İMZA

Ebru ADIYAMAN

14/ 08 /2024

ÖZET

TORNALANMA İŞLEMİNDE KESME SICAKLIKLARININ MAKİNE ÖĞRENMESİ YOLU İLE TAHMİN EDİLMESİ

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Makine Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Ali Osman ER

Ağustos 2024, 68 sayfa

İşlenmesi zor malzemelerden parça üretilmesinde karşılaşılan olumsuzluklar, talaşlı imalat gibi geleneksel işleme yöntemlerinde yeni arayışlara gidilmesine sebep olmuştur. İşlenmesi zor malzemeleri işleyebilmek ve üretimde verimliliği artırmak için yeni teknolojilerle üretilmiş ileri kesici takımlarla çalışılması, minimum miktarda yağlama ve kriyojenik soğutma gibi yeni tekniklerin kullanıldığı soğutma-yaglama sistemlerinin ve ön ısıtılmalı işleme gibi yöntemlerin kullanımı her geçen gün daha fazla tercih sebebi olmaktadır. Özellikle otonom sistemlerin, karanlık fabrikaların yer aldığı dijital imalat uygulamalarının giderek yaygınlaştığı görülmektedir. Önümüzdeki dönemlerde bu otomatik sistemlere entegre olarak çalışacak uygun işleme sıcaklığını tespit edecek, gerekirse ısıtma gerekirse soğutma-yaglama yapacak sistemler için veri alt yapısına ihtiyaç duyulacaktır. Bu çalışmada, malzemelerin talaşlı imalat yöntemleriyle işlenmesini kolaylaştırmak için kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklıklar makine öğrenmesi ile tahmin edilmiştir. Makine öğrenmesi için gerekli veri seti 16MnCr5 çeliği kullanılarak yapılan kuru tornalama deneyleri esnasında, en düşük kesme kuvveti değerlerinin ölçüldüğü deney parametreleri ile sıcaklık değerlerinden oluşmaktadır. Çalışmanın sonucunda, veri seti baz alınarak istenilen değerlerde kesme hızı, ilerleme hızı, kesme derinliği, malzeme ve kesici takım parametreleri modele girilerek, kesme bölgesindeki sıcaklık tahmin edilmiştir. Tahmin edilen sıcaklık ile işleme öncesinde uygun ortam koşulları

sađlanarak deneye bařlanacađı iin takım ve iř parası ařınmasının, kesme kuvvetinin, yzey pürzlölüđünün, kesme sıvısı tüketiminin azaltılması sađlanarak enerjiden, maliyetten ve zamandan tasarruf edilmiř olacaktır.

Anahtar kelimeler: Dijital imalat, talařlı imalat, tornalama, uygun iřleme sıcaklıđı, makine öđrenmesi.



ABSTRACT

PREDICTION OF CUTTING TEMPERATURES IN TURNING PROCESS BY MACHINE LEARNING

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Mechanical Engineering, Master's Thesis

Supervisor: Dr. Ali Osman ER

August 2024, 68 sayfa

The negativities encountered in the production of parts from difficult-to-machine materials have led to new researches in traditional machining methods such as machining. In order to process difficult-to-machine materials and increase efficiency in production, working with advanced cutting tools produced with new technologies, the use of cooling-lubrication systems using new techniques such as minimum amount of lubrication and cryogenic cooling, and methods such as preheated processing are increasingly preferred. In particular, it is seen that digital manufacturing applications involving autonomous systems and dark factories are becoming more and more common. In the coming periods, a data infrastructure will be needed for systems that will work in integration with these automatic systems, determine the appropriate processing temperature, heat if necessary, cooling-lubrication if necessary. In this study, the temperatures in the cutting zone, which minimizes the cutting force, were estimated by machine learning in order to facilitate the machining of materials with machining methods. The data set required for machine learning consists of the experiment parameters and temperature values in which the lowest shear force values are measured during dry turning experiments using 16MnCr5 steel. As a result of the study, the temperature in the cutting zone was estimated by entering the cutting speed, feed rate, cutting depth, material and cutting tool parameters into the model at the desired values based on the data set. Since the experiment will be started by providing suitable ambient conditions before machining with the estimated temperature, energy,

cost and time will be saved by reducing tool and workpiece wear, cutting force, surface roughness, and coolant consumption.

Keywords: Digital manufacturing, machining, turning, appropriate machining temperature, machine learning.



TEŐEKKÜR

Öncelikle bana bu tezi yazmayı nasip eden Rabbime Őükürler olsun. Gösterdiğim üstün çaba ve sabır için kendime çok teşekkür ederim.

Yüksek lisans tezimin hazırlanması boyunca maddi ve manevi yardımlarını esirgemeyen, bilimsel deney imkanlarını sonuna kadar bizlerin hizmetine sunan tez yöneticisi hocam, Sayın Dr. Öğr. Üyesi Ali Osman ER'e teşekkürlerimi sunarım.

Çalışmalarım süresince maddi ve manevi desteklerinden dolayı kıymetli anneme ve babama sevgi ve saygılarımı sunarım.



İÇİNDEKİLER

Sayfa

ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xi
TABLolar DİZİNİ.....	xiii
KISALTMALAR VE SİMGELER.....	xiv
1. GİRİŞ.....	1
2. LİTERATÜR ARAŞTIRMASI.....	5
3. KURAMSAL TEMELLER.....	18
3.1. Talaşlı İmalat.....	18
3.2. Tornalama.....	18
3.3. Yüzey Pürüzlülüğü.....	19
3.4. Takım Aşınması.....	19
3.5. Ön Isıtma Yöntemleri.....	20
3.5.1. İndüksiyonla Isıtma.....	20
3.5.2. TIG Tekniği.....	20
3.5.3. Elektrik Arkıyla Isıtma.....	21
3.5.4. Gaz Yakıcı Alevle Isıtma.....	21
3.5.5. Plazma Arkıyla Isıtma.....	21
3.5.6. Lazer Destekli İşleme.....	21
3.6. Makine Öğrenmesi (Machine Learning).....	22
3.6.1. Denetimli Öğrenme.....	23
3.6.1.1. Sınıflandırma.....	24
3.6.1.2. Regresyon.....	24
3.6.1.2.1. Karar Ağacı Regresyon (Decision Tree Regression).....	25
3.6.1.2.2. Rastgele Orman Regresyon (Random Forest Regression).....	25
3.6.2. Denetimsiz Öğrenme.....	26
3.6.3. Performans Metrikleri.....	27
4. MATERYAL VE YÖNTEM.....	29

4.1. İş Parçası.....	29
4.2. Takım Tezgâhı.....	30
4.3. Kesici Takım.....	32
4.4. Kesme Kuvvetlerinin Ölçülmesi.....	32
4.5. Sıcaklık Ölçümü.....	33
4.6. Deney Tasarımı.....	34
5. SONUÇLAR.....	36
5.1. Veri Seti.....	37
6. DEĞERLENDİRMELER VE ÖNERİLER.....	60
KAYNAKLAR.....	63
ÖZGEÇMİŞ.....	68



ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Takım tezgâhları genel durum.....	2
Şekil 3.1. Silindirik tornalama işlemi.....	19
Şekil 3.2. Makine öğrenmesi türleri ve ilgili kavramların Türkçe karşılıkları.....	23
Şekil 3.3. Denetimli öğrenme modelinin şematik gösterimi.....	24
Şekil 3.4. Sınıflandırma ve regresyon modellerinin şematik gösterimi.....	24
Şekil 3.5. Karar ağacı regresyon modelinin görselleştirilmesi.....	25
Şekil 3.6. Rastgele orman regresyon modelinin görselleştirilmesi ve ilgili kavramların Türkçe karşılıkları.....	26
Şekil 3.7. Denetimsiz öğrenme modelinin görselleştirilmesi.....	27
Şekil 4.1. 16MnCr5 iş malzemesi.....	29
Şekil 4.2. GOODWAY GLS 150 CNC torna tezgâhı.....	30
Şekil 4.3. Kater-Kesici uç.....	32
Şekil 4.4. Kistler dinamometre.....	32
Şekil 4.5. FLIR i50 termal kamera.....	33
Şekil 4.6. İşlenmiş yüzey ve termal kamera görüntüsü.....	35
Şekil 5.1. Kesme hızı: 150 m/dak, kesme derinliği: 0.1 mm ve ilerleme: 0.1 mm/dev parametreleriyle yapılan en düşük kesme kuvvetinin ölçüldüğü, kesme bölgesindeki sıcaklığın 50 °C bulunduğu kuru tornalama deneyi sonucunda meydana gelen talaşın görüntüsü.....	36
Şekil 5.2. Kesme hızı: 150 m/dak, kesme derinliği: 0.4 mm ve ilerleme: 0.2 mm/dev parametreleriyle yapılan en düşük kesme kuvvetinin ölçüldüğü, kesme bölgesindeki sıcaklığın 121 °C bulunduğu kuru tornalama deneyi sonucunda meydana gelen talaşın görüntüsü.....	37
Şekil 5.3. Belirlenen deney parametreleri ile ölçülen sıcaklık değerlerinin grafikleri.....	51
Şekil 5.4. Belirlenen deney parametreleri ile ölçülen minimum kesme kuvveti değerlerinin grafikleri.....	52

Şekil 5.5. Oluşturulan makine öğrenmesi modelinin 1.bölümünün ekran görüntüsü (Google Colab).....	54
Şekil 5.6. Oluşturulan makine öğrenmesi modelinin 2.bölümünün ekran görüntüsü (Google Colab).....	54
Şekil 5.7. Oluşturulan makine öğrenmesi modelinin 3.bölümünün ekran görüntüsü (Google Colab).....	55
Şekil 5.8. Oluşturulan makine öğrenmesi modelinin 4.bölümünün ekran görüntüsü (Google Colab).....	55
Şekil 5.9. Karar ağacı regresyon modelinin performans metrikleri grafiği.....	56
Şekil 5.10. Oluşturulan makine öğrenmesi modelinin 5.bölümünün ekran görüntüsü (Google Colab).....	56
Şekil 5.11. Rastgele orman regresyon modelinin performans metrikleri grafiği.....	57
Şekil 5.12. Oluşturulan makine öğrenmesi modelinin tahmin bölümünün ekran görüntüsü (Google Colab).....	58

TABLolar DİZİNİ

Sayfa

Tablo 2.1. Ön ısıtmalı işleme yöntemleri ile bulunan uygun sıcaklık değerleri.....	12
Tablo 4.1. GOODWAY GLS 150 marka CNC torna tezgâhı teknik özellikleri.....	31
Tablo 4.2. Kistler marka 9257b model dinamometrenin teknik özellikleri.....	33
Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları.....	38
Tablo 5.2. Veri seti (Dataset).....	50
Tablo 5.3. Oluşturulan makine öğrenmesi modeli ile tahmin edilen sıcaklık değerleri.....	59

KISALTMALAR VE SİMGELER

ANN, YSA: Artificial Neural Network (Yapay Sinir Ağları)

ANOVA: Varyans analizi

CC: Correlation coefficient (Korelasyon)

Dak: Dakika

Dev: Devir

DTR: Decision Tree Regression (Karar Ağacı Regresyon)

FEM: Finite Element Method (Sonlu Elemanlar Yöntemi)

FFNN: Multilayer feedforward neural network (Çok katmanlı ileri beslemeli sinir ağı)

GPR: Gaussian Regression Process (Gauss Süreç Regresyonu)

HRC: Rockwell sertlik değeri

KNN: K-nearest neighbour algorithm (K-en yakın komşu algoritması)

LAM: Laser Assisted Machining (Lazer Destekli İşleme)

LBM: Lattice Boltzmann Method (Kafes Boltzmann Yöntemi)

M: Metre

MAE: Mean Absolute Error (Ortalama Mutlak Hata)

MAPE: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)

MLP: Multilayer perceptron (Çok katmanlı algılayıcı)

MSE: Mean Squared Error (Ortalama Kare Hata)

MLQ: Minimum Quantity Lubrication (Minimum miktarda yağlama)

N: Newton

PVD: Physical Vapor Deposition (Fiziksel Buhar Biriktirme)

RFR: Random Forest Regression (Rastgele Orman Regresyon)

SVM-RBF: Radyal tabanlı çekirdeği olan destek vektör regresyon modeli

SVR: Support Vector Regression (Destek Vektör Regresyon)

TİAD: Takım Tezgahları Sanayici ve İş İnsanları Derneği

W: Watt

1. GİRİŞ

Talaşlı imalat, malzemeye istenilen geometriyi, ölçüleri ve özellikleri kazandırmak için stok parçadan talaş kaldırarak parçayı üreten bir alışılmış imalat yöntemidir. Alışılmış imalat yöntemi olmasına rağmen talaşlı imalat, elde ettiği hassas toleranslar ve yüzey pürüzlülüğü değerleri sayesinde savunma sanayi, otomotiv, beyaz eşya, elektronik, medikal, havacılık ve makine imalatı gibi birçok sektör için önemini korumaya ve artırmaya devam edecektir. Bu kadar önemli bir sektörde Şekil 1.1’de gösterilen ‘Takım Tezgahları ve Tamamlayıcı Ekipmanları 2023-3.Çeyrek Sektör Analizi’ raporundan alınan verilere göre, en yaygın talaşlı imalat yöntemlerinden biri olan tornalama işlemleri için kullanılan torna tezgâhlarının ithalat ve ihracat dengesinin %6 olmasıyla Türkiye’nin dışa bağımlı olduğu, ihracat tutarlarının ithalatla karşılaştırıldığında oldukça düşük düzeylerde olduğu görülmektedir. Gelişen ve sürekli büyüyen Türkiye sanayisinin yüksek teknolojili takım tezgâhlarına ihtiyacı arttıkça, torna tezgâhlarının yüksek katma değer sağladığı ve ülkemizde tüm alt gruplarda üretilmesine daha fazla önem verilmesi gerektiği açık şekilde görülmektedir[1].

USD (\$)	2021	2022	2022 – 9 Ay	2023 – 9 Ay
ÜRETİM				
Metal İşleme	300.000.000	334.300.000	253.500.000	274.500.000
Metal Şekillendirme	615.000.000	718.700.000	472.000.000	511.000.000
Toplam	915.000.000	1.053.000.000	725.500.000	785.500.000
Değişim Oranı	27,79%	15,08%		8,3%
İHRACAT				
Metal İşleme	198.540.207	236.091.417	166.068.360	186.556.036
Metal Şekillendirme	423.832.890	507.571.294	359.839.801	401.921.342
Toplam	622.373.097	743.662.711	525.908.161	588.477.378
Değişim Oranı	34,94%	19,49%		11,9%
İTHALAT				
Metal İşleme	1.073.723.921	1.161.473.651	800.842.958	1.065.130.280
Metal Şekillendirme	319.868.583	405.917.032	288.189.112	292.515.863
Toplam	1.393.592.504	1.567.390.683	1.089.032.070	1.357.646.143
Değişim Oranı	41,29%	12,47%		24,7%
KULLANIM (YURT İÇİ SATIŞ)				
Metal İşleme	1.175.183.714	1.259.682.234	888.274.598	1.153.074.244
Metal Şekillendirme	511.035.693	617.045.738	400.349.311	401.594.521
Toplam	1.686.219.407	1.876.727.972	1.288.623.909	1.554.668.765
Değişim Oranı	35,86%	11,30%		20,6%

DIŞ TİCARET DENGESİ				
ÜRÜN TİPİ	GTİP	IHRACAT 2023 – 9 AY (USD)	İTHALAT 2023 – 9 AY (USD)	DENGE (%)
Elektro Erozyon, Lazer, Su Jeti Tezgahları	8456	84.435.058	178.759.965	47
İşleme Merkezleri, Transfer Tezgahları	8457	17.475.633	407.692.263	4
Torna Tezgahları	8458	17.401.849	283.917.660	6
Freze, Delme, Diş/Vida Açma Tezgahları	8459	14.363.730	67.718.301	21
Taşlama, Takım Bileme, vb. Tezgahlar	8460	17.982.124	74.818.090	24
Dişli Açma/Taşlama, Testere Tezgahları	8461	34.897.642	52.224.001	67
Presler, Giyotin, Punch, Abkant Tezgahları	8462	370.941.792	228.110.813	163
Boru/Tel Çekme, Diş Açma Tezgahları	8463	30.979.550	64.405.050	48
Genel Toplam		588.477.378	1.357.646.143	43

Şekil 1.1. Takım tezgâhları genel durum [1]

Yukarıdaki tablodan da anlaşılacağı üzere talaşlı imalat tezgâhları ve tornalama tezgâhlarının büyük ölçüde dışarıdan ithal edildiği görülmektedir. Bu durumu tersine çevirmek amacıyla sanayi için gerekliliği tartışılmaz olan talaşlı imalat tezgâhlarının yerli ve milli üretimlerinin artırılması için çalışılması gereklidir. Buna ek olarak bu tezgâhlarda kullanılan kesici uçların ve kesme sıvılarının da büyük bir kısmı ithal edilmektedir. İthal edilen bu malzemelerin azaltılması için talaşlı imalatın bileşenlerinin kontrol edilmesi gerekmektedir. Özellikle kesme bölgesinde oluşan sıcaklığın otomatik olarak kontrol edilmesiyle, işleme kalitesi artarken kesici uç ve kesme sıvısı tüketimi azalacaktır.

Tornalama işlemleri için uygun koşulların sağlanmasıyla, deneme yanılma yöntemine gerek kalmadan hızlı ve verimli bir şekilde üretim yapabilmek enerjiden, maliyetten ve zamandan tasarruf sağlayacaktır. Bu sayede talaşlı imalat sektörüne ve tornalama işlemlerine olan ilgi ve talebin artması ile takım tezgâhları üretiminin de artırılması sağlanarak sektörün canlanmasına katkıda bulunmuş olacaktır. İmalat sektöründeki rekabetin günümüz teknolojisi ile artmasıyla birlikte, üreticilerden talep edilen sadece ürünlerin maliyetinin uygun olması değil, bununla birlikte kalitesi yüksek ve hızlı teslim edilen ürünler olmuştur[2]. Bu sebeple, üretim süreçlerinin analiz edilerek iyileştirilmesi, modern teknolojilerin ya da veri odaklı yaklaşımların uygulanması, geleneksel imalat sektörünün daha etkili ve işlevsel hale getirilebilmesi için gerekli olmaktadır.

Bu çalışmanın amacı, malzemelerin tornalanmasında akıllı sistemlerin karar alması amacıyla gerekli olan kesme bölgesindeki sıcaklıkların belirli iş malzemeleri için makine öğrenmesi ile tahmin edilmesidir. Deneyleri yapılarak bulunmuş en düşük kesme kuvveti değerlerinin ölçüldüğü deney parametreleri ve deneyler sırasında ölçülerek kaydedilen sıcaklık değerleri seçilerek oluşturulan veri setiyle, makine öğrenmesi modeli oluşturmak ve bu model sayesinde istenilen değerler için de kesme bölgesindeki sıcaklık tahminlerini yapabilmektir. Çalışmanın sonucunda, veri seti baz alınarak istenilen değerlerde; malzeme, kesici takım, ilerleme hızı, kesme hızı ve kesme derinliği parametreleri modele girilerek, kesme bölgesindeki sıcaklık tahmin edilebilecektir. İstenilen parametre değerleri modele girilerek sıcaklık tahmin edilebileceği için, yapılmak istenen deney için önceden belirlenmiş parametreler için de ara değerler için de deneme yanılma yöntemlerine ihtiyaç duyulmadan, tahmin edilen sıcaklığa göre işlem yapılabilir.

Günümüz teknolojisiyle beraber neredeyse her alanda otomasyona geçildiği düşünüldüğünde her geçen gün bu bilgilerin tahmin edilmesine çok daha fazla ihtiyaç duyulmaktadır. İleri zamanlarda, daha fazla gelişmesi beklenen teknolojiyle birlikte imalatta kullanılan tezgâhlar, işleme koşullarına kendileri karar verebileceklerdir. Bu koşullar için gereken önemli ihtiyaçlardan birisi ise malzemenin işleme sıcaklığı yani ön ısıtılma ya da soğutulma sıcaklığıdır. Yaptığımız bu çalışma ile imalat sanayisinde ileri dönemler için karanlık fabrikalara geçileceği, dijitalleşeceği ve insana olan ihtiyacın azalacağı düşünüldüğünde, veri tabanı oluşturulmasına katkı sağlanmış

olacaktır. Özdüzgün (2024) tarafından yapılan çalışmada, makine öğrenmesi modelleri kullanılarak malzemenin optimum sıcaklıkta işlenebilmesi için gerekli yağlama aralığının tahmin edilebileceği, bu sayede sistemin ne kadar soğutma yapacağına kendisinin karar verebileceği şekilde bir sistem tasarlanmıştır. Elde edilecek makine öğrenmesi yöntemleri ve yapılan sistem tasarımı ile kesme bölgesinde oluşan sıcaklık, kesme parametreleri göz önünde bulundurularak optimum seviyede kalacaktır. Malzemenin olması gereken sıcaklıkta işlenmesi sağlanmış olacaktır. Soğutmada kullanılan kesme sıvısı yeterli miktarda kullanılarak; gereğinden fazla kesme sıvısı kullanımının ekonomik zararlarının, çevre ve insan sağlığına yol açtığı olumsuz etkilerin önüne geçilmiş olacaktır[3]. Yaptığımız bu çalışmayla Özdüzgün (2024) ile birlikte geliştirmekte olduğumuz akıllı soğutma sisteminin optimum işleme sıcaklıkları makine öğrenmesi kullanılarak tahmin edilmiş olunacaktır. Bu çalışmada kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklık tahmini makine öğrenmesi yoluyla yapılmıştır. Oluşturduğumuz makine öğrenmesi modeli ile yüzey pürüzlülüğünü minimum yapan, takım aşınmasını minimum yapan vb. farklı etkenlerin de dikkate alınarak oluşturulan yeni veri setleriyle de kesme bölgesindeki sıcaklık tahmin edilebilecektir. Hepsinin bir arada değerlendirilmesiyle de kesme bölgesindeki sıcaklık tahminlerinde en uygun işleme sıcaklığının tahmin edilmesine daha fazla yaklaşılacaktır.

Ayrıca tahmin edilen kesme bölgesindeki sıcaklık sayesinde, yapılacak deneyin öncesinde ideal ortam şartları oluşturularak deneye başlanacağı için takım aşınmasının, kesme kuvvetinin, yüzey pürüzlülüğünün, kesme sıvısı tüketiminin ve iş parçasının aşınmasının azaltılması sağlanarak enerjiden, zamandan ve maliyetten tasarruf sağlanmış olacaktır. Oluşturduğumuz makine öğrenmesi için gerekli veri seti, 16MnCr5 çeliğini işleyerek yaptığımız kuru tornalama deneyleri esnasında en düşük kesme kuvveti değerlerinin ölçüldüğü kesme parametreleri ile sıcaklık değerlerinden oluşmaktadır.

2. LİTERATÜR ARAŞTIRMASI

Kesme bölgesindeki sıcaklıkların makine öğrenmesiyle tespit edilmesi ile ilgili olan bu çalışmada önce talaşlı imalatta ön ısıtma ile ilgili çalışmalar incelenecek daha sonra ise makine öğrenmesi ile ilgili olan çalışmalar özetlenecektir.

Hamamcı (2015), sertleştirilmiş DIN 1.2842 (90MnCrV8) soğuk iş takım çeliğinin frezeleme yöntemiyle işlenebilirliğini artırmak için malzemeye indüksiyonla ön ısıtma uygulamıştır. Deneysel numunelerinin ve bağlama pabuçlarının hazırlanmasında alışılmamış imalat yöntemi olan tel ve dalma erozyon yöntemleri kullanılmıştır. Deneysel çalışmalar, Hartford VMC-1020 CNC dikey freze tezgâhında, CBN kesici uç malzemesi kullanılarak gerçekleştirilmiştir. 61HRC sertliğindeki soğuk iş takım çeliği işlem öncesinde indüksiyon cihazı ile 500 °C'ye kadar ısıtılmış daha sonra frezeleme işlemine tabi tutulmuştur. Frezeleme işlemi esnasında kesme kuvvetleri ölçülmüş, işlem sonrasında ise malzemenin yüzey pürüzlülük değerleri ve takımın aşınma değerleri ölçülerek incelenmiştir. Deneysel çalışmada işleme değişkenlerini ve deney sayılarını belirlerken Taguchi metodu kullanılmıştır. L16 (4**3) standart ortogonal dizisi için farklı sayılarda belirlenen kesme hızı, ilerleme ve ön ısıtma sıcaklığı kullanılarak deneyler gerçekleştirilmiş ve ön ısıtma sayesinde sert malzemenin işlenmesi için gerekli kesme kuvveti, takım aşınması ve yüzey pürüzlülüğü değerlerini azaltmak amaçlanmıştır. Çalışmanın sonucunda minimum takım aşınması ve kesme kuvveti değerleri, uygulanan farklı ön ısıtma sıcaklıkları arasında 500 °C'de yapılan frezeleme sonucunda ölçülmüştür[4].

Hamamcı (2014), titanyum alaşımının (Ti6Al4V) frezelenmesi ile ilgili olarak yaptığı çalışmada ön ısıtma işlemi için indüksiyon fırını kullanmıştır. Fiziksel buhar biriktirme yöntemiyle kaplanmış karbür kesici uç ile farklı işleme değişkenleri kullanarak ve farklı ön ısıtma sıcaklıklarında Ti6Al4V alaşımını frezeleyerek kesici uçlardaki aşınma mekanizmalarını ve iş parçası üzerinde oluşan yüzey pürüzlülük değerlerini inceleyerek takım ömrünü belirlemeye çalışmıştır. Ti6Al4V malzemesinin frezelenmesinde, ön ısıtma yapılarak işlenmesinde takımın aşınmaya sebebiyet

verecek mekanizmaları ve ön ısıtmasız işlemede takımın aşınmaya sebebiyet verecek mekanizmaları karşılaştırmıştır. Yapılan çalışma sonucunda, ön ısıtma ile yapılan deneylerde, oda sıcaklığında yapılan deneylere göre işleme zamanında %30'lara varan, kesme kuvvetinde ise %7-16 aralığında azalmalar gözlemlenmiştir. Özellikle 400 °C ön ısıtma değerinde en düşük kesme kuvvetleri ölçülmüştür. Takım ömrü ise %35 oranında artmıştır. Ön ısıtma sıcaklığının 300-400 °C aralığının üzerine çıktığında takım ömrünün negatif etkilendiği tespit edilmiştir[5].

Uğraş (2022), yaptığı çalışmada TIG tekniğinin ısı destekli işleme için uygulanabilirliğini, diğer enerji kaynakları arasındaki yerini ve konvansiyonel işleme göre sağladığı üstünlükleri araştırmıştır. TIG tekniği kullanılarak ısı destekli işleme yapabilen bir sistem geliştirmiştir. Deneylerde AISI 4340 çeliğinin sertleştirilmemiş ve 49HRC sertliğinde sertleştirilmiş numuneleri, yüksek talaş kaldırma oranlarında konvansiyonel yöntemle ve TIG tekniği ile ısı destek sağlanarak işlenmiştir. Kesici uç olarak: SNMG 120408-QM 4225 ISO kodlu kaplamalı karbür kullanılmıştır. Ön ısıtmanın etkisiyle kesme enerjisi düşmüş ve talaşın plastik deformasyonu daha kolay hale gelmiştir. Konvansiyonel işleme kıyasla kesme işleminde harcanan güç değerinde maksimum %20,92 azalma sağlandığı ve yüzey kalitesinde maksimum %22,28 iyileşme sağlandığı gözlemlenmiştir. Numunelerin boyutsal kararlılık özellikleri iyileştirilmiş ve çap ölçüsündeki sapma değerlerinde 40 µm'a varan azalma sağlanmıştır. TIG tekniğinin ısı destekli işleme için uygulanabilir ve alternatif bir enerji kaynağı olduğu sonucuna varılmıştır. Kesme ile eş zamanlı gerçekleştirilemeyen ön ısıtma nedeniyle numunelerin çap ölçüsünde genişlemeye bağlı boyutsal daralma olduğu belirlenmiş ve kısa devre nedeniyle kaynak arkının sonlanmasının TIG esaslı ısı destekli işleme yöntemi için dezavantaj olduğu tespit edilmiştir. AISI 4340 alaşımlı çeliğin TIG kaynağı ile ısıtılarak tornalanmasında en düşük yüzey pürüzlülük değerinin ölçüldüğü en uygun işleme sıcaklığının 469 °C ve 49HRC sertliğindeki AISI 4340 alaşımlı çeliğin TIG kaynağı ile ısıtılarak tornalanmasında ise en düşük yüzey pürüzlülük değerinin ölçüldüğü en uygun işleme sıcaklığının 497 °C olduğu tespit edilmiştir[6].

Kavak (2019), yaptığı çalışmada alevle ısıtma yöntemini kullanarak, Ti6Al4V alaşımının ve AISI 4340 çeliğinin tornalanmasında meydana gelen iş malzemelerinin yüzey pürüzlülüğü değerlerini ve kesici takımlarda meydana gelen aşınmaları

belirlemeye çalışmıştır. Ön ısıtmalı tornalama ve ön ısıtmasız tornalama işlemleri arasında karşılaştırmalar yapmıştır. Deneylede PVD kaplamalı karbür (KPL), kriyojenik işlem görmüş karbür (KİG) ve kaplamasız karbür kesici uç kullanmıştır. Ti6Al4V alaşımının deneylerinin incelenmesi sonucunda bütün takım türlerinde sıcaklık değerlerinin artması, yüzey pürüzlülük değerlerinin düşmesini sağlamıştır. Ancak 650 °C sıcaklığa ulaşıldığında yüzey pürüzlülüğü değerlerinde artış gözlemlenmiştir. Farklı kesici takım çeşitleri üzerinde yapılan bu çalışma sonucunda, en iyi yüzey pürüzlülük değeri KİG kesici takım kullanıldığında elde edilmiştir. Ti6Al4V malzemesinin kesme işlemi için en iyi işleme sıcaklığı 450 °C olarak bulunmuştur. 450 °C sıcaklık değerinde Ti6Al4V iş malzemesinin sertlik direncinin kaybolması ile işlenebilirliği artmıştır. AISI 4340 alaşımlı çeliğin deney sonuçları incelendiğinde ise; farklı kesici takım çeşitleri üzerinde yapılan bu çalışma sonucunda en iyi yüzey pürüzlülük değeri KPL kesici takım kullanıldığında elde edilmiştir. AISI 4340 alaşımlı çeliğin kesme işlemi için en iyi işleme sıcaklığı ise 650 °C olarak bulunmuştur. 650 °C sıcaklıkta AISI 4340 iş malzemesinin sertlik direncinin kaybolması ile işlenebilirliği artmıştır[7].

Tosun vd. (2002) tarafından yapılan çalışmada, yüksek manganlı çelik numuneler; kesme hızı, ilerleme hızı, kesme derinliği ve yüzey sıcaklıkları parametreleriyle çeşitli kesme koşullarında sıvı petrol gazı aleviyle ısıtılarak torna tezgâhında işlenmiştir. Takım ömrünü tahmin etmek amacıyla ANN ve regresyon analizi metotlarını kullanmışlardır. Deneylelerin sonuçları değerlendirildiğinde, yüksek manganlı çeliğin ön ısıtmalı şartlarda tornalanmasında takım ömründe, oda sıcaklığındaki tornalanmasıyla kıyaslandığında artış meydana geldiği görülmüştür. Takım ömrü, en uzun 600 °C sıcaklık koşullarında sağlanırken, 400 °C sıcaklık koşullarında da neredeyse aynı değerler elde edilmesi sebebiyle iş malzemesinin maliyeti ve mikro yapısı göz önüne alınarak en uygun işleme sıcaklığı 400 °C olarak belirlenmiştir[8].

Rebro vd. (2004) tarafından yapılan çalışmada, basınçsız sinterlenmiş mullit seramik iş malzemesinin lazer destekli tornalanmasının değerlendirilmesi üzerinde durmuşlardır. Tornalama işlemi CNC taret torna tezgâhında gerçekleştirilirken, lazer ısı kaynağı olarak CO₂ lazer kullanmışlardır. Malzeme kaldırma sıcaklıkları: 925, 1043 ve 1215 °C olarak ölçülmüştür. Lazer gücü ayarları ise sırasıyla 150, 170 ve 190 W'tır. Mullitin yumuşaması ve mukavemetinin azalmasının sağlanmasında; 170–190

W aralığındaki lazer güçleri olumlu sonuçlar vermiştir. Bu aralıktaki lazer güçleriyle işleme sırasında; yarı sürekli talaş oluşumu, iş parçasında kabul edilebilir yüzey kalitesi, belirgin bir şekilde kesme kuvvetlerinde azalma ve takım ömründe önemli bir artış meydana gelmiştir. Bu aralıktaki güçlere karşılık gelen sıcaklık değerleri ise 1043-1215 °C'dir[9].

Dandekar vd. (2010) yaptıkları çalışmada titanyum alaşımını lazer destekli ve hibrit işleme yöntemleriyle işleyerek, modelleme ve deneyler yoluyla takım ömrünü ve kaldırılan malzeme oranını en üst düzeye çıkarmayı amaçlamışlardır. Yaptıkları çalışmalar sonucunda, LAM ve hibrit işleme için optimum malzeme kaldırma sıcaklığını 250 °C olarak belirlemişlerdir. Bu malzeme kaldırma sıcaklığında, geleneksel işlemeye kıyasla 107 m/dak'nın altındaki kesme hızları için takım ömrünü LAM ile 1.7 kat iyileştirirken, hibrit işleme ile 2 kat iyileştirdiği sonucuna varmışlardır[10].

Masood vd. (2011) yaptıkları çalışmada Nd:YAG lazer kullanarak yüksek kromlu beyaz dökme demirlerin LAM ile işlenmesini araştırmışlardır. Lazer destekli işlemenin takım ömrünü uzatarak, işleme maliyetlerini düşürmesinin yanı sıra bu tür işlenmesi zor malzemelerin kalitesini artırmanın bir yolu olarak geleneksel işlemeye alternatif olup olmayacağını belirlemeyi amaçlamışlardır. Yaptıkları çalışma sonucunda, lazer gücündeki artışın yüzey sıcaklığında ve ısı penetrasyon derinliğinde bir artışa neden olduğu gözlemlenmiştir. Lazer noktası ile kesici takım arasındaki mesafe arttıkça ısı penetrasyonunun arttığını ancak yüzey sıcaklığının düştüğünü tespit etmişlerdir. Bu malzemenin lazer destekli işlenmesinin, kesme kuvvetlerinde maksimum %24 ve besleme kuvvetlerinde maksimum %22 azalma gösterdiği tespit edilmiştir[11].

Sun vd. (2011) yaptıkları çalışmada Ti6Al4V alaşımının lazer destekli frezelenmesinde işlenebilirliğin iyileştirilmesini araştırmışlardır. İş parçasının sıcaklık analizinde, kesme bölgesinin önündeki sıcaklık 200-450 °C aralığında olduğunda ilerleme kuvvetinde önemli bir azalma meydana geldiğini tespit etmişlerdir. Frezeleme işlemini daha etkili hale getirmek adına talaşı basınçlı hava kullanarak kesici takımdan uzaklaştırmışlardır. İş mili aracılığıyla verilen basınçlı hava ile kesme bölgesinin önündeki optimum iş parçası sıcaklığının yaklaşık olarak 350 °C olduğunu ve bunun

da sabit bir nozuldan verilen basınçlı havayla sağlanan sıcaklıktan yaklaşık 230 °C daha yüksek olduğunu tespit etmişlerdir[12].

Rashid vd. (2012) yaptıkları çalışmada Ti-6Cr-5Mo-5V-4Al beta titanyum alaşımının işlenebilirliğinin ve kesme kuvvetlerinin azaltılmasının lazer destekli işleme yöntemiyle iyileştirilmesini amaçlamışlardır. Yapılan çalışmalar sonucunda Ti-6Cr-5Mo-5V-4Al beta titanyum alaşımını lazer destekli koşullar altında işlerken kesme kuvvetlerinde orta düzeyde bir azalma elde etmek için 1050–1250 °C aralığında kesme sıcaklıkları kullanılması gerektiğini tespit etmişlerdir[13].

Ayed vd. (2014) yaptıkları çalışmada Ti6Al4V alaşımının lazer destekli tornalanması sırasında meydana gelen fiziksel olayların anlaşılmasına ve bu sürecin optimize edilmesine odaklanmışlardır. Yaptıkları çalışmalar sonucunda, lazer destekli işlemede yaklaşık 80 m/dak 'lık bir kesme için işlenecek malzemenin birincil bölgeden hemen önceki ortalama sıcaklığının; 500 W lazer gücü için yaklaşık 350 °C ve 1000 W lazer gücü için 600 °C olduğunu tespit etmişlerdir[14].

Germain vd. (2008) yaptıkları çalışmada, Inconel 718'in karbür ve seramik kesici uç kullanarak lazer destekli işlenmesini incelemiş, uçların kullanımı arasındaki farkları ve geleneksel işleme ile arasındaki farkları karşılaştırmışlardır. ROFIN YAG lazer ile donatılmış numerik kontrollü bir torna tezgâhı kullanılmıştır. Karbür kesici takımla yapılan deneylerde, deney parametreleri olarak kesme derinliği: 2,5 mm, kesme hızı: 30 m/dak ve ilerleme: 0,2 mm/dev olarak seçilmiş, lazer ışınının ise kesici takımdan yaklaşık 5 mm uzakta pahlı kesim yüzeyine odaklanması sağlanmıştır. Seramik uç ile yapılan deneylerde, deney parametreleri olarak kesme derinliği: 1,5 mm, kesme hızı: 220 m/dak ve ilerleme: 0,18 mm/dev olarak seçilmiştir. Her iki kesici uç ile yapılan deneyler sonucunda da LAM'ın kesme kuvvetlerini önemli ölçüde azalttığı (%40'a kadar) gözlemlenmiştir. Lazer destekli işleme sırasında seramik kesici uçların, karbür kesici uçlara kıyasla çok daha iyi performans sağladığı gözlemlenmiştir. Lazer destekli işlemede karbür kesici ucun ömrü, geleneksel işlemedeki ömründen önemli ölçüde düşükken; seramik kesici uçların ömrünün, geleneksel işlemedeki ömrüne kıyasla %25 arttığı tespit edilmiştir[15].

Chang vd. (2007) yaptıkları çalışmada konvansiyonel planyalamayı LAM kullanarak alüminyum oksit planyalama ile karşılaştırmak için deneysel bir sistem kullanmışlardır. LAM'da öncelikli olarak kesme kuvvetine dikkat edilmiştir. LAM sistemi; odaklama optikli 25 W (sürekli dalga) CO2 lazer, servo motorlu ve kontrolörlü tek eksenli bir besleme tablası ve kübik bor nitrür (CBN) kesici takımdan oluşturulmuştur. İş parçası olarak yaklaşık 45 mm uzunluğunda, 10 mm genişliğinde ve 10 mm yüksekliğinde Al₂O₃ seramik malzeme kullanılmıştır. Alüminyum oksit seramiklerin işlenmesinde, cam geçiş sıcaklığının 850 °C'nin üzerinde olduğu dikkate alınarak yapılan deneylerde, optimum işleme sıcaklığının 850-900 °C olduğu tespit edilmiştir. Ek olarak iş parçası yüzeyinin altındaki dikey sıcaklık dağılımı LBM (Kafes Boltzmann Yöntemi) ile hesaplandığında sıcaklığın 0,1 mm derinlikte, hızla 100 °C'nin altına düştüğü gözlemlenmiştir. İlerleme hızı 0,5 m/dak olduğunda kesme kuvvetinin LAM ile geleneksel planyalamaya göre yaklaşık 5 N daha fazla azaldığı gözlemlenmiştir. İlerleme hızı 0,5 m/dak'ya düştükten sonra, LAM'daki kesme kuvveti, ilerleme kuvveti için yaklaşık %12 ve itme kuvveti için %10 azalmıştır. Ayrıca daha yavaş ilerleme hızı nedeniyle, işleme sırasındaki kesme kuvveti daha düşüktür. Bu verilerden yola çıkarak, LAM'ın seramik gibi işlenmesi zor malzemelerin işlenmesi için uygun olduğunu tespit etmişlerdir. İşlenmiş yüzey boyunca yüzey pürüzlülüğü parametreleri ölçüldüğünde, LAM kullanılarak yapılan planyalamada yüzey bütünlüğü performansının, geleneksel işleme yönteminden çok daha iyi olduğunu tespit etmişlerdir[16].

Chang vd. (2007), lazer destekli tornalama yöntemiyle Al₂O₃ iş parçasını işleyerek farklı yüzey pürüzlülüğü ölçümleri elde etmek için deneyler yapmışlardır. Deneylerde lazer kaynağı olarak Nd:YAG lazer kullanılmıştır. Deneysel sonuçlar, optimum işleme koşullarının belirlenmesini kolaylaştıran Taguchi yöntemi kullanılarak analiz edilmiştir. Yaklaşık 15 mm çapında ve 65 mm uzunluğunda silindirik Al₂O₃ iş parçası kullanılmıştır. Alüminyum oksit seramiklerin cam geçiş sıcaklığının 850 °C'nin üzerinde daha viskoz hale geldiği, hacimsel olarak genişlediği ve elastomerlere dönüştüğü için tanelerin veya tane gruplarının yüzeyden ayrılmasına neden olduğu bilinmektedir. Buradan yola çıkılarak yapılan deneylerde alüminyum oksit seramiklerin tornalanması için en uygun sıcaklığın 1100 °C olduğu tespit edilmiştir[17].

Maity vd. (2008) alevli ısıtma yöntemini kullanarak, yüksek manganlı çeliğin sıcak işleme operasyonu için deneysel bir araştırma yapmışlardır. İş parçasının ısıtılması, sıvı petrol gazı ve oksijen karışımının yakılmasıyla gerçekleştirilmiştir. Karbür kesici takım kullanılmıştır. İşleme parametreleri; kesme hızı: 22-43 m/dak, ilerleme hızı: 0,05-0,7 mm/dev, sıcaklık: 200-600 °C ve kesme derinliği: 0,5-1,5 mm olarak seçilmiştir. İş parçası sıcaklığının, takım ömrünün iyileştirilmesinde önemli bir rol oynadığı belirlenmiştir. Takım ömrünün belirlenmesinde; ilerlemenin öneminin, kesme derinliğinden daha fazla olduğu tespit edilmiştir. İlerleme hızı, kesme derinliği ve kesme hızı azaldıkça takım ömründe artış olduğu belirlenmiştir. Bununla birlikte sınırlayıcı en yüksek sıcaklığın iş parçasının yeniden kristalleşme sıcaklığı olduğu, bunun ötesinde daha yüksek ısıtma sıcaklığının iş parçası malzemesinde istenmeyen yapısal değişikliklere neden olabileceği tespit edilmiştir[18].

Anderson vd. (2006) yaptıkları çalışmada lazer destekli tornalama yöntemi ile Inconel 718 iş malzemesini işlemişlerdir. Isı kaynağı olarak CO2 lazer kullanmışlardır. Kaplamasız Inconel 718'in CO2 lazerin düşük emiciliğinin üstesinden gelmesi için, lazer ısıtma yapılmadan önce tüm parçalar grafit ile kaplanmıştır. Maksimum sıcaklığı, kaplama için izin verilen maksimum sıcaklığın altında tutmak için çevresel olarak ısıtmak adına ikinci bir ısı kaynağı olarak Nd:YAG lazer kullanmışlardır. Yapılan deneyler sonucunda, oda sıcaklığından 620 °C'ye çıkan malzeme kaldırma sıcaklığı ile lazer destekli işlemenin yararları, geleneksel işlemeye göre spesifik kesme enerjisinde %25 azalma, yüzey pürüzlülüğünde 2-3 kat iyileşme ve seramik takım ömründe %200-300 artış ile kanıtlanmıştır. Ayrıca ekonomik bir analiz yapıldığında Inconel 718'in karbür ve seramik kesici uçlarla işlenmesinde; lazer destekli işlemenin geleneksel işlemeye göre önemli faydaları olduğu tespit edilmiştir[19].

Tablo 2.1. Ön ısıtmalı işleme yöntemleri ile bulunan uygun sıcaklık değerleri

Kullanılan Tezgâh	Çalışılan Malzeme	Isıtma Kaynağı	Kesici Takım	Uygun Sıcaklık Değeri (°C)	Kaynak
Freze	Soğuk iş takım çeliği (90MnCrV8)	İndüksiyon fırını	CBN	500	Hamamcı (2015)
Freze	Ti6Al4V	İndüksiyon fırını	PVD kaplı karbür	400	Hamamcı (2014)
Torna	Ti6Al4V	Alevli ısıtma	Kriyojenik işlem görmüş kaplamasız karbür	450	Kavak (2019)
Torna	AISI 4340	Alevli ısıtma	PVD kaplı karbür	650	Kavak (2019)
Torna	Sertleştirilmemiş AISI 4340	TIG kaynağı	Kaplamalı karbür	469	Uğraş (2022)
Torna	49 HRC sertliğinde AISI 4340	TIG kaynağı	Kaplamalı karbür	497	Uğraş (2022)
Torna	Yüksek manganlı çelik	Alevle ısıtma	Sinterlenmiş karbür	400	Tosun vd. (2002)
Torna	Basıncsız sinterlenmiş mullit seramik	CO2 Lazer	CBN karbür ve kaplamasız karbür	1043-1215	Rebro vd. (2004)
Torna	Ti6Al4V	CO2 Lazer	TiAlN kaplamalı karbür	250	Dandekar vd (2010)
Torna	Ti-6Cr-5Mo-5V-4Al	Nd:YAG lazer	Kaplamasız tungsten karbür takım	1050-1250	Rashid vd. (2012)
Planya	Al2O3 seramik	CO2 Lazer	CBN	850-900	Chang vd. (2006)
Torna	Al2O3 seramik	Nd:YAG lazer	CBN	1100	Chang vd. (2006)
Freze	Ti6Al4V	Nd:YAG Lazer	Karbür	350	Sun vd. (2011)
Torna	Inconel 718	CO2 Lazer	Greenleaf WG-300	620	Anderson vd. (2006)

Literatürden yararlanılarak özetlenmiş olan Tablo 2.1’de ön ısıtma yöntemleri için kullanılan ısıtma kaynakları, tezgâh, malzeme, kesici takım ve yapılan deneyler sonucunda tespit edilen uygun sıcaklık değerleri gösterilmektedir.

Binali vd. (2022) tarafından yapılan çalışmada, S960QL çeliğinin işleme verimliliğini yükseltmek için FE yöntemi kullanılmıştır. İşlenmesi güç malzemelerden olduğu bilinen S960QL çeliğinin talaşlı imalatı esnasında aşırı güç tüketimi ortaya çıkmakta, bu durum ise işleme maliyetini artırmaktadır. Bu sorunu minimuma indirmek amacıyla, S960QL yapı çeliğinin frezelenmesi esnasında kesme parametresi değerlerine bağlı olarak güç tüketimini modellemek için sonlu elemanlar yöntemi kullanılmıştır. Çalışmanın neticesinde, kesme parametrelerinin güç tüketimi üzerindeki etkisinin belirlenmesinde sonlu elemanlar yönteminin uygun olduğu sonucuna varılmıştır[20].

Asiltürk vd. (2023) tarafında yapılan çalışmada, AISI 4140 iş malzemesinin tornalama yöntemiyle işlenmesinde; kesme hızı, ilerleme hızı ve kesme derinliği gibi işleme parametrelerinin, yüzey pürüzlülüğü ve titreşimler üzerinde oluşturduğu etkileri araştırmışlardır. İşleme sonrasında akustik emisyon ve yüzey pürüzlülük değerleri ölçülerek kaydedilmiştir. Matlab programı ile kural tabanlı bulanık mantık modeli geliştirilmiş ve deneyler sırasında ölçülerek kaydedilen değerler ile kural tabanlı bulanık mantık modelinin yapmış olduğu tahmin değerleri karşılaştırılmıştır. Yapılan değerlendirmeler neticesinde, kural tabanlı bulanık mantık modelinin başarılı sonuçlar verdiği belirlenmiştir[21].

Gupta vd. (2022) yaptıkları çalışmada, işlenmesi zor bir malzeme olan Ti6Al4V iş parçasını kuru tornalama, LN₂ ve CO₂ soğutma destekli tornalama yöntemleriyle işleyerek, kesme sıcaklıkları ve kesme kuvvetlerini ölçmüşlerdir. Bu işlemin sonlu elemanlar yöntemiyle (FE) simülasyonunu yapmış ve tornalama deneylerinin sonuçları ile simülasyon sonuçlarını karşılaştırarak değerlendirmişlerdir. Çalışmanın sonuçları incelendiğinde, işleme sıcaklığı değerleri için deneysel sonuçlar ile sonlu elemanlar modeli arasındaki sapmaların; kuru işleme, LN₂ ve CO₂ soğutma şartları için sırasıyla ortalama %5,54, %5,18 ve %8,42 olduğunu, kesme kuvveti için deney sonuçları ile sonlu elemanlar modeli arasındaki sapmaların; kuru işleme, LN₂ ve CO₂ soğutma şartları için sırasıyla %3.74, %3.358 ve %3.03 olduğunu tespit etmişlerdir[22].

Korkmaz vd. (2023) yaptıkları çalışmada Bohler çeliğinin tornalanmasında takım ömrünün durumunu değerlendirmek için makine öğrenimi kullanımının uygunluğunu

ve Bohler çeliğinin sürdürülebilir tornalanması kapsamında altta yatan mekanizmayı anlamayı amaçlamışlar ve bunun için hem kuru ortamda hem de çeşitli yağlama yöntemlerini kullanarak farklı kesme koşullarında kapsamlı deneyler yapmışlardır. Oluşturdukları veri seti, takım uzunluğu ve gözlemlenen gerçek takım aşınması arasındaki ilişkiyi temsil etmektedir. Bu veri seti ile ridge, karar ağacı, rastgele orman ve destek vektör regresyon algoritmaları kullanılarak oluşturdukları makine öğrenmesi modellerinin performans metriklerinin incelenmesi sonucunda, ridge regresyon ve karar ağacı regresyon modellerinin, verileri tahmin etmek için daha yüksek performanslara sahip olduklarını tespit etmişlerdir. Her iki modelin de takım aşınmasıyla ilgili doğru tahminler yapmak için kullanıma uygun olduğu sonucuna varılmıştır. Ayrıca bütün modellerin arasından en iyi performansın ridge regresyon modeline ait olduğunu özellikle belirtmişlerdir[23].

Akdulum vd. (2023) yaptıkları çalışmada, alüminyum alaşımlarının U matkap ile delinmesinde makine öğrenmesi algoritmalarıyla minimum sayıda kimyasal bileşim, mekanik özellikler ve kesme parametreleri makineye öğretilerek itme kuvvetinin tahmin edilmesine odaklanmışlardır. Destek vektör regresyon (SVR), gaussian process regresyon (GPR), XGBoost, FFNN (çok katmanlı ileri beslemeli sinir ağı) algoritmaları ile iki özellik girilerek kurulan tekli ve hibrit modeller ile başarılı tahminler yapmışlardır. Bu tahminler sayesinde daha doğru malzeme seçimi ve optimizasyonu sağlanmış olacaktır. Bu çalışmayı diğer çalışmalardan farklı kılan ise kimyasal bileşim, mekanik özellikler ve delme parametrelerinin modele tanıtılarak itme kuvveti tahmininin makine öğrenmesi ile yapılmasıdır. En az girdi verisi ile en yüksek performans gösteren model XGBoost+GPR hibrit modeli olmuştur[24].

Korkmaz vd. (2023) yaptıkları çalışmada, makine öğrenmesi modellerini kullanarak farklı yağlama koşulları altında paslanmaz çelik 316L'nin aşınma ve sürtünme özelliklerini tespit etmeyi amaçlamışlardır. Farklı işleme koşulları altında test edilen tüm modeller arasında düşük aşınma koşullarında %100 ve ağır aşınma koşullarında %99,27 toplam denetim doğruluğu ile J48 yöntemi en iyi sonucu vermiştir[25].

Kishore vd. (2023) yaptıkları çalışmada, Inconel 625 malzemesini CNC yüzey taşlama tezgâhında farklı kesme koşullarında (kuru, ıslak ve MQL) işleyip, teğetsel kuvvetler ve yüzey pürüzlülük değerleri için regresyon modelleri geliştirerek Inconel 625'in

taşlanmasını makine öğrenmesi tekniklerini kullanarak iyileştirmeyi amaçlamışlardır. Makine öğrenmesi modelleri için MLP (çok katmalı algılayıcı), KNN (k-en yakın komşu algoritması) ve SVR algoritmaları kullanılmıştır. Geliştirilen modellerin performansı için korelasyon katsayısı (CC), R^2 değeri, kök ortalama kare hata (RMSE) ve ortalama mutlak hata (MAE) parametreleri incelenerek değerlendirilmiştir. Bütün modeller arasında KNN modelinin verilerin tahmini için en uygun model olduğu tespit edilmiştir. Ayrıca MLP modeli ile ıslak taşıma için R^2 : 0,9983 değeri ile yüzey pürüzlülüğü değerlerini tahmin ederken, SVM-RBF modeli MQL taşıma için R^2 : 0,9950 değeri ile teğetsel kuvvetleri daha doğru tahmin ettiği tespit edilmiştir[26].

Rajesh vd. (2022) yaptıkları çalışmada, makine öğrenmesi algoritmaları ile geçmiş ve mevcut akıllı işleme süreçlerinin incelemesini yapmış ve işleme endüstrisinin gelecekteki yönlerini özetlemişlerdir. İnceledikleri farklı türlerde makine öğrenmesi algoritmalarının kullanıldığı tornalama işlemlerine dayanan beş makaleden, tornalama işlemleri için en çok tercih edilen algoritmaların; ANN (yapay sinir ağları), MOGA (çok amaçlı genetik algoritma) ve GA (genetik algoritma) olduğunu tespit etmişlerdir[27].

Bustillo vd. (2020) yaptıkları çalışmada makine öğrenmesi modelinin doğruluğunu artırmak için deneysel tekrar stratejisini incelemişlerdir. AISI 1045 çelik disklerin alın tornalanmasında, farklı soğutma sistemlerine ve geometrilerine bağlı olarak takım ömrünün makine öğrenmesi ile belirlenmesini vaka çalışması olarak seçmişlerdir. Veri seti boyutunda, aynı kesme koşullarının yeni tekrarları eklenerek çeşitlilik sağlanmıştır. Ayrıca algoritmaların verimliliği, farklı deneysel koşulların ortalamasının kullanılması durumu ile karşılaştırılmıştır. Yapılan çalışmalar sonucunda, tekrarlanan deneyler yoluyla veri seti boyutunu artırmak yapay sinir ağları ve karar ağaçları gibi makine öğrenmesi tekniklerine avantaj sağladığı görülmezken, KNN ve rastgele orman regresyon (random forest regression) gibi yöntemlerin doğruluk oranlarını önemli ölçüde artırdığını tespit etmişlerdir. Makine öğrenimi modelleri, ortalama veri setleri yerine orijinal veriler ile oluşturulan veri setleri ile eğitildiğinde tahminlerin doğruluk oranının arttığı tespit edilmiştir. Bunun nedeniyse, deneylerin tekrarının mekanik açıdan güvenilir sonuçlar elde etmek için gerekli olmasıdır[28].

Savkovic vd. (2020) yaptıkları çalışmada alüminyum alaşımının frezelenmesinde yapay zekâ yöntemlerinin uygulanma olasılıklarını araştırmışlardır. Kesme derinliği, kesme hızı ve ilerleme parametrelerine bağlı olarak frezeleme işleminde seçilen çıktı (ortalama yüzey pürüzlülüğü ve kesme bölgesinde oluşan sıcaklık) özellikleri için güvenilir akıllı modeller elde etmeyi amaçlamışlardır. Bulanık mantık, yapay sinir ağları ve genetik algoritmalar kullanılarak oluşturulan modellerin doğruluk oranları incelenmiştir. İncelemeler sonucunda bulanık mantık yönteminin en iyi sonuçlar verdiği tespit edilmiştir[29].

Simunovic vd. (2013) yaptıkları çalışmada, alüminyum alaşımının düşük güçteki freze tezgâhı ile yüzey frezelenmesinde, işlenen yüzeyin pürüzlülüğü üzerine bir araştırma gerçekleştirmişlerdir. Girdi değerleri olarak; devir sayısı-iş mili hızı, ilerleme hızı ve kesme derinliği alınırken, çıktı değişkeni olarak yüzey pürüzlülüğünün alındığı regresyon ve sinir ağlarının uygulanmasına dayalı iki adet model geliştirmişlerdir. Geliştirdikleri her iki modelin de yüzey pürüzlülüğü tahmini için uygun olduğu sonucuna varmışlardır[30].

Yapılan çalışmalar incelendiğinde talaşlı imalat sektöründe yüzey pürüzlülüğü, kesme kuvveti ve kesme bölgesinde oluşan sıcaklık değerlerini tahmin etmek için farklı makine öğrenmesi modellerinin kullanıldığı görülmektedir. Günümüzde neredeyse her alanda otomasyona geçildiği düşünüldüğünde bu bilgilerin tahminine her geçen gün çok daha fazla gereksinim duyulmaktadır.

Bu çalışmanın amacı, malzemelerin talaşlı imalat yöntemleriyle işlenmesinde belirli malzemeler için veri seti baz alınarak kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklıkları, makine öğrenmesi yöntemlerini kullanarak tespit etmektir. Makine öğrenmesi için gerekli olan veri seti, 16MnCr5 iş malzemesini kullanarak yaptığımız kuru tornalama deneyleri esnasında en düşük kesme kuvveti değerlerinin ölçüldüğü işleme parametreleri ve sıcaklık değerlerinden oluşmaktadır. Amacımız kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklığı tespit etmek olduğu için, verilerin güvenilirliğini artırmak adına aynı kesme parametreleri ile onar kez tekrarlanan (Kesme hızı:150 m/dak, ilerleme: 0.15 mm/dev ve kesme derinliği: 0.4 mm parametreleriyle 9 adet tekrarlı deney yapılmıştır.) 43 farklı deney yapılmıştır. Oluşturulan veri seti, bu deneyler esnasında dinamometre ile ölçerek kaydettiğimiz en

düşük kesme kuvveti ve bu değerlerin ölçüldüğü deney parametre değerleri ile deneyler esnasında termal kamerayla ölçerek kaydettiğimiz sıcaklık değerleri seçilerek oluşturulmuştur. Oluşturulan veri setiyle gerçekleştirilen makine öğrenmesi ile 16MnCr5 iş malzemesi için girdi parametreleri olarak; kesme hızı, kesme derinliği, ilerleme hızı, malzeme ve kesici takım parametreleri makineye öğretilerek kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklıklar tahmin edilmiştir.

Çalışmanın sonucunda literatürde bulunan diğer çalışmalardan farklı olarak, veri seti baz alınmak suretiyle, istenilen parametre değerleri girilerek kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklık tahmin edileceği için, yapılmak istenen deneyin önceden belirlenen parametreleri için de ara değerler için de deneme yanılma yöntemlerine ihtiyaç duyulmadan, makine öğrenmesi modelinin tahmin ettiği sıcaklığa göre işlem yapılabilir. Belirlenen uygun işleme sıcaklığına göre ideal ortam şartları deney öncesinde sağlanarak deneye başlanacağı için iş parçası aşınmasının, yüzey pürüzlülüğünün, kesme sıvısı tüketiminin, takım aşınmasının ve kesme kuvvetinin azaltılması sağlanarak enerjiden, zamandan ve maliyetten tasarruf edilmiş olacaktır.

3. KURAMSAL TEMELLER


Bu bölümde talaşlı imalat, yüzey pürüzlülüğü, takım aşınması, ön ısıtma yöntemleri, makine öğrenmesi türleri, karar ağacı regresyon, rastgele orman regresyon ve performans metrikleri hakkında genel bilgiler verilmiştir.

3.1. Talaşlı İmalat

Takım tezgâhları aracılığıyla talaş kaldırılarak malzemelere istenilen şekli vermek için kullanılan bir seri üretim yöntemidir. Tornalama, frezeleme, vida açma, delik delme, taşlama yaygın olarak bilinen talaşlı imalat yöntemleridir.

3.2. Tornalama

Tornalama işlemi, yaygın olarak kullanılan önemli bir talaşlı imalat yöntemidir. Dönel hareket yapan malzeme üzerinden kesici takım yardımıyla talaş kaldırılarak parçayı istenilen silindirik şekle getirme işlemidir. Tornalama işlemleri için, işlenecek malzemeye uygun takım ve tezgâhlar tercih edilmesi önemli bir kriterdir. Ayrıca tornalama işlemi, iş parçasının istenilen şekil ve boyuta getirilmesinin yanı sıra işlenmiş ürün üzerinde iyi bir yüzey kalitesi elde etmek için de kullanılmaktadır. Şekil 3.1’de silindirik tornalama işleminin görseli gösterilmektedir.



Şekil 3.1. Silindirik tornalama işlemi

3.3. Yüzey Pürüzlülüğü

İşleme için kullanılan kesici takım ve tezgâhın etkisiyle, işleme esnasında açığa çıkan yüksek sıcaklıkların etkisiyle ya da kesme derinliği, kesme hızı, ilerleme hızı gibi kesme parametreleri nedeniyle iş malzemesi yüzeyinde oluşan mikro ölçekli dalgalanmalara veya çıkıntılara yüzey pürüzlülüğü denir. Tornalama işlemlerinde kaliteli bir yüzey elde etmek için işlenecek malzemenin türüne ve işleme koşullarına bağlı olarak uygun kesici takım, kesme derinliği, ilerleme ve kesme hızı tercihi oldukça önemlidir.

3.4. Takım Aşınması

Malzemeyi işlerken talaş kaldırma sırasında iş malzemesi ile kesici takım arasındaki etkileşimler sebebiyle kesici takımın yüzeyinde yıpranmalar veya deformasyonlar meydana gelmesidir. Takımın aşınması, işlenen malzemenin yüzey kalitesini, takım ömrünü ve işleme ekonomisini olumsuz etkilediği için istenmeyen bir durumdur. Uygun işleme koşullarının sağlanması, kesici takımların bakımlarının yapılması ve zamanında değiştirilmesi ile takım aşınması azaltılarak işleme kalitesi iyileştirilebilmektedir.

3.5. Ön Isıtma Yöntemleri

Ön ısıtılmalı işleme yöntemleri; süper alaşımlar, yapısal seramikler, takım çelikleri, paslanmaz çelikler, yüksek mukavemetli malzemeler gibi işlenmesi zor malzemelerin, takım tezgâhına entegre edilmiş bir ısı kaynağı yardımıyla malzeme yüzeyinin ısıtılarak, direncinin ve akma dayanımının azaltılmasının sağlandığı bir işleme yöntemidir. Seramik gibi talaşlı imalatı neredeyse mümkün olmayan malzemelerin veya çok fazla aşınmaya sebebiyet veren sert malzemelerin daha kolay işlenmesini, iş parçası yüzey kalitesini iyileştirmeyi, malzeme deformasyonunu ve takım aşınmasını en aza indirmeyi hedeflemektedir. Ön ısıtma işlemleri için kaynak olarak lazer, indüksiyon fırını, plazma arkı, alevle (torç), elektrik arkı, TIG kaynağı gibi ısıtma yöntemleri kullanılmaktadır.

3.5.1. İndüksiyonla Isıtma

İndüksiyon ile ısıtma yöntemi, elektromanyetik alanın kullanıldığı temassız bir ısıtma işlemidir. İndüksiyonla ısıtmanın temel prensibi şöyledir; iletken metal malzeme değişken bir manyetik alanın içine dahil edildiğinde malzeme gerilim indüklenir ve indüklenen gerilim ile iletken malzemede yüksek seviyelerde eddy akımları dolaşır. Yüksek seviyelerde dolaşan bu akımlara karşı malzemenin iç direnç göstermesiyle beraber malzemenin hızlı bir şekilde, manyetik alan içinde ısınmasına indüksiyonla ısıtma denir[31].

3.5.2. TIG Tekniği

TIG kaynak makinesine ulaşım, diğer ısı kaynaklarına kıyasla daha kolaydır. Lazer ve plazma gibi ön ısıtılmalı işleme yöntemlerine göre daha ekonomiktir. Noktasal işleme için uygun olduğundan dolayı, iş malzemesinin dar bir kısmını dahi ısıtabilme kabiliyetine sahiptir. Bu teknik ile ısıtma için gerekli akım şiddeti (I) hassas bir şekilde ayarlanabilmektedir. TIG kaynağı, endüstride yaygın olarak kullanılan ark kaynaklarından biridir. Ark, erimeyen elektrot olarak bilinen tungsten elektrot ile iş malzemesi arasında oluşur. Tungsten, iyi bir elektrik iletkeni, ark taşıyıcısı ve yüksek ergime sıcaklığı (3410 °C) nedeniyle iyi bir elektrot malzemesidir. Koruyucu gaz olarak helyum, argon veya bunların karşımı kullanılmaktadır. Dolgu malzemesi olarak ilave tel kullanımı gerekmektedir. İlave tel, kaynak banyosuna el ile ya da otomatik

olarak, önden veya yandan bir sevk aparatı ile verilebilir. Bu yöntemi kullanabilmek için işlenecek malzemelerin elektrik iletkenliğine sahip olmaları gerekmektedir[6].

3.5.3. Elektrik Arkıyla Isıtma

Erimez elektrotlar ya da karbon ile iş malzemesinin hemen önünde bir ark meydana getirilmesiyle hem derinlikte hem de alanda iyi ısı konsantrasyonunun sağlandığı bir ısıtma yöntemidir. Düşük manyetik özelliğe sahip metallerin ısıtılması için verimli bir yöntemdir. Bu yöntem kullanılarak uygulanan ısıtma işleminde temas sıcaklık seviyesinin korunması zahmetlidir ve aşırı ısınma kaynaklı yüzeyde hasar oluşma tehlikesi vardır. Yöntemi kullanabilmek için donanım maliyetini artıran ve işlemeyi zorlaştıran özel düzenekler gereklidir. Ayrıca güçlü ark tutuşması sebebiyle özel korunma ekipmanlarına gereksinim vardır[7].

3.5.4. Gaz Yakıcı Alevle Isıtma

İş malzemesi üzerinde ve kesicinin hemen ön tarafında hareketli gaz yakıcılar kullanılmaktadır. Oksi-asetilen alevi ile ısıtma, bu ısıtma yöntemine örnek olarak verilebilir. Basit ve kolay bir düzeneğe sahiptir ve yatırım masrafının fazla olmaması bu yöntemi kullanışlı kılmaktadır. Düşük elektrik geçirgenliği olan malzemeler bu yöntem ile etkili bir biçimde ısıtılabilir. İş malzemesinin ısıtılması için gereken yüksek ısı girişi için çift gaz yakıcılar kullanılmaktadır. İhmal edilmesi durumunda ısı sınırlaması zor olmakta ve gaz yakıcı alev iş malzemesine doğrudan temas ettiği için yüzeyde hasar oluşabilmektedir[7].

3.5.5. Plazma Arkıyla Isıtma

Plazma arkıyla ısıtma yöntemi, iş parçası ve elektrot arasında gaz üflecinden kısa bir ark geçirilerek yapılan ısıtma yöntemidir. Manyetik olmayan malzemeler, bu yöntemle etkili bir biçimde ısıtılabilir. Bu yöntem ile ısıtma sıcaklığı hemen hemen 22,000 °C'dir. Donanım maliyetinin pahalı olmasına rağmen işleme maliyeti düşüktür. Gürültülü çalışması ve köreltici ışığı bu yöntemin dezavantajları arasında yer almaktadır[7].

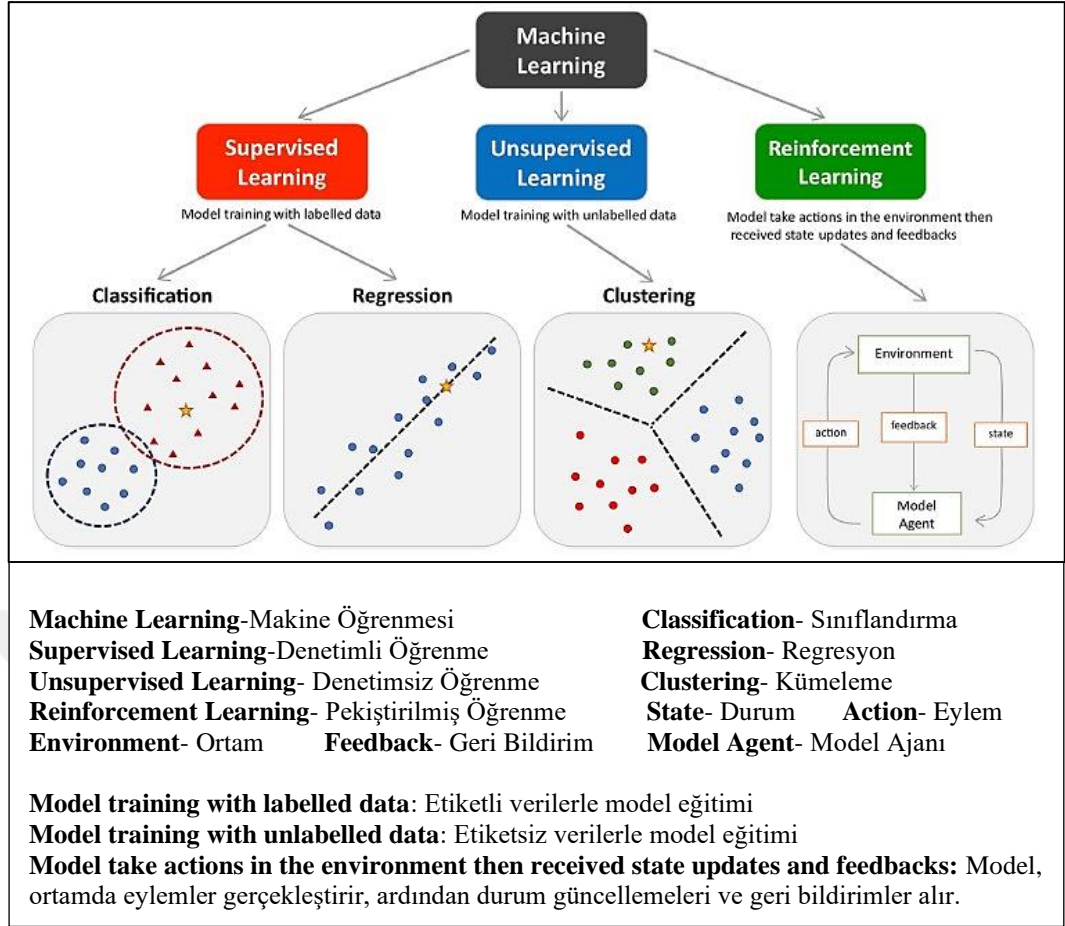
3.5.6. Lazer Destekli İşleme

Lazer destekli işleme, iş malzemesini lokal olarak ısıtmak ve yumuşatmak için harici bir ısı kaynağı olarak lazer ışınının kullanıldığı, termal olarak geliştirilmiş işleme

tekniklerinden biridir. Bu yöntemle, işleme için gereken kesme kuvvetlerinde azalma meydana geldiği gözlemlenmiştir. Çeşitli malzemelerin lazer destekli işlenmesi sırasında takım ömründe bir artış ve daha iyi bir yüzey kalitesi tespit edilmiştir. İşleme sürecine bir lazer ışını uygulamanın temel amacı, malzemenin akma dayanımını ve sertliğini önemli ölçüde azaltarak iş parçasının plastik deformasyonunu kolaylaştırmaktır[13]. Lazer destekli işleme için kullanılan lazer kaynakları genellikle CO2 lazer ve Nd-YAG lazerdir.

3.6. Makine Öğrenmesi (Machine Learning)

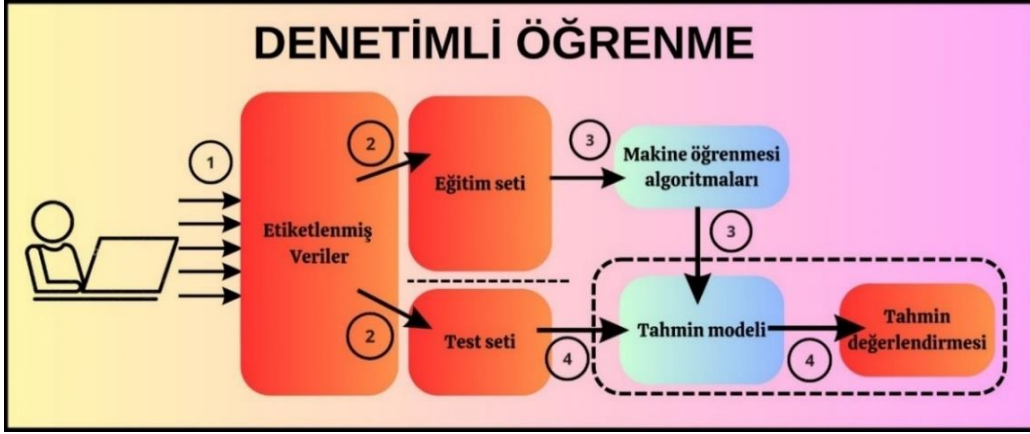
Yapay zekâ kapsamında önde gelen bir alt disiplindir. Veri setlerini referans alarak, bilgisayar sistemlerinin belirli görevleri etkin bir şekilde gerçekleştirebilmesi amacıyla öğrenme yeteneği kazanmalarının sağlandığı teknikler ve algoritmalar bütünüdür. Bu teknikler ve algoritmalar, modelin veri setinde yer alan desenleri tanımasını, veriler arasındaki ilişkileri anlamasını ve bu çerçevede tahminler yapmasını sağlamaktadır. Makine öğrenmesi; denetimsiz, denetimli ve pekiştirilmiş öğrenme olarak üç ana kategoriye ayrılmaktadır. Şekil 3.2’de makine öğrenmesi türleri ve ilgili kavramların Türkçe karşılıkları gösterilmektedir.



Şekil 3.2. Makine öğrenmesi türleri [32] ve ilgili kavramların Türkçe karşılıkları

3.6.1. Denetimli Öğrenme

Model etiketlenmiş veriler kullanılarak eğitilmektedir. Etiketlenmiş veriler, girdi verileri ile ilişkilendirilen doğru çıktıları ifade etmektedir. Denetimli öğrenme modeli, veri setini baz alarak kendisine öğretilen özelliklerden (bağımsız değişkenlerden) faydalanarak, hedef (bağımlı) değişkeni tahmin eder. Regresyon ve sınıflandırma problemlerini çözmek amacıyla kullanılmaktadır. Şekil 3.3'te denetimli öğrenme modelinin şematik olarak görselleştirilmesi gösterilmiştir.



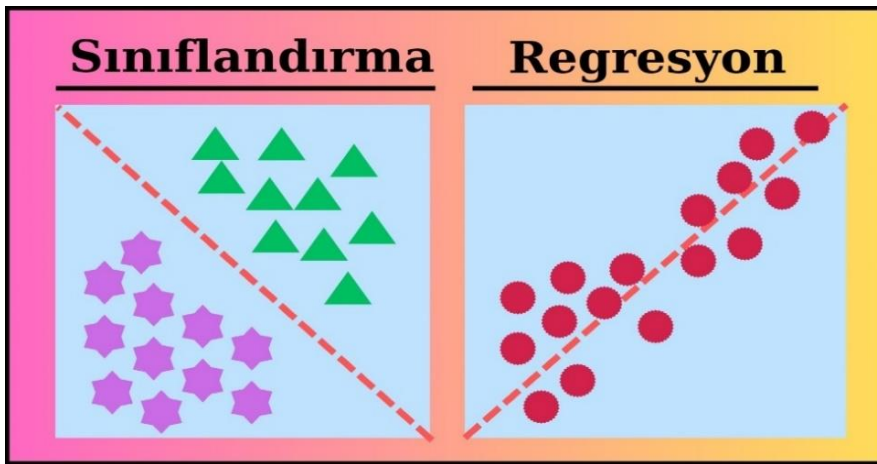
Şekil 3.3. Denetimli öğrenme modelinin şematik gösterimi

3.6.1.1. Sınıflandırma

Algoritmanın hedefi, giriş verilerini belirlenmiş bir sınıfa ya da kategoriye ayırmaktır. E-postaların filtrelendirilmesinde sınıflandırma tekniği kullanılmaktadır. Bir e-postanın 'spam' ya da 'spam değil' şeklinde sınıflandırılması bu kategoriye örnektir.

3.6.1.2. Regresyon

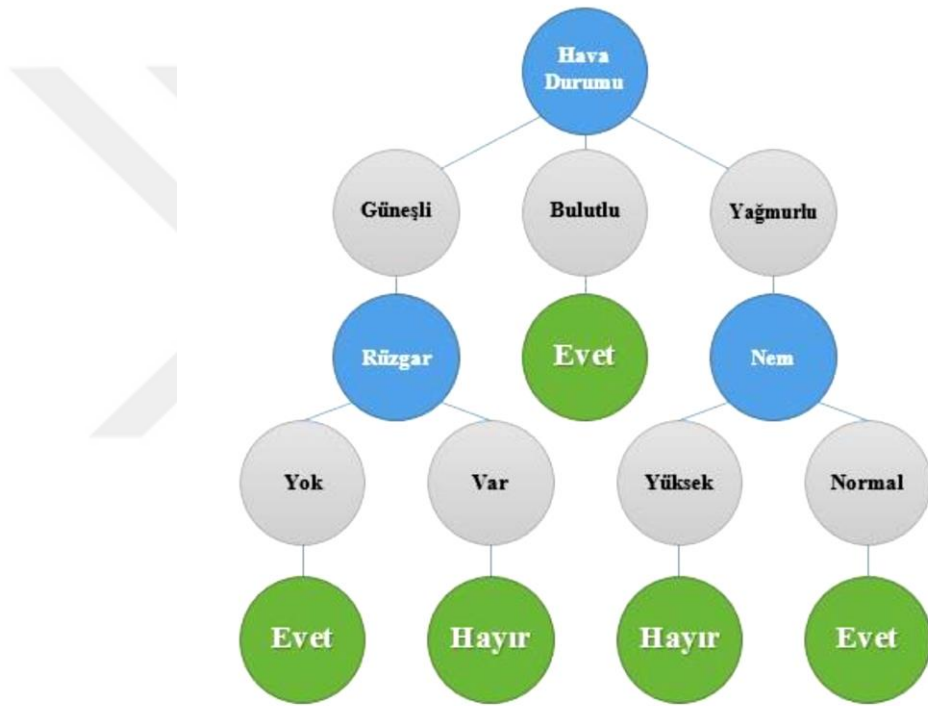
Regresyon algoritmalarının amacı sürekli ve sayısal verileri modellemek ve tahmin etmektir. Bağımsız değişkenleri (girdi verileri) ve aralarındaki ilişkiyi analiz ederek bu verilere karşılık gelen bağımlı değişkeni (hedef) tahmin eder. Konut fiyatlarının değerlendirilmesinde; evin konumu, oda sayısı, büyüklüğü, cephesi gibi özellikler içeren bir veri seti kullanılarak oluşturulan model ile evin fiyatı hakkında tahminlerde bulunulması bu kategoriye örnektir. Şekil 3.4'te sınıflandırma ve regresyon modellerinin şematik olarak görselleştirilmesi gösterilmiştir.



Şekil 3.4. Sınıflandırma ve regresyon modellerinin şematik gösterimi

3.6.1.2.1. Karar Ağacı Regresyon (Decision Tree Regression)


Veri setinde bulunan girdi verileri ile çıktı verisi arasındaki bağlantıyı modellemek amacıyla kullanılır. Her bir bağımsız değişken için bir bölme kriteri belirlenerek veri seti bölünür ve bir ağaç yapısı oluşturulur. Ancak veri setinde bulunan özelliklerin kompleks ilişkilerini temsil etmek için tek ağaç yapısı kullanılması sebebiyle aşırı uyum (overfitting) tehlikesi bulunmaktadır. Aşırı uyum, eğitim verilerine olması gerekenden fazla uyum göstermesi ya da eğitim verilerini ezberlemesidir ve modelin performansını olumsuz etkilediği için istenmeyen bir durumdur. Şekil 3.5'te karar ağacı regresyon modelinin görselleştirilmesi gösterilmektedir.



Şekil 3.5. Karar ağacı regresyon modelinin görselleştirilmesi [33]

3.6.1.2.2. Rastgele Orman Regresyon (Random Forest Regression)

Birden fazla karar ağacının (ensemble) birleşerek etkili bir tahmin modeli oluşturduğu regresyon metodudur. Her bir ağaç, eğitim verilerinden gelişigüzel örnekler (boots trap sampling) seçilerek oluşturulur. Bu yöntem, her ağacın farklı veri alt grupları üzerinde eğitilmesini sağladığı için ağaçlar birbirinden değişik olup, genelleme yeteneği yüksektir. Bu çeşitlilik, ensemble modelinin aşırı uyum (overfitting) riskini düşürmektedir. Şekil 3.6'da rastgele orman regresyon modelinin görselleştirilmesi ve ilgili kavramların Türkçe karşılıkları gösterilmiştir.



Input dataset: Girdi veri seti → Ağaç-1, Ağaç-2,Ağaç-n
Average all predictions: Tüm tahminlerin ortalaması alınır
Random forest predictions: Rastgele orman tahminleri

Şekil 3.6. Rastgele orman regresyon modelinin görselleştirilmesi [34] ve ilgili kavramların Türkçe karşılıkları

3.6.2. Denetimsiz Öğrenme

Veriler üzerinde etiketlerin veya bağımlı değişkenin olmadığı durumlarda kullanılan öğrenme türüdür. Denetimsiz öğrenmede model, veri setinde bulunan yapıları keşfetmeye çalışır ve verileri birbirine olan benzerliklerine (renk, şekil, boyut vb.) göre sınıflandırır. Boyut azaltma ve kümeleme gibi vazifelerde kullanılır. Örneğin, müşteri verilerini analiz ederek benzer alışveriş alışkanlıklarına sahip müşteri grupları oluşturmak için bu model kullanılır. Şekil 3.7’de denetimsiz öğrenme modelinin görselleştirilmesi gösterilmiştir.

olmaktadır. Talaşlı imalat sektöründe ise Gündüz (2006) tarafından yapılan çalışmada, PA malzemeleri CNC torna tezgâhında işlenerek ilerleme hızı, kesme derinliği ve kesme hızı parametrelerine bağlı olarak kesici uca etki eden kesme kuvvetleri dinamometre ile ölçülmüştür. Yapay sinir ağları ve bulanık mantık teknikleri kullanılarak, kesme kuvveti için tahmin modelleri oluşturulup, deneyler sonucunda elde edilen veriler ile karşılaştırılarak değerlendirilmiş ve kesme kuvvetlerinin tahmin edilmesinde hangi metodun daha uygun olduğu araştırılmıştır. Çalışmanın sonucunda, kesme kuvveti tahmini için bulanık mantık yönteminin yapay sinir ağları yöntemine göre daha başarılı olduğu tespit edilmiştir[35]. Tosun vd. (2002), tarafından yapılan çalışmada, alevle ısıtılan yüksek manganlı çelik numuneler kullanılan tornalama işlemlerinde, kesme hızı, ilerleme hızı, kesme derinliği ve yüzey sıcaklıkları gibi parametrelerle farklı kesme koşullarında deneyler yapılmış ve takım ömrünün tahmini için regresyon ve yapay sinir ağları metotları kullanılmıştır[8].

Yukarıda bahsedilen çalışmalar değerlendirildiğinde, malzemelerin belirli sıcaklık değerlerinde işlenmesinin kolaylaştığı gözlemlenmiş ancak işlemeyi kolaylaştıracak sıcaklığın tespit edilmesi amacıyla makine öğrenmesi modellerinin kullanıldığı bir çalışma olmadığı belirlenmiştir. Bu nedenle çalışmanın sonucunda, veri seti baz alınarak modele girilen kesme parametreleri, kesici takım ve malzeme için istenilen işleme parametrelerine karşılık gelen kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklığı tahmin edecek makine öğrenmesi modeli oluşturulmuştur.

4. MATERYAL VE YÖNTEM

4.1. İş Parçası

Deneyleerde Şekil 4.1'de gösterilen 16MnCr5 iş malzemesi tornalanmıştır. İş malzemesi, çap 40 mm'den işlenmeye başlanmış ve 75 mm boyunca işlenmiştir.



Şekil 4.1. 16MnCr5 iş malzemesi

Bu çalışmanın amacı, malzemelerin tornalanmasında kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklığın, makine öğrenmesi yoluyla tahmin edilmesidir. Makine öğrenmesi oluşturabilmek için veri seti gerekli olduğundan örnek olarak 16MnCr5 iş malzemesi kuru kesme koşullarında tornalanmıştır. Deneyleer sonrasında en düşük kesme kuvvetlerinin ölçüldüğü parametre değerleri seçilerek bir veri seti oluşturulmuş ve bu veri seti kullanılarak makine öğrenmesi gerçekleştirilmiştir. Çalışmanın sonucunda oluşturulan makine öğrenmesi modelinde, işleme parametreleri gibi malzeme ve kesici takım parametreleri de kullanılacak olan veri setine bağlı olarak değişkenlik göstermektedir. Oluşturduğumuz makine öğrenmesi modeli, oluşturulan farklı veri setleri içinde kullanılabilir olup farklı malzeme ve kesici takımlar kullanılarak yapılan deneyleer ile oluşturulan yeni veri setleri için de kullanılabilir. Bu sayede işlenmesi zor olan malzemelerle yapılan deneyleer sonucunda; en düşük

kesme kuvveti deęerleri, en dūřuk yūzey pūrūzlūlūk deęerleri ve en az takım ařınmasının elde edildięi parametre deęerleri seęilerek oluřturulan veri setleriyle de yaptığımız bu alıřma sonucunda oluřturulan makine ōęrenmesi modeli kullanılarak kesme bōlgesindeki sıcaklıklar tespit edilebilecektir. Hepsinin bir arada deęerlendirilmesiyle oluřturulan veri setleriyle de en uygun iřleme sıcaklıkları daha yūksek doęruluk oranlarıyla tahmin edilebilecektir.

4.2. Takım Tezgāhı

40 mm apındaki 16MnCr5 iř malzemesinin deneyleri Őekil 4.2’de gōsterilen GOODWAY GLS 150 CNC torna tezgāhında gerekleřtirilmiřtir. Bu tezgāha ait ōzellikler Tablo 4.1’de gōsterilmiřtir.



Őekil 4.2. GOODWAY GLS 150 CNC torna tezgāhı

Tablo 4.1. GOODWAY GLS 150 marka CNC torna tezgâhı teknik özellikleri

Maksimum Çevirme Çapı	Ø 500 mm
Maksimum Tornalama Çapı	Ø 380 mm
Maksimum İşleme Boyu	500 mm
Ayna Ebadı	6"
Çubuk Kapasitesi	Ø 45 mm
İş Mili Delik Çapı	Ø 56 mm
İş Mili Delik Rulman Çapı	Ø 80 mm
İş Mili Devri	6000 dev/dak
İş Mili Normu	A2-5
İş Mili Gücü	15 kw
İş Mili Bağlantı Tipi	Kayış
X/Z Eksen Hareketleri	170 mm/520 mm
X-Z Eksen Motor Gücü	2.7 kW
X-Z Eksen Seri Hareketi	32/32 m/dak
Kızak Yapısı	Lineer
Taret İstasyon Sayısı	12
Taret İndeks Zamanı	0.2 sn
Kare Takım Ebadı	25 mm
Yuvarlak Takım Ebadı	40 mm
Punta Pinolü	MT-4
Punta Pinol Çapı/Hareketi	Ø 70/150 mm
Pozisyonlama Hassasiyeti	0.005
Tekrarlama Hassasiyeti	0.003
Hidrolik Tank Kapasitesi	50 L
Soğutma Tank Kapasitesi	120 L
Makine Ağırlığı	3500 kg
Yerleşim Ölçüsü (Mm)	2260x1490x1675 mm
Kontrol Ünitesi	FANUC
Maksimum Tornalama Çapı (C Eksen)	Ø 280 mm
Maksimum Tornalama Boyu (C Eksen)	340 mm
Canlı Takım Bağlanabilme	12
Canlı Takım Gücü	2.7 kW
Pens Ölçüsü	ER-20
Canlı Takım Devri	4400 mm/dev
Maksimum Tornalama Çapı (Y Eksen)	Ø 280 mm
Y Eksen Motor Gücü	2.7 kW
Y Eksen Hareketi	70 mm=±35

4.3. Kesici Takım

16MnCr5 iş malzemesini tornalamak için Şekil 4.3'te gösterilen Sandvik marka DCLNR 2020K12 kodlu kater ve SM 1105 kalite CNMG 120408 kodlu kesici uç kullanılmıştır.



Şekil 4.3. Kater-Kesici uç

4.4. Kesme Kuvvetlerinin Ölçülmesi

Deneylerde, kesme kuvvetlerinin ölçümü için Şekil 4.4'te gösterilen Kistler marka 9257b model dinamometre kullanılmıştır. Dinamometrenin teknik özellikleri Tablo 4.2'de verilmiştir.



Şekil 4.4. Kistler Dinamometre

Tablo 4.2. Kistler marka 9257b model dinamometrenin teknik özellikleri

Kuvvet aralığı (Fx, Fy, Fz)	(kN)	-5...10
Tepki verme (N)		<0.01
Hassasiyet Fx, Fy	(pC/N)	-7,5
Fz		-3,5
Doğrusallık		%1 FSO
Histerezis		%0,5 FSO
Doğal frekans $f_0(x,y,z)$	(kHz)	3,5
Çalışma sıcaklığı	(°C)	0...70
Kapasitans	(pF)	220
20°C'deki yalıtım direnci	(Ω)	> 1013
Topraklama sınıfı	(Ω)	> 108
Koruma sınıfı		IP 67
Ağırlık	(kg)	7,3

4.5. Sıcaklık Ölçümü

Tornalama işlemleri esnasında sıcaklık ölçümü için Şekil 4.5'te gösterilen FLIR i50 marka termal kamera kullanılmıştır.




Şekil 4.5. FLIR i50 termal kamera

4.6. Deney Tasarımı

Deneylerde, üç farklı kesme hızı (150,250,350 m/dak), beş farklı kesme derinliği (0.1, 0.2, 0.3, 0.4, 0.5 mm) ve üç farklı ilerleme hızı (0.1, 0.15, 0.2 mm/dev) seçilerek oluşturulan kesme parametreleriyle, 40 mm çapındaki 16MnCr5 iş malzemesi, 75 mm boyunca kuru kesme koşullarında tormalanmıştır. Kesme hızı: 350 m/dak, ilerleme hızı: 0.1, 0.15, 0.2 mm/dev ve kesme derinliği: 0.1, 0.2, 0.3, 0.4, 0.5 mm olan kesme parametreleriyle, her biri için onar adet tekrarlı olmak üzere toplam 150 adet deney; kesme hızı: 250 m/dak, ilerleme hızı: 0.1, 0.15, 0.2 mm/dev ve kesme derinliği: 0.1, 0.2, 0.3, 0.4, 0.5 mm olan kesme parametreleriyle, her biri için onar adet tekrarlı olmak üzere toplam 150 adet deney; kesme hızı: 150 m/dak, ilerleme: 0.1 mm/dev, kesme derinliği: 0.1, 0.2, 0.3 mm olan kesme parametreleriyle, her biri için onar adet tekrarlı olmak üzere 30 adet deney, ilerleme hızı: 0.15 mm/dev ve kesme derinliği: 0.1, 0.2, 0.3, 0.4, 0.5 mm olan kesme parametreleriyle, kesme derinliği: 0.4 için 9 adet tekrarlı, diğerleri için onar adet tekrarlı olmak üzere 49 adet deney, ilerleme hızı: 0.2 mm/dev ve kesme derinliği: 0.1, 0.2, 0.3, 0.4, 0.5 mm olan kesme parametreleriyle, her biri için onar adet tekrarlı olmak üzere 50 adet deney, genel toplamda ise 429 adet deney yapılmıştır.

Deneyler esnasında kesme bölgesindeki sıcaklıklar termal kamera ile kesme kuvveti ise dinamometre ile ölçülerek kaydedilmiştir. Örnek olarak, Şekil 4.6'da kesme hızı: 150 m/dak, kesme derinliği: 0.5 mm, ilerleme hızı: 0.15 mm/dev parametreleriyle yapılan deney sonrasında oluşan işlenmiş yüzey ve aynı parametreler ile yapılan farklı bir deney esnasında termal kamera ile kaydedilen 130 °C sıcaklık değerinin ölçüldüğü fotoğraflar gösterilmektedir.



Şekil 4.6. İşlenmiş yüzey ve termal kamera görüntüsü

Buna ek olarak belirli aralıklarla alınan talaş örnekleri incelenmiştir. Talaş şekli işlemin uygunluğu ve talaş rengi bize uygun işleme sıcaklığı hakkında bilgi vermektedir.

5. SONUÇLAR

16MnCr5 iş malzemesi kullanılarak yapılan kuru tornalama deneyleri sonucunda meydana gelen, en düşük kesme kuvveti değerlerinin ölçüldüğü kesme bölgesindeki sıcaklıkların 50 °C ve 121 °C bulunduğu talaş görüntüleri Şekil 5.1 ve Şekil 5.2’de gösterilmiştir. Şekil 5.1’de kesme hızı: 150 m/dak, kesme derinliği: 0.1 mm ve ilerleme: 0.1 mm/dev parametreleriyle yapılan en düşük kesme kuvvetinin ölçüldüğü ve kesme bölgesindeki sıcaklığın 50 °C bulunduğu kuru tornalama deneyi sonucunda meydana gelen talaşın görüntüsü verilmiştir. Talaşın spiral görüntüsü ve gri renkli olmasıyla işleme parametrelerinin uygun seçildiği ve tornalama esnasında meydana gelen sıcaklık artışının kabul edilebilir olduğu görülmektedir.



Şekil 5.1. Kesme hızı: 150 m/dak, kesme derinliği: 0.1 mm ve ilerleme: 0.1 mm/dev parametreleriyle yapılan en düşük kesme kuvvetinin ölçüldüğü, kesme bölgesindeki sıcaklığın 50 °C bulunduğu kuru tornalama deneyi sonucunda meydana gelen talaşın görüntüsü

Şekil 5.2’de kesme hızı: 150 m/dak, kesme derinliği: 0.4 mm ve ilerleme: 0.2 mm/dev parametreleriyle yapılan en düşük kesme kuvvetinin ölçüldüğü ve kesme bölgesindeki sıcaklığın 121 °C bulunduğu kuru tornalama deneyi sonucunda meydana gelen talaşın görüntüsü gösterilmiştir.



Şekil 5.2. Kesme hızı: 150 m/dak, kesme derinliği: 0.4 mm ve ilerleme: 0.2 mm/dev parametreleriyle yapılan en düşük kesme kuvvetinin ölçüldüğü, kesme bölgesindeki sıcaklığın 121 °C bulunduğu kuru tornalama deneyi sonucunda meydana gelen talaşın görüntüsü

Talaşın spiral şeklinde ve bronz renkte olmasıyla seçilen parametreler ile yapılan tornalama sırasında sıcaklığın arttığı ancak kabul edilebilir bir artış olduğu için seçilen parametrelerin tornalama işlemi için uygun olduğu görülmektedir.

5.1. Veri Seti

Makine öğrenmesi modeli için kullanacağımız veri seti, aynı parametreler ile onar adet tekrarlanarak (Kesme hızı: 150 m/dak, ilerleme: 0.15 mm/dev ve kesme derinliği: 0.4 mm parametreleriyle 9 adet tekrarlı deney yapılmıştır.) ölçülen kesme kuvveti değerleri arasından, en düşük kesme kuvvetinin ölçüldüğü sıcaklık değerleri ve bu değerlerin ölçüldüğü deney parametreleri seçilerek oluşturulmuştur. 16MnCr5 iş malzemesini kullanarak yaptığımız kuru tornalama deney parametreleri Tablo 5.1’de gösterilmektedir.

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
1	350	0,3	0,1	82	128
2	350	0,3	0,1	102	138
3	350	0,3	0,1	110	131
4	350	0,3	0,1	112	133
5	350	0,3	0,1	120	142
6	350	0,3	0,1	126	133
7	350	0,3	0,1	146	147
8	350	0,3	0,1	179	139
9	350	0,3	0,1	167	136
10	350	0,3	0,1	180	141
11	350	0,2	0,1	158	106
12	350	0,2	0,1	175	106
13	350	0,2	0,1	187	103
14	350	0,2	0,1	169	106
15	350	0,2	0,1	165	101
16	350	0,2	0,1	148	103
17	350	0,2	0,1	137	106
18	350	0,2	0,1	187	107
19	350	0,2	0,1	159	107
20	350	0,2	0,1	178	104
21	350	0,1	0,1	110	71
22	350	0,1	0,1	117	75
23	350	0,1	0,1	113	72
24	350	0,1	0,1	112	72
25	350	0,1	0,1	135	70
26	350	0,1	0,1	140	71
27	350	0,1	0,1	146	69
28	350	0,1	0,1	150	70
29	350	0,1	0,1	150	73
30	350	0,1	0,1	146	77
31	350	0,3	0,15	82	142
32	350	0,3	0,15	99	143
33	350	0,3	0,15	104	145
34	350	0,3	0,15	112	157
35	350	0,3	0,15	110	149
36	350	0,3	0,15	110	139
37	350	0,3	0,15	138	145
38	350	0,3	0,15	101	148
39	350	0,3	0,15	122	142
40	350	0,3	0,15	131	152

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
41	350	0,2	0,15	96	100
42	350	0,2	0,15	110	98
43	350	0,2	0,15	125	104
44	350	0,2	0,15	104	99
45	350	0,2	0,15	113	101
46	350	0,2	0,15	117	97
47	350	0,2	0,15	108	99
48	350	0,2	0,15	123	104
49	350	0,2	0,15	119	107
50	350	0,2	0,15	109	105
51	350	0,1	0,15	118	67
52	350	0,1	0,15	91	61
53	350	0,1	0,15	96	65
54	350	0,1	0,15	104	66
55	350	0,1	0,15	111	67
56	350	0,1	0,15	104	67
57	350	0,1	0,15	102	64
58	350	0,1	0,15	97	69
59	350	0,1	0,15	111	67
60	350	0,1	0,15	114	69
61	350	0,3	0,2	87	150
62	350	0,3	0,2	93	156
63	350	0,3	0,2	98	160
64	350	0,3	0,2	104	159
65	350	0,3	0,2	108	160
66	350	0,3	0,2	104	161
67	350	0,3	0,2	113	159
68	350	0,3	0,2	114	161
69	350	0,3	0,2	122	156
70	350	0,3	0,2	118	157
71	350	0,2	0,2	52,8	108
72	350	0,2	0,2	61	116
73	350	0,2	0,2	58	117
74	350	0,2	0,2	74	117
75	350	0,2	0,2	59	116
76	350	0,2	0,2	82	116
77	350	0,2	0,2	93	119
78	350	0,2	0,2	71	118
79	350	0,2	0,2	94	118
80	350	0,2	0,2	103	117

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
81	350	0,1	0,2	77	67
82	350	0,1	0,2	80	70
83	350	0,1	0,2	75	72
84	350	0,1	0,2	85	71
85	350	0,1	0,2	72	72
86	350	0,1	0,2	81	71
87	350	0,1	0,2	73	72
88	350	0,1	0,2	75	70
89	350	0,1	0,2	74	71
90	350	0,1	0,2	71	70
91	350	0,5	0,1	122	174
92	350	0,5	0,1	119	178
93	350	0,5	0,1	160	178
94	350	0,5	0,1	134	181
95	350	0,5	0,1	185	179
96	350	0,5	0,1	167	181
97	350	0,5	0,1	198	183
98	350	0,5	0,1	175	187
99	350	0,5	0,1	179	189
100	350	0,5	0,1	172	198
101	350	0,4	0,1	169	173
102	350	0,4	0,1	199	179
103	350	0,4	0,1	213	182
104	350	0,4	0,1	235	192
105	350	0,4	0,1	202	200
106	350	0,4	0,1	170	204
107	350	0,4	0,1	159	201
108	350	0,4	0,1	190	219
109	350	0,4	0,1	208	222
110	350	0,4	0,1	202	223
111	350	0,5	0,15	194	184
112	350	0,5	0,15	182	188
113	350	0,5	0,15	199	182
114	350	0,5	0,15	218	191
115	350	0,5	0,15	186	192
116	350	0,5	0,15	207	194
117	350	0,5	0,15	234	197
118	350	0,5	0,15	214	196
119	350	0,5	0,15	205	193
120	350	0,5	0,15	203	195

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
121	350	0,4	0,15	178	159
122	350	0,4	0,15	196	165
123	350	0,4	0,15	199	164
124	350	0,4	0,15	188	165
125	350	0,4	0,15	194	162
126	350	0,4	0,15	189	161
127	350	0,4	0,15	192	165
128	350	0,4	0,15	194	165
129	350	0,4	0,15	188	163
130	350	0,4	0,15	199	165
131	350	0,5	0,2	86	210
132	350	0,5	0,2	74	219
133	350	0,5	0,2	85	218
134	350	0,5	0,2	84	221
135	350	0,5	0,2	79	221
136	350	0,5	0,2	92	221
137	350	0,5	0,2	93	224
138	350	0,5	0,2	103	222
139	350	0,5	0,2	74	224
140	350	0,5	0,2	74	222
141	350	0,4	0,2	86	189
142	350	0,4	0,2	95	185
143	350	0,4	0,2	74	182
144	350	0,4	0,2	81	185
145	350	0,4	0,2	78	189
146	350	0,4	0,2	82	190
147	350	0,4	0,2	86	192
148	350	0,4	0,2	74	195
149	350	0,4	0,2	74	186
150	350	0,4	0,2	75	188
151	250	0,3	0,1	87	108
152	250	0,3	0,1	78	107
153	250	0,3	0,1	88	110
154	250	0,3	0,1	91	107
155	250	0,3	0,1	92	108
156	250	0,3	0,1	91	109
157	250	0,3	0,1	97	111
158	250	0,3	0,1	105	112
159	250	0,3	0,1	102	113
160	250	0,3	0,1	113	115

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
161	250	0,2	0,1	96	87
162	250	0,2	0,1	96	82
163	250	0,2	0,1	101	85
164	250	0,2	0,1	98	89
165	250	0,2	0,1	102	86
166	250	0,2	0,1	136	88
167	250	0,2	0,1	92	86
168	250	0,2	0,1	104	87
169	250	0,2	0,1	95	88
170	250	0,2	0,1	111	87
171	250	0,1	0,1	65	47
172	250	0,1	0,1	66	45
173	250	0,1	0,1	92	45
174	250	0,1	0,1	69	48
175	250	0,1	0,1	70	49
176	250	0,1	0,1	71	49
177	250	0,1	0,1	95	51
178	250	0,1	0,1	71	49
179	250	0,1	0,1	71	49
180	250	0,1	0,1	82	48
181	250	0,3	0,15	73	129
182	250	0,3	0,15	79	129
183	250	0,3	0,15	91	129
184	250	0,3	0,15	95	129
185	250	0,3	0,15	101	131
186	250	0,3	0,15	82	129
187	250	0,3	0,15	88	126
188	250	0,3	0,15	102	129
189	250	0,3	0,15	82	132
190	250	0,3	0,15	113	131
191	250	0,2	0,15	105	99
192	250	0,2	0,15	93	95
193	250	0,2	0,15	92	97
194	250	0,2	0,15	85	96
195	250	0,2	0,15	87	97
196	250	0,2	0,15	107	98
197	250	0,2	0,15	82	97
198	250	0,2	0,15	101	100
199	250	0,2	0,15	87	100
200	250	0,2	0,15	94	99

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
201	250	0,1	0,15	73	57
202	250	0,1	0,15	71	57
203	250	0,1	0,15	65	57
204	250	0,1	0,15	75	56
205	250	0,1	0,15	73	52
206	250	0,1	0,15	64	53
207	250	0,1	0,15	64	53
208	250	0,1	0,15	62	53
209	250	0,1	0,15	76	53
210	250	0,1	0,15	62	56
211	250	0,3	0,2	68	132
212	250	0,3	0,2	77	140
213	250	0,3	0,2	94	142
214	250	0,3	0,2	107	140
215	250	0,3	0,2	93	139
216	250	0,3	0,2	95	139
217	250	0,3	0,2	83	142
218	250	0,3	0,2	87	138
219	250	0,3	0,2	87	145
220	250	0,3	0,2	86	145
221	250	0,2	0,2	75	101
222	250	0,2	0,2	81	103
223	250	0,2	0,2	89	104
224	250	0,2	0,2	90	103
225	250	0,2	0,2	71	106
226	250	0,2	0,2	76	103
227	250	0,2	0,2	78	104
228	250	0,2	0,2	76	102
229	250	0,2	0,2	71	103
230	250	0,2	0,2	82	104
231	250	0,1	0,2	84	61
232	250	0,1	0,2	84	62
233	250	0,1	0,2	80	65
234	250	0,1	0,2	68	61
235	250	0,1	0,2	70	57
236	250	0,1	0,2	67	51
237	250	0,1	0,2	74	55
238	250	0,1	0,2	77	61
239	250	0,1	0,2	65	60
240	250	0,1	0,2	73	58

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
241	250	0,5	0,1	149	139
242	250	0,5	0,1	148	140
243	250	0,5	0,1	164	141
244	250	0,5	0,1	181	141
245	250	0,5	0,1	163	143
246	250	0,5	0,1	166	143
247	250	0,5	0,1	173	140
248	250	0,5	0,1	135	142
249	250	0,5	0,1	148	135
250	250	0,5	0,1	150	140
251	250	0,4	0,1	135	121
252	250	0,4	0,1	137	117
253	250	0,4	0,1	161	117
254	250	0,4	0,1	153	115
255	250	0,4	0,1	180	118
256	250	0,4	0,1	163	116
257	250	0,4	0,1	146	110
258	250	0,4	0,1	138	115
259	250	0,4	0,1	151	118
260	250	0,4	0,1	113	125
261	250	0,5	0,15	103	188
262	250	0,5	0,15	115	198
263	250	0,5	0,15	121	196
264	250	0,5	0,15	130	199
265	250	0,5	0,15	122	202
266	250	0,5	0,15	128	243
267	250	0,5	0,15	130	193
268	250	0,5	0,15	133	203
269	250	0,5	0,15	138	198
270	250	0,5	0,15	130	211
271	250	0,4	0,15	130	169
272	250	0,4	0,15	140	187
273	250	0,4	0,15	125	169
274	250	0,4	0,15	136	159
275	250	0,4	0,15	132	169
276	250	0,4	0,15	127	177
277	250	0,4	0,15	144	165
278	250	0,4	0,15	134	167
279	250	0,4	0,15	136	178
280	250	0,4	0,15	135	171

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
281	250	0,5	0,2	160	296
282	250	0,5	0,2	148	214
283	250	0,5	0,2	164	211
284	250	0,5	0,2	192	233
285	250	0,5	0,2	186	214
286	250	0,5	0,2	185	222
287	250	0,5	0,2	184	212
288	250	0,5	0,2	204	225
289	250	0,5	0,2	207	210
290	250	0,5	0,2	245	218
291	250	0,4	0,2	199	231
292	250	0,4	0,2	193	206
293	250	0,4	0,2	186	184
294	250	0,4	0,2	199	176
295	250	0,4	0,2	170	185
296	250	0,4	0,2	183	225
297	250	0,4	0,2	198	195
298	250	0,4	0,2	207	189
299	250	0,4	0,2	229	207
300	250	0,4	0,2	212	213
301	150	0,3	0,1	73	72
302	150	0,3	0,1	82	75
303	150	0,3	0,1	78	74
304	150	0,3	0,1	80	78
305	150	0,3	0,1	81	77
306	150	0,3	0,1	78	73
307	150	0,3	0,1	84	76
308	150	0,3	0,1	75	79
309	150	0,3	0,1	75	79
310	150	0,3	0,1	79	78
311	150	0,2	0,1	66	52
312	150	0,2	0,1	66	54
313	150	0,2	0,1	61	54
314	150	0,2	0,1	69	54
315	150	0,2	0,1	63	58
316	150	0,2	0,1	60	49
317	150	0,2	0,1	64	55
318	150	0,2	0,1	61	66
319	150	0,2	0,1	63	58
320	150	0,2	0,1	68	56

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
321	150	0,1	0,1	58	29
322	150	0,1	0,1	64	34
323	150	0,1	0,1	50	27
324	150	0,1	0,1	54	29
325	150	0,1	0,1	52	30
326	150	0,1	0,1	55	33
327	150	0,1	0,1	51	29
328	150	0,1	0,1	49	36
329	150	0,1	0,1	51	34
330	150	0,1	0,1	51	29
331	150	0,3	0,15	64	64
332	150	0,3	0,15	69	103
333	150	0,3	0,15	63	104
334	150	0,3	0,15	73	102
335	150	0,3	0,15	77	103
336	150	0,3	0,15	80	105
337	150	0,3	0,15	72	104
338	150	0,3	0,15	76	102
339	150	0,3	0,15	70	104
340	150	0,3	0,15	73	104
341	150	0,2	0,15	60	67
342	150	0,2	0,15	60	68
343	150	0,2	0,15	59	71
344	150	0,2	0,15	58	70
345	150	0,2	0,15	61	69
346	150	0,2	0,15	61	69
347	150	0,2	0,15	62	70
348	150	0,2	0,15	61	72
349	150	0,2	0,15	64	71
350	150	0,2	0,15	58	70
351	150	0,1	0,15	49	39
352	150	0,1	0,15	51	37
353	150	0,1	0,15	53	37
354	150	0,1	0,15	53	37
355	150	0,1	0,15	54	37
356	150	0,1	0,15	56	39
357	150	0,1	0,15	51	39
358	150	0,1	0,15	51	36
359	150	0,1	0,15	52	38
360	150	0,1	0,15	57	40

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
361	150	0,3	0,2	64	129
362	150	0,3	0,2	71	136
363	150	0,3	0,2	76	137
364	150	0,3	0,2	75	139
365	150	0,3	0,2	87	139
366	150	0,3	0,2	72	141
367	150	0,3	0,2	75	138
368	150	0,3	0,2	78	138
369	150	0,3	0,2	76	142
370	150	0,3	0,2	84	139
371	150	0,2	0,2	74	92
372	150	0,2	0,2	67	87
373	150	0,2	0,2	68	89
374	150	0,2	0,2	63	89
375	150	0,2	0,2	65	89
376	150	0,2	0,2	62	91
377	150	0,2	0,2	65	90
378	150	0,2	0,2	77	91
379	150	0,2	0,2	69	89
380	150	0,2	0,2	73	89
381	150	0,1	0,2	54	49
382	150	0,1	0,2	54	44
383	150	0,1	0,2	55	45
384	150	0,1	0,2	60	45
385	150	0,1	0,2	68	46
386	150	0,1	0,2	55	45
387	150	0,1	0,2	57	46
388	150	0,1	0,2	58	45
389	150	0,1	0,2	53	45
390	150	0,1	0,2	52	46
391	150	0,5	0,15	130	176
392	150	0,5	0,15	111	191
393	150	0,5	0,15	119	182
394	150	0,5	0,15	119	180
395	150	0,5	0,15	116	179
396	150	0,5	0,15	127	186
397	150	0,5	0,15	121	146
398	150	0,5	0,15	130	194
399	150	0,5	0,15	134	184
400	150	0,5	0,15	137	216

Tablo 5.1. 16MnCr5 kuru tornalama deney sonuçları (devamı)

Deney No	Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	İşleme Sıcaklığı (°C)	Ort. Kesme Kuvveti (N)
401	150	0,4	0,15	124	182
402	150	0,4	0,15	140	102
403	150	0,4	0,15	117	176
404	150	0,4	0,15	113	161
405	150	0,4	0,15	106	128
406	150	0,4	0,15	99	132
407	150	0,4	0,15	111	148
408	150	0,4	0,15	137	169
409	150	0,4	0,15	122	129
410	150	0,5	0,2	105	205
411	150	0,5	0,2	103	218
412	150	0,5	0,2	116	216
413	150	0,5	0,2	129	214
414	150	0,5	0,2	114	211
415	150	0,5	0,2	135	213
416	150	0,5	0,2	124	203
417	150	0,5	0,2	123	210
418	150	0,5	0,2	138	211
419	150	0,5	0,2	124	209
420	150	0,4	0,2	117	165
421	150	0,4	0,2	133	164
422	150	0,4	0,2	135	164
423	150	0,4	0,2	140	166
424	150	0,4	0,2	121	161
425	150	0,4	0,2	116	162
426	150	0,4	0,2	117	164
427	150	0,4	0,2	130	165
428	150	0,4	0,2	132	164
429	150	0,4	0,2	171	162

Veri seti oluşturulurken, kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklığı tespit etmeyi amaçladığımız için, 429 adet olan veri sayısı (Tablo 5.1’de gösterilmiştir) onar adet tekrarlanarak yapılan (Kesme hızı:150 m/dak, ilerleme: 0.15 mm/dev ve kesme derinliği: 0.4 mm parametreleriyle 9 adet tekrarlı deney yapılmıştır.) deney parametrelerinden en düşük kesme kuvvetinin elde edildiği sıcaklık değerleri ve bu değerlerin ölçüldüğü deney parametreleri seçilerek oluşturulduğu için 43 adet veriye düşürülmüştür. İleri zamanlarda çok daha fazla gelişeceği düşünülen akıllı

imalat teknolojileriyle birlikte, imalatta kullanılan tezgâhlar işleme koşullarına kendileri karar verebileceklerdir. Bu koşullar için gereken önemli ihtiyaçlardan birisi ise malzemenin işleme sıcaklığı yani ön ısıtılma ya da soğutulma sıcaklığıdır. Yaptığımız bu çalışma, imalat sanayisinde ileri dönemler için karanlık fabrikalara geçileceği, dijitalleşeceği ve insana olan ihtiyacın azalacağı düşünüldüğünde, nasıl bir veri tabanı oluşturulması gerektiği hakkında başlangıç çalışması olacak ve literatüre katkı sağlayacaktır.

Oluşturduğumuz makine öğrenmesi modelinde, en düşük kesme kuvveti değerlerinin ölçüldüğü parametre değerleri seçilerek oluşturulan veri seti kullanılmıştır. Yaptığımız bu çalışma ile aynı şekilde en düşük yüzey pürüzlülüğünün ölçüldüğü, en az takım aşınması değerlerinin ölçüldüğü deney parametre değerleri kullanılarak da kesme bölgesindeki sıcaklıklar tahmin edilebilecektir.

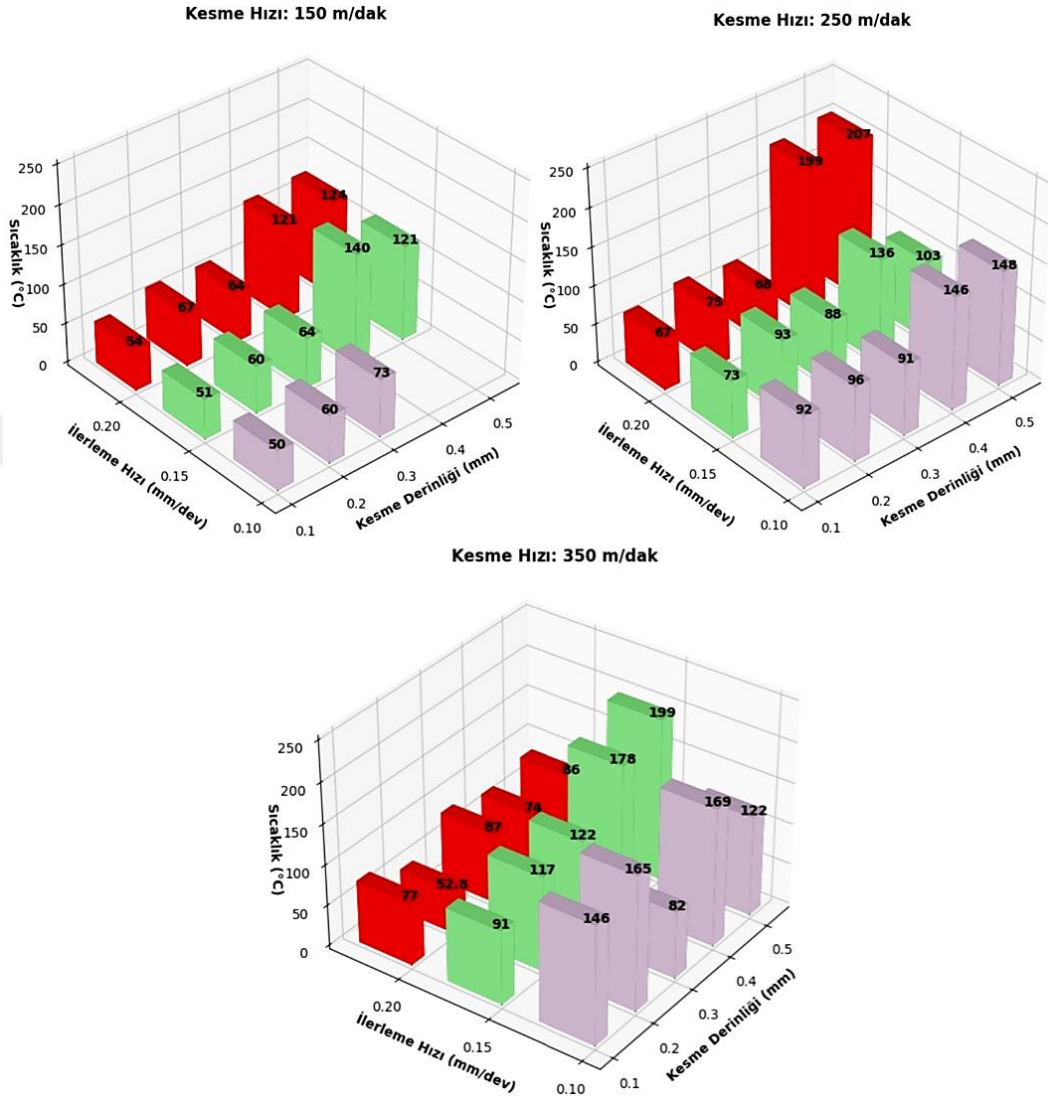
Oluşturduğumuz makine öğrenmesi modeli ile hepsinin bir arada değerlendirilmesiyle ve veri sayısının artırılmasıyla oluşturulan yeni veri setleri ile yapılacak olan tahminlerle çok daha iyi sonuçlar elde edilebilecek ve en uygun işleme sıcaklıklarının tahmin edilmesine çok daha fazla yaklaşılabilecektir.

Oluşturulan veri seti Tablo 5.2’de gösterilmiştir.

Tablo 5.2. Veri seti (Dataset)

Kesme_Hızı (m/dak)	Kesme_Deriniği (mm)	İlerleme (mm/dev)	Malzeme	Kesici_Takım	Sıcaklık (°C)
350	0,3	0,2	16MnCr5	CNMG120408	87
350	0,2	0,2	16MnCr5	CNMG120408	52,8
350	0,1	0,2	16MnCr5	CNMG120408	77
350	0,3	0,15	16MnCr5	CNMG120408	122
350	0,2	0,15	16MnCr5	CNMG120408	117
350	0,1	0,15	16MnCr5	CNMG120408	91
350	0,3	0,1	16MnCr5	CNMG120408	82
350	0,2	0,1	16MnCr5	CNMG120408	165
350	0,1	0,1	16MnCr5	CNMG120408	146
350	0,5	0,2	16MnCr5	CNMG120408	86
350	0,4	0,2	16MnCr5	CNMG120408	74
350	0,5	0,15	16MnCr5	CNMG120408	199
350	0,4	0,15	16MnCr5	CNMG120408	178
350	0,5	0,1	16MnCr5	CNMG120408	122
350	0,4	0,1	16MnCr5	CNMG120408	169
250	0,3	0,2	16MnCr5	CNMG120408	68
250	0,2	0,2	16MnCr5	CNMG120408	75
250	0,1	0,2	16MnCr5	CNMG120408	67
250	0,3	0,15	16MnCr5	CNMG120408	88
250	0,2	0,15	16MnCr5	CNMG120408	93
250	0,1	0,15	16MnCr5	CNMG120408	73
250	0,3	0,1	16MnCr5	CNMG120408	91
250	0,2	0,1	16MnCr5	CNMG120408	96
250	0,1	0,1	16MnCr5	CNMG120408	92
250	0,5	0,2	16MnCr5	CNMG120408	207
250	0,4	0,2	16MnCr5	CNMG120408	199
250	0,5	0,15	16MnCr5	CNMG120408	103
250	0,4	0,15	16MnCr5	CNMG120408	136
250	0,5	0,1	16MnCr5	CNMG120408	148
250	0,4	0,1	16MnCr5	CNMG120408	146
150	0,3	0,2	16MnCr5	CNMG120408	64
150	0,2	0,2	16MnCr5	CNMG120408	67
150	0,1	0,2	16MnCr5	CNMG120408	54
150	0,3	0,15	16MnCr5	CNMG120408	64
150	0,2	0,15	16MnCr5	CNMG120408	60
150	0,1	0,15	16MnCr5	CNMG120408	51
150	0,3	0,1	16MnCr5	CNMG120408	73
150	0,2	0,1	16MnCr5	CNMG120408	60
150	0,1	0,1	16MnCr5	CNMG120408	50
150	0,5	0,2	16MnCr5	CNMG120408	124
150	0,4	0,2	16MnCr5	CNMG120408	121
150	0,5	0,15	16MnCr5	CNMG120408	121
150	0,4	0,15	16MnCr5	CNMG120408	140

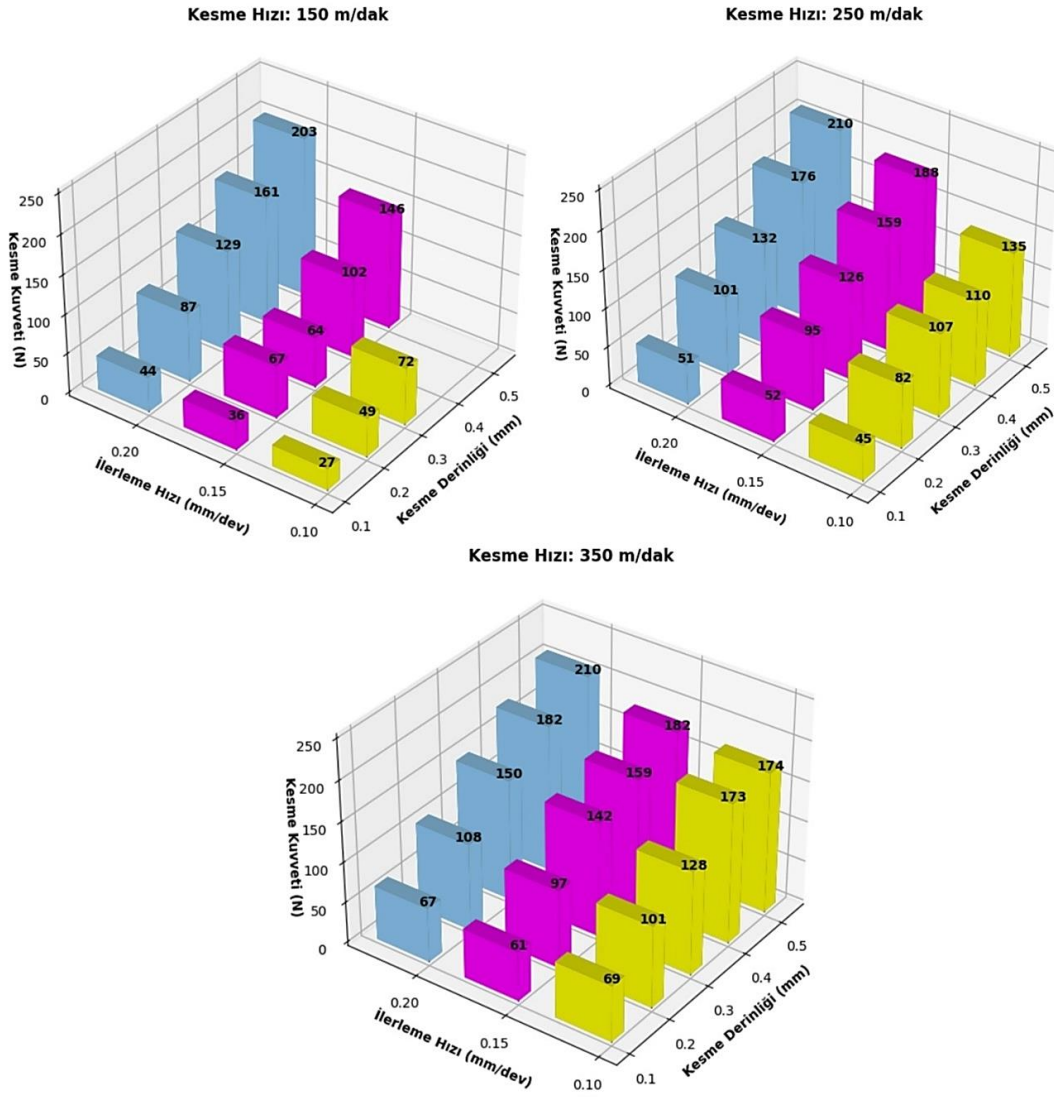
Şekil 5.3'te veri setinde bulunan kesme hızları (150, 250, 350 m/dak) sabit tutularak, farklı işleme parametreleriyle kesme kuvvetini minimum yapan sıcaklık değerlerinin grafikleri gösterilmektedir.



Şekil 5.3. Belirlenen deney parametreleri ile ölçülen sıcaklık değerlerinin grafikleri

Burada grafiklerden de görüleceği üzere işleme şartları zorlaştıkça yani ilerleme veya kesme derinliği arttıkça kesme kuvvetini minimum yapan sıcaklık değeri de artmaktadır. Aynı şekilde kesme hızı değeri arttıkça da sıcaklık gereksinimi artmaktadır. Özellikle dikkat çekilmesi gereken husus, kesme derinliğinin 0.3 mm'nin üzerine çıktığı durumlardaki sıcaklık gereksinimindeki artıştır. Bu değer in altında sınır değeri olduğu rahatlıkla anlaşılmaktadır. Tavsiye edilen, bu değer in altında işlem yapılmasıdır. Lakin bu değer in üstünde yapılacak tornalama işlemlerinde de sıcaklığın

istenilen seviyeye çıkarılması işlemin verimliliğini artırarak işlemeyi kolaylaştıracaktır.



Şekil 5.4. Belirlenen deney parametreleri ile ölçülen minimum kesme kuvveti değerlerinin grafikleri

Şekil 5.4'te veri setinde bulunan kesme hızları (150, 250, 350 m/dak) sabit tutularak, farklı işleme parametreleriyle ölçülen minimum kesme kuvveti değerlerinin grafikleri gösterilmektedir. Şekil 5.4'te ki grafikler değerlendirildiğinde, yapılan deneyler sonucunda ölçülen minimum kesme kuvveti değerlerinin genellikle artan işleme değişkenleri değerlerine paralel olarak artış veya azalan işleme değişkenleri değerlerine paralel olarak azalış gösterdiği görülmektedir. İstisna olan durum ise yüksek kesme hızlarıdır. En yüksek kesme hızı olan 350 m/dak'da ölçülen kesme kuvvetlerindeki minimum değerler, genellikle ilerleme hızının 0.15 mm/dev olduğu durumlarda karşımıza çıkmaktadır ki bu da işleme parametrelerindeki optimum

değerin bu değer olduğuna işaret etmektedir. Aynı şekilde kesme hızının 150 m/dak ve ilerleme hızının 0.15 mm/dev olduğu durumlarda güzel sonuçlar vermektedir. Bu durumda, minimum kesme kuvvetini veren sıcaklık gereksinimi de 50-60 °C civarında yani minimum seviyelerdedir. Bu da bu işleme değişkenleri için enerji gereksiniminin minimum olacağına işaret eder. Şunun da belirtilmesi gerekir ki bu tez çalışması kapsamında uygun işleme değişkenlerinin tespitinden çok makine öğrenmesi modeli ile uygun sıcaklık tahminine odaklanılmıştır.

İleride oluşturulacak akıllı imalat sistemleri ile bu çalışmada kesme kuvveti için örnekleme yapılan sisteme benzer sistemler tezgâhlara entegre edilecek ve elde edilen sonuçlar ile sürekli artan büyük bir veri elde edilecektir. Sistem sürekli kendini yenileyecektir. Aşağıda bu tez çalışması kapsamında oluşturulan makine öğrenmesi modeli ayrıntılarıyla açıklanacaktır.

Makine öğrenmesi modeli, en düşük kesme kuvveti değerlerinin ölçüldüğü deney parametreleri ve ölçülen sıcaklık değerleri seçilerek oluşturulan veri seti kullanılarak Python dili ile Google Colab ortamında geliştirilmiştir. Rastgele orman regresyon (random forest regression) ve karar ağacı regresyon (decision tree regression) algoritmaları kullanılmıştır. Bu modelin tahmin doğruluğunu ölçmek için; R^2 , MSE, MAE ve MAPE gibi performans metrikleri belirlenerek değerlendirilmiştir.

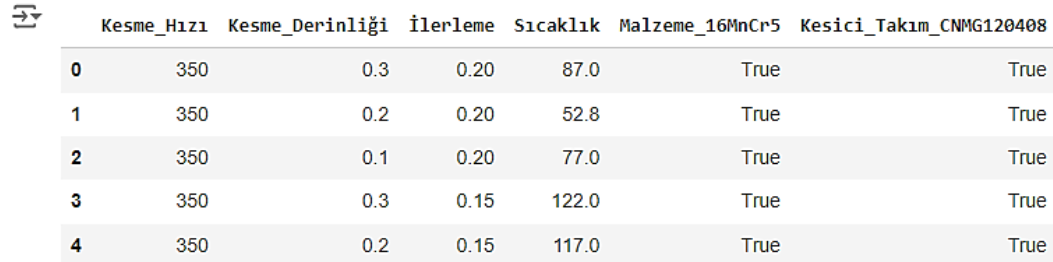
İlk olarak makine öğrenmesi modelini oluşturmak için gereken Numpy ve Pandas kütüphaneleri çağrıldı. Bu kütüphanelerden Numpy kütüphanesi, bilimsel hesaplamalar yapmak amacıyla kullanılan bir kütüphanedir. Bu kütüphane, çok boyutlu diziler (arrays) oluşturmak ve bu diziler üzerinde hızlı matematiksel işlemler gerçekleştirmek için kullanılmaktadır. Pandas kütüphanesi ise, veri manipülasyonu ve veri analizi için kullanılmaktadır. Bu kütüphane; verileri analiz etmek, işlemek, dönüştürmek ve temizlemek için bir dizi veri yapıları ve fonksiyonlar temin etmektedir. Pandas'ın temel veri yapıları DataFrame ve Series'dir.

```
[ ] import numpy as np
import pandas as pd
```

```
[ ] df= pd.read_excel("VeriSeti.xlsx")
```

```
[ ] df=pd.get_dummies(df,columns=[ "Malzeme", "Kesici_Takım"])
```

```
[ ] df.head()
```



	Kesme_Hızı	Kesme_Derinliği	İlerleme	Sıcaklık	Malzeme_16MnCr5	Kesici_Takım_CNMG120408
0	350	0.3	0.20	87.0	True	True
1	350	0.2	0.20	52.8	True	True
2	350	0.1	0.20	77.0	True	True
3	350	0.3	0.15	122.0	True	True
4	350	0.2	0.15	117.0	True	True

Şekil 5.5. Oluşturulan makine öğrenmesi modelinin 1.bölümünün ekran görüntüsü (Google Colab)

Şekil 5.5'te görüldüğü gibi Pandas kütüphanesi kullanılarak 'VeriSeti' isimli ve excel uzantılı veri seti çağrıldı. Daha sonra ise veri setinde yer alan tüm değerlerin numerik olması gerektiği için 'Malzeme ve Kesici_Takım' sütunları Pandas'ın 'get_dummies' yöntemi ile kategorik verilere dönüştürüldü. Düzenlenen veri setinin ilk 5 satırını görmek içinse 'df.head()' komutu kullanıldı.

```
[ ] y=df["Sıcaklık"]
x=df.drop(columns=["Sıcaklık"])
```

```
[ ] from sklearn.preprocessing import StandardScaler
sc_x=StandardScaler()
x=sc_x.fit_transform(x)
```

```
[ ] from sklearn.model_selection import train_test_split
```

Şekil 5.6. Oluşturulan makine öğrenmesi modelinin 2.bölümünün ekran görüntüsü (Google Colab)

Şekil 5.6'da ise tahmin modelini oluşturabilmek için x'e bağımsız değişkenler, y'ye ise bağımlı değişken atandı. Burada tahmin etmek istenilen değer yani 'Sıcaklık' bağımlı (hedef) değişkeni, diğer veriler ise sıcaklığı tahmin etmek için kullanılacak olan bağımsız değişkenleri temsil etmektedir. Daha sonra verilerin özelliklerini standartlaştırmak amacıyla kullanılan bir ön işleme yöntemi olan 'StandardScaler' sınıfı kullanıldı. Bu yöntem, verilerin özelliklerini ortalama değeri 0 ve standart sapması 1 olacak biçimde dönüştürmektedir. Daha sonra ise 'Scikit-learn'

kütüphanesinin 'model_selection' modülünden, oluşturacağımız modeli eğitim ve test olarak ayırabilmek için gereken 'train_test_split' fonksiyonu aktif hale getirildi.

```
[ ] x_train, x_test, y_train, y_test = train_test_split(x,y,train_size=0.85, random_state=13)
```

```
[ ] from sklearn.tree import DecisionTreeRegressor
tree_regression = DecisionTreeRegressor(random_state=42)
dtr = tree_regression.fit(x_train, y_train)
tahmin_tree_regression= dtr.predict(x_test)
dtr.score(x_test,y_test)
```

```
0.9612655426079031
```

```
[ ] x_train, x_test, y_train, y_test = train_test_split(x,y,train_size=0.85, random_state=14)
```

```
[ ] from sklearn.ensemble import RandomForestRegressor
rf= RandomForestRegressor (n_estimators=100, random_state=20)
model=rf.fit(x_train, y_train)
tahmin_random_regression = model.predict(x_test)
model.score(x_test,y_test)
```

```
0.943097754443564
```

Şekil 5.7. Oluşturulan makine öğrenmesi modelinin 3.bölümünün ekran görüntüsü (Google Colab)

Şekil 5.7'de ise bağımsız değişkenler ve hedef değişken, eğitim ve test olarak parçalandıktan sonra teste tabi tutuldu ve daha güvenilir bir makine öğrenmesi gerçekleştirildi. Burada eğitim için %85'lik bir parça ayrıldı ve %85'lik bölümü öğrenmesi istenildi. Geriye kalan %15'lik bölüm içinse teste tabi tutularak tahminlerde bulunması istenildi. Eğitim ve test olmak üzere iki parçaya ayrılan veri seti kullanılarak, karar ağacı regresyon ve rastgele orman regresyon algoritmaları ile makine öğrenmesi gerçekleştirildi ve R^2 skorlarına bakıldı.

```
[ ] from sklearn.metrics import mean_squared_error, mean_absolute_error, mean_absolute_percentage_error, r2_score
```

```
[ ] r2= r2_score(y_test,tahmin_tree_regression)
mse= mean_squared_error(y_test, tahmin_tree_regression)
mae= mean_absolute_error(y_test, tahmin_tree_regression)
mape= mean_absolute_percentage_error(y_test, tahmin_tree_regression)
```

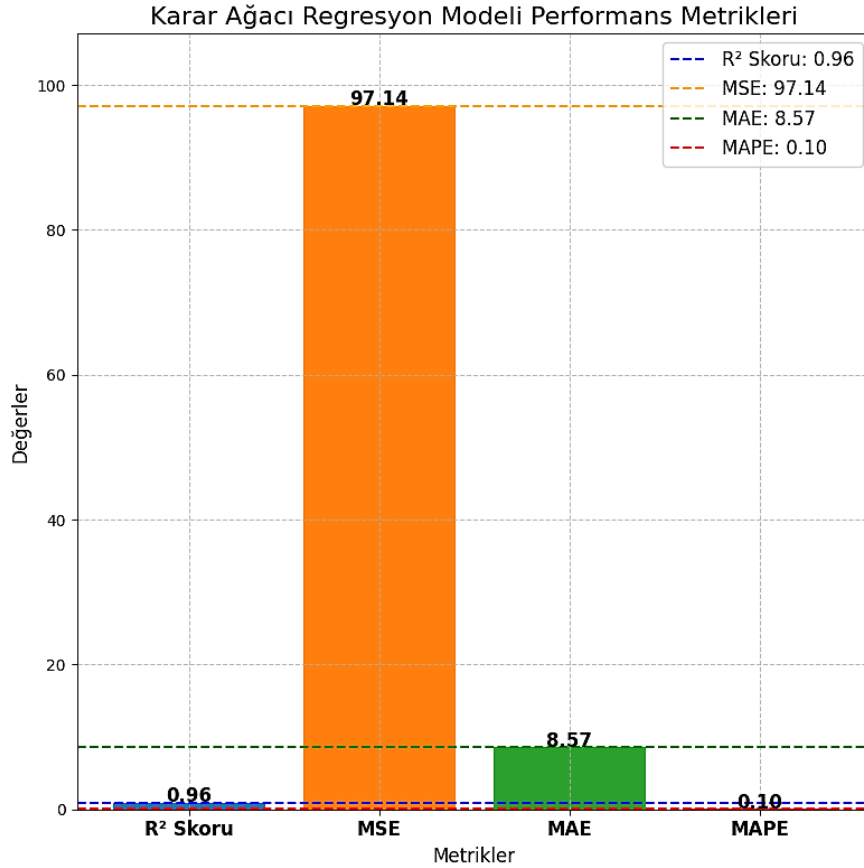
```
[ ] print(f"r2_score: {r2}, MSE: {mse}, MAE: {mae}, MAPE: {mape}")
```

```
r2_score: 0.9612655426079031, MSE: 97.14285714285714, MAE: 8.571428571428571, MAPE: 0.10951722916003827
```

Şekil 5.8. Oluşturulan makine öğrenmesi modelinin 4.bölümünün ekran görüntüsü (Google Colab)

Şekil 5.8'de karar ağacı regresyon algoritması kullanılarak oluşturulan makine öğrenmesi modelinin performans metrikleri gösterilmektedir. Bulunan performans metrikleri değerlendirildiğinde; R^2 değerinin 0.96 bulunduğu ve 1'e yakın olduğu için

performansının çok iyi olduğu görülmektedir. MSE değerinin: 97.14, MAE: 8.57 ve MAPE: %10 değerlerinin ise oldukça düşük olduğu ve bulunan metrikler bir bütün olarak değerlendirildiğinde, oluşturulan modelin performansının başarılı olduğu görülmektedir. Karar ağacı regresyon modelinin performans metrikleri grafiği Şekil 5.9'da gösterilmektedir.



Şekil 5.9. Karar ağacı regresyon modelinin performans metrikleri grafiği

```
[ ] from sklearn.metrics import mean_squared_error, mean_absolute_error, mean_absolute_percentage_error, r2_score

[ ] R2= r2_score(y_test,tahmin_random_regression)
MSE= mean_squared_error(y_test, tahmin_random_regression)
MAE= mean_absolute_error(y_test, tahmin_random_regression)
MAPE= mean_absolute_percentage_error(y_test, tahmin_random_regression)

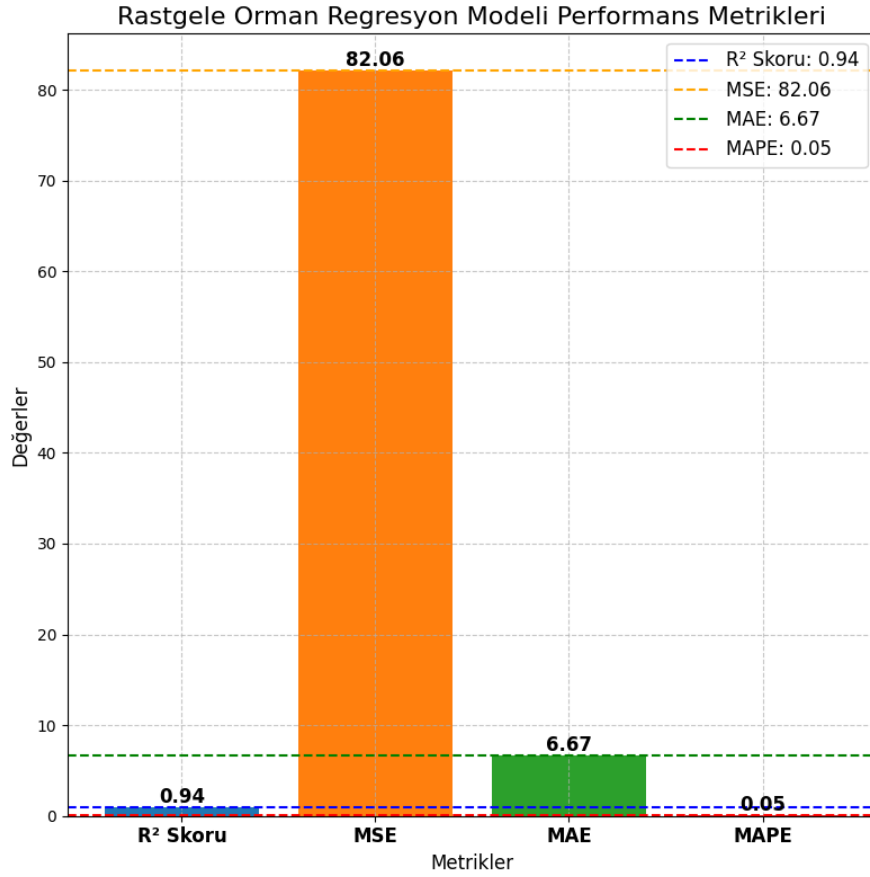
[ ] print(f"r2_score: {R2}, MSE: {MSE}, MAE: {MAE}, MAPE: {MAPE}")

r2_score: 0.943097754443564, MSE: 82.06000571428562, MAE: 6.673142857142849, MAPE: 0.05795907428538966
```

Şekil 5.10. Oluşturulan makine öğrenmesi modelinin 5.bölümünün ekran görüntüsü (Google Colab)

Şekil 5.10'da ise rastgele orman regresyon algoritması kullanılarak oluşturulan makine öğrenmesi modelinin performans metrikleri gösterilmektedir. Bulunan performans metrikleri değerlendirildiğinde; R² değerinin 0.94 bulunduğu ve 1'e yakın olduğu için

performansının çok iyi olduđu görölmektedir. MSE: 82.06, MAE: 6.67 ve MAPE: %5 deđerlerinin ise oldukça düşük olduđu ve bulunan metrikler bir bütün olarak deđerlendirildiğinde, modelin performansının başarılı olduđu görölmektedir. Rastgele Orman Regresyon modeli performans metrikleri grafiđi Şekil 5.11'de gösterilmektedir.



Şekil 5.11. Rastgele orman regresyon modelinin performans metrikleri grafiđi

Karar ağacı regresyon ve rastgele orman regresyon algoritmaları kullanılarak oluşturulan makine öğrenmesi modelinin incelenen performans metrikleri deđerlendirildiğinde, her iki metodun kullanılmasıyla da yapılan tahminlerin, yüksek doğruluk oranlarına sahip olduđu görölmektedir.

```
df.head()

Kesme_Hızı Kesme_Derinliđi İlerleme Sıcaklık Malzeme_16MnCr5 Kesici_Takım_CNMG120408
0 350 0.3 0.20 87.0 True True
1 350 0.2 0.20 52.8 True True
2 350 0.1 0.20 77.0 True True
3 350 0.3 0.15 122.0 True True
4 350 0.2 0.15 117.0 True True

[ ] model.predict([[105,0.25,0.12,True,True]])
array([111.136])

[ ] dtr.predict([[105,0.25,0.12,True,True]])
array([122.])
```

Şekil 5.12. Oluşturulan makine öğrenmesi modelinin tahmin bölümünün ekran görüntüsü (Google Colab)

Şekil 5.12’de ise en düşük kesme kuvveti değerlerinin ölçüldüğü parametreler seçilerek oluşturulan veri setinden yola çıkılarak, ilk önce eğitim ve test şeklinde iki ayrı parçaya bölünen daha sonra rastgele orman regresyon ve karar ağacı regresyon algoritmaları kullanılarak makine öğrenmesi gerçekleştirilen modelin, tahminlerde bulunması istenilmiştir. Kendi belirlediğimiz parametreler ile rastgele orman regresyon algoritmasını kullanarak oluşturduğumuz modele; kesme hızı: 105 m/dak, kesme derinliği: 0.25 mm, ilerleme: 0.12 mm/dev, malzeme: 16MnCr5 ve kesici takım: CNMG120408 olacak biçimde bir tahminde bulunmasını istediğimizde tahmin ettiği, kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklığın 111.136 °C olduğu görülmektedir. Aynı şekilde kendi belirlediğimiz parametreler ile karar ağacı regresyon algoritmasını kullanarak oluşturduğumuz modele; kesme hızı: 105 m/dak, kesme derinliği: 0.25 mm, ilerleme:0.12 mm/dev, malzeme: 16MnCr5 ve kesici takım: CNMG120408 olacak biçimde bir tahminde bulunmasını istediğimizde tahmin ettiği, kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklığın 122 °C olduğu görülmektedir.

Tablo 5.3. Oluşturulan makine öğrenmesi modeli ile tahmin edilen sıcaklık değerleri

Rastgele Orman Regresyon Modeli ile Tahmin Edilen Sıcaklık Değerleri					
Kesme Hızı	Kesme Derinliği	İlerleme	Malzeme 16MnCr5	Kesici Takım CNMG120408	Tahmin Edilen Sıcaklık
105	0,25	0,12	True	True	111,136
175	1	0,3	True	True	170,32
245	0,4	0,6	True	True	80,55
280	0,55	0,7	True	True	107,94
310	1,2	0,15	True	True	174,38
Karar Ağacı Regresyon Modeli ile Tahmin Edilen Sıcaklık Değerleri					
Kesme Hızı	Kesme Derinliği	İlerleme	Malzeme 16MnCr5	Kesici Takım CNMG120408	Tahmin Edilen Sıcaklık
105	0,25	0,12	True	True	122
175	1	0,3	True	True	178
245	0,4	0,6	True	True	87
280	0,55	0,7	True	True	74
310	1,2	0,15	True	True	199

Tablo 5.3'te örnek olarak, kendi belirlediğimiz ara değerlere göre, rastgele orman regresyon ve karar ağacı regresyon algoritmaları kullanılarak oluşturulan makine öğrenmesi modelinin tahmin ettiği, kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklık değerleri gösterilmektedir. Modelin aynı parametreler kullanılarak, her iki yöntemle de tahmin ettiği sıcaklık değerlerinin genel olarak birbirlerine yakın oldukları görülmektedir. Ancak rastgele orman regresyon algoritması ile oluşturulan modelin performans metrikleri bir bütün olarak göz önüne alındığında, performansının daha başarılı olması ve aşırı uyum riskinin daha az olması nedeniyle daha güvenilir tahminler yaptığı söylenebilir.

6. DEĞERLENDİRMELER VE ÖNERİLER

Bu çalışmanın amacı, malzemelerin tornalanmasında kesme kuvvetini minimum yapan kesme bölgesindeki işleme sıcaklığının makine öğrenmesi yoluyla tahmin edilmesidir. Makine öğrenmesi oluşturabilmek için veri seti gerekli olduğundan örnek olarak 16MnCr5 iş malzemesi kuru kesme koşullarında tornalanmıştır. Deneyler sonrasında en düşük kesme kuvveti değerlerinin ölçüldüğü parametre değerleri ile sıcaklık değerleri seçilerek bir veri seti oluşturulmuş ve bu veri seti kullanılarak makine öğrenmesi gerçekleştirilmiştir. Çalışmanın sonucunda oluşturulan makine öğrenmesinde, işleme parametreleri gibi malzeme ve kesici takım parametreleri de kullanılacak olan veri setine bağlı olarak değişkenlik göstermektedir. Oluşturulan makine öğrenmesi modeli, oluşturulacak farklı veri setleri içinde kullanılabilecek olup farklı malzeme ve kesici takımlar kullanılarak yapılan deneyler ile oluşturulan veri setleri için de kullanılabilecektir. Bu sayede işlenmesi zor olan malzemelerle yapılan deneyler sonucunda; en düşük kesme kuvveti değerleri, en düşük yüzey pürüzlülük değerleri ve en az takım aşınmasının elde edildiği parametre değerleri seçilerek oluşturulan veri setleri ile yapılan bu çalışma sonucunda oluşturulan makine öğrenmesi modeli kullanılarak da kesme bölgesindeki sıcaklıklar tespit edilebilecektir.

Çalışmanın sonucunda, rastgele orman regresyon (random forest regression) ve karar ağacı regresyon (decision tree regression) algoritmaları kullanılarak, 16MnCr5 malzemesi için veri setine bağlı olarak istenilen değerlerde; kesme hızı, kesme derinliği, ilerleme hızı, kesici takım ve malzeme parametreleri modele girildiğinde kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklığı tahmin eden makine öğrenmesi modeli oluşturulmuştur.

Oluşturulan makine öğrenmesi modelinin performans metrikleri incelendiğinde; karar ağacı regresyon algoritması kullanılarak gerçekleştirilen makine öğrenmesi modelinin R^2 değerinin 0.96 (%96), rastgele orman regresyon algoritması kullanılarak gerçekleştirilen makine öğrenmesi modelinin R^2 değerinin ise 0.94 (%94) olarak bulunduğu ve 1'e yakın oldukları için performanslarının çok iyi olduğu tespit

edilmiştir. Ortalama mutlak yüzde hata (MAPE) değeri, karar ağacı regresyon algoritması ile oluşturulan makine öğrenmesi modeli için %10 ve rastgele orman regresyon algoritması ile oluşturulan makine öğrenmesi modeli için %5 olarak bulunmuştur. Bulunan metrikler bir bütün olarak değerlendirildiğinde, oluşturulan makine öğrenmesi modelinin, her iki metodun kullanılmasıyla da yapılan tahminlerin yüksek doğruluk oranlarına sahip olduğu belirlenmiştir ve iki yöntem de kullanılarak tahminlerde bulunulmuştur. Ancak aşırı uyum riskinin daha az olması nedeniyle rastgele orman regresyon modelinin daha güvenilir tahminler yaptığı söylenebilir.

Günümüzde, neredeyse her alanda otomasyona geçildiği düşünüldüğünde makine öğrenmesi modellerine ve bu modeller için gerekli olan bilgilerin tespit edilmesine olan gereksinim gün geçtikçe artmaktadır. Tahmin edilen, kesme kuvvetini minimum yapan kesme bölgesindeki sıcaklık değerleri ile deney öncesinde ideal ortam şartları oluşturularak işlemeye başlanacağı için takım aşınmasının, kesme kuvvetinin, yüzey pürüzlülüğünün, iş parçasının aşınmasının ve kesme sıvısı tüketiminin azaltılması sağlanarak enerjiden, zamandan ve maliyetten tasarruf edilmiş olacaktır.

Veri setinde bulunan değerler çerçevesinde, istenilen kesme parametreleri modele girilerek sıcaklık tahmin edilebileceği için, yapılmak istenen deneyin ön hazırlık ile belirlenmiş parametreleri için de ara değerler için de deneme yanılma yöntemlerine ihtiyaç duyulmadan, tahmin edilen sıcaklık değerlerine göre işlem yapılabilir.

İleri zamanlarda çok daha fazla gelişeceği düşünülen akıllı imalat teknolojileriyle birlikte, imalatta kullanılan tezgâhlar işleme koşullarına kendileri karar verebileceklerdir. Bu koşullar için gereken önemli ihtiyaçlardan birisi ise malzemenin işleme sıcaklığı yani ön ısıtılma ya da soğutulma sıcaklığıdır. Yapılan bu çalışma ile imalat sanayisinde ileri dönemler için karanlık fabrikalara geçileceği, dijitalleşeceği ve insana olan ihtiyacın azalacağı düşünüldüğünde, nasıl bir veri tabanı oluşturulması gerektiği hakkında başlangıç çalışması gerçekleştirilmiş ve literatüre katkı sağlanmıştır.

Bu çalışmada, malzemelerin tornalanmasında uygun kesme sıcaklığını belirlemek için veri seti oluşturulurken, en düşük kesme kuvveti değerlerinin ölçüldüğü deney parametreleri kullanılmıştır. Bu yöntemle, en az takım aşınması değerleri ve en düşük

yüzey pürüzlülük değerlerinin ölçüldüğü deney parametre değerleri baz alınarak oluşturulan yeni veri setlerinin kullanılmasıyla da kesme bölgesindeki sıcaklıklar tahmin edilebilecektir. Hepsinin bir arada değerlendirilmesiyle oluşturulan yeni veri setleri kullanılarak yapılacak olan tahminler ile en uygun kesme sıcaklıklarına çok daha fazla yaklaşılabilecektir.

Veri setinde yer alan deney parametre değerlerinin artırılması (veri sayısının artırılması) ve çeşitlendirilmesi ile makine öğrenmesi modelinin performansı daha başarılı olacaktır. Bu sayede daha güvenilir, daha tutarlı ve daha fazla tahminde bulunabilir ve hata oranlarının daha az olması sağlanabilir.

Farklı malzemeler, farklı kesiciler, farklı işleme değişkenleri, farklı ölçüm aletleri kullanılarak yapılacak yeni çalışmalar, ileride yapay zekâ alanında yapılacak uygulamalar için veri tabanı oluşturulması sürecine katkı sağlayacaktır.

KAYNAKLAR

- [1] Takım Tezgahları Sanayici ve İş İnsanları Derneği (2023), Takım Tezgahları Ve Tamamlayıcı Ekipmanları 2023-3.Çeyrek Sektör Analizi, https://tiad.org/wp-content/uploads/2023/11/2023_3CeyrekSektorAnalizi.pdf, İndirilme Tarihi: 29.04.2024.
- [2] Binali, R., Yıldız, S., & Neşeli, S. (2021). S960QL Yapı Çeliğinin İşlenebilirliğinin Sonlu Elemanlar Yöntemi ile İncelenmesi. *Avrupa Bilim ve Teknoloji Dergisi (31)*, 85-91. <https://doi.org/10.31590/ejosat.996324>
- [3] Özdüzgün, H. S. (2024). Talaşlı İmalatta Kesme Sıvısı Kullanımı İçin Yenilikçi Bir Sistem Tasarımı. Yüksek Lisans Tezi. *Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü*, Kırıkkale.
- [4] Hamamcı, B. (2015). Sertleştirilmiş Çeliklerin Ön Isıtmalı İşlenmesi. Doktora Tezi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, Isparta.
- [5] Hamamcı, E. (2014). Ti6Al4V Titanyum Alaşımının Ön Isıtmalı Şartlarda Frezelenmesinin Araştırılması. Doktora Tezi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, Isparta.
- [6] Uğraş, A. (2022). İşlenmesi Zor Malzemelerin Yüksek Talaş Kaldırma Oranlarıyla İşlenmesi İçin Isı Destekli Hibrid Sistemin Geliştirilmesi ve Çalışma Parametrelerinin Belirlenmesi. Doktora Tezi. *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.
- [7] Kavak, Y. (2019). İşlenmesi Zor Malzemenin Tornalanmasının Yüzey Pürüzlülüğüne Etkisinin İstatistiksel Yöntem ile İncelenmesi. Yüksek Lisans Tezi. *Düzce Üniversitesi Fen Bilimleri Enstitüsü*, Düzce.
- [8] Tosun, N., & Özler, L. (2002). A study of tool life in hot machining using artificial neural networks and regression analysis method. *Journal of Materials Processing Technology*, 124(1-2), 99–104. [https://doi.org/10.1016/s0924-0136\(02\)00086-9](https://doi.org/10.1016/s0924-0136(02)00086-9)

- [9] Rebro, P. A., Shin, Y. C., & Incropera, F. P. (2004). Design of operating conditions for crackfree laser-assisted machining of mullite. *International Journal of Machine Tools and Manufacture*, 44(7-8), 677–694. <https://doi.org/10.1016/j.ijmachtools.2004.02.011>
- [10] Dandekar, C. R., Shin, Y. C., & Barnes, J. (2010). Machinability improvement of titanium alloy (Ti–6Al–4V) via LAM and hybrid machining. *International Journal of Machine Tools and Manufacture*, 50(2), 174–182. <https://doi.org/10.1016/j.ijmachtools.2009.10.013>
- [11] Masood, S. H., Armitage, K., & Brandt, M. (2011). An experimental study of laser-assisted machining of hard-to-wear white cast iron. *International Journal of Machine Tools and Manufacture*, 51(6), 450–456. <https://doi.org/10.1016/j.ijmachtools.2011.02.001>
- [12] Sun, S., Brandt, M., Barnes, J. E., & Dargusch, M. S. (2011). Experimental investigation of cutting forces and tool wear during laser-assisted milling of Ti–6Al–4V alloy. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 225(9), 1512–1527. <https://doi.org/10.1177/0954405411411608>
- [13] Rahman Rashid, R. A., Sun, S., Wang, G., & Dargusch, M. S. (2012). An investigation of cutting forces and cutting temperatures during laser-assisted machining of the Ti–6Cr–5Mo–5V–4Al beta titanium alloy. *International Journal of Machine Tools and Manufacture*, 63, 58–69. <https://doi.org/10.1016/j.ijmachtools.2012.06.004>
- [14] Ayed, Y., Germain, G., Ben Salem, W., & Hamdi, H. (2014). Experimental and numerical study of laser-assisted machining of Ti6Al4V titanium alloy. *Finite Elements in Analysis and Design*, 92, 72–79. <https://doi.org/10.1016/j.finel.2014.08.006>
- [15] Germain, G., Lebrun, J.-L., Tarek Braham-Bouchnak, Bellett, D., & Auger, S. (2008). Laser-assisted machining of Inconel 718 with carbide and ceramic inserts. *International Journal of Material Forming*, 1(S1), 523–526. <https://doi.org/10.1007/s12289-008-0213-y>
- [16] Chang, C.-W., & Kuo, C.-P. (2007). An investigation of laser-assisted machining of Al₂O₃ ceramics planing. *International Journal of Machine Tools*

- and* *Manufacture*, 47(3-4), 452–461.
<https://doi.org/10.1016/j.ijmachtools.2006.06.010>
- [17] Chang, C.-W., & Kuo, C.-P. (2007). Evaluation of surface roughness in laser-assisted machining of aluminum oxide ceramics with Taguchi method. *International Journal of Machine Tools and Manufacture*, 47(1), 141–147. <https://doi.org/10.1016/j.ijmachtools.2006.02.009>
- [18] Maity, K. P., & Swain, P. K. (2008). An experimental investigation of hot-machining to predict tool life. *Journal of Materials Processing Technology*, 198(1), 344–349. <https://doi.org/10.1016/j.jmatprotec.2007.07.018>
- [19] Anderson, M., Patwa, R., & Shin, Y. C. (2006). Laser-assisted machining of Inconel 718 with an economic analysis. *International Journal of Machine Tools and Manufacture*, 46(14), 1879–1891. <https://doi.org/10.1016/j.ijmachtools.2005.11.005>
- [20] Binali, R., Yıldız, S., & Neşeli, S. (2022). Investigation of Power Consumption in the Machining of S960QL Steel by Finite Elements Method. *European Journal of Technic*. <https://doi.org/10.36222/ejt.1066472>
- [21] Asiltürk, İ., Kuntoğlu, M., Binali, R., Akkuş, H., & Salur, E. (2023). A Comprehensive Analysis of Surface Roughness, Vibration, and Acoustic Emissions Based on Machine Learning during Hard Turning of AISI 4140 Steel. *Metals*, 13(2), 437. <https://doi.org/10.3390/met13020437>
- [22] Kumar Gupta, M., Korkmaz, M. E., Sarıkaya, M., Krolczyk, G. M., & Günay, M. (2022). In-process detection of cutting forces and cutting temperature signals in cryogenic assisted turning of titanium alloys: An analytical approach and experimental study. *Mechanical Systems and Signal Processing*, 169, 108772. <https://doi.org/10.1016/j.ymsp.2021.108772>
- [23] Korkmaz, M. E., Gupta, M. K., Kuntoğlu, M., Patange, A. D., Ross, N. S., Yılmaz, H., Chauhan, S., & Vashishtha, G. (2023). Prediction and classification of tool wear and its state in sustainable machining of Bohler steel with different machine learning models. *Measurement*, 223, 113825–113825. <https://doi.org/10.1016/j.measurement.2023.113825>

- [24] Akdulum, A., & Kayır, Y. (2023). Prediction of thrust force in indexable drilling of aluminum alloys with machine learning algorithms. *Measurement*, 222, 113655–113655. <https://doi.org/10.1016/j.measurement.2023.113655>
- [25] Korkmaz, M. E., Gupta, M. K., Singh, G., Kuntoğlu, M., Patange, A., Demirsoz, R., Ross, N. S., & Prasad, B. (2023). Machine learning models for online detection of wear and friction behaviour of biomedical graded stainless steel 316L under lubricating conditions. *The International Journal of Advanced Manufacturing Technology*, 128(5-6), 2671–2688. <https://doi.org/10.1007/s00170-023-12108-3>
- [26] Kishore, K., Chauhan, S. R., & Sinha, M. K. (2023). Application of machine learning techniques in environmentally benign surface grinding of Inconel 625. *Tribology International*, 188, 108812–108812. <https://doi.org/10.1016/j.triboint.2023.108812>
- [27] Rajesh, A. S., Prabhuswamy, M. S., & Krishnasamy, S. (2022). Smart Manufacturing through Machine Learning: A Review, Perspective, and Future Directions to the Machining Industry. *Journal of Engineering*, 2022, 1–6. <https://doi.org/10.1155/2022/9735862>
- [28] Bustillo, A., Reis, R., Machado, A. R., & Pimenov, D. Yu. (2020). Improving the accuracy of machine-learning models with data from machine test repetitions. *Journal of Intelligent Manufacturing*, 33(1), 203–221. <https://doi.org/10.1007/s10845-020-01661-3>
- [29] Savkovic, B., Kovac, P., Rodic, D., Strbac, B., & Klancnik, S. (2020). Comparison of artificial neural network, fuzzy logic and genetic algorithm for cutting temperature and surface roughness prediction during the face milling process. *Advances in Production Engineering & Management*, 15(2), 137–150. <https://doi.org/10.14743/apem2020.2.354>
- [30] Simunovic, G., Simunovic, K., & Saric, T. (2013). Modelling and Simulation of Surface Roughness in Face Milling. *International Journal of Simulation Modelling*, 12(3), 141–153. [https://doi.org/10.2507/ijssimm12\(3\)1.219](https://doi.org/10.2507/ijssimm12(3)1.219)
- [31] Alınca, A. (2012). İndüksiyon ile Kompozit Malzemelerin Isıtılmalarının İncelenmesi. Yüksek Lisans Tezi. *Maltepe Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.

- [32] Peng, J., Jury, E. C., Dönnes, P., & Ciurtin, C. (2021). Machine Learning Techniques for Personalised Medicine Approaches in Immune-Mediated Chronic Inflammatory Diseases: Applications and Challenges. *Frontiers in Pharmacology*, 12. <https://doi.org/10.3389/fphar.2021.720694>
- [33] Akpolat, O., & Ertürk, G. (2023). Karar Ağaçları ve Yapay Sinir Ağlarının Karşılaştırılması: Kimyasal Verilerin Tahmini Üzerine Bir Örnek Çalışma. *Avrupa Bilim ve Teknoloji Dergisi* (51), 1-13. <https://doi.org/10.31590/ejosat.1073201>
- [34] Sahour, H., Gholami, V., Torkaman, J., Vazifedan, M., & Saedi, S. (2021). Random forest and extreme gradient boosting algorithms for streamflow modeling using vessel features and tree-rings. *Environmental Earth Sciences*, 80(22). <https://doi.org/10.1007/s12665-021-10054-5>
- [35] Gündüz, A. (2006). Tornalama İşleminde Oluşan Kesme Kuvvetlerinin Bulanık Mantık ve Yapay Sinir Ağlarıyla Tahmini. Yüksek Lisans Tezi. *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.

ÖZGEÇMİŞ

Adı Soyadı: Ebru ADIYAMAN

Yabancı Dil: İngilizce

Lisans: Karabük Üniversitesi, Makine Mühendisliği %30 İng. 2014-2019

Yüksek Lisans: Kırıkkale Üniversitesi, Makine Mühendisliği 2022-2024

Yayımlar:

Adıyaman, E., & Er, A. O. (2024). İşlenmesi Zor Malzemelerin Tornalanması İçin En Uygun İşleme Sıcaklıklarının Makine Öğrenmesi İle Belirlenmesi. İmalat Teknolojileri ve Uygulamaları, 5(1), 46-64. <https://doi.org/10.52795/mateca.1463257>