

İşlenmesi Zor Malzemelerin Tornalanması İçin En Uygun İşleme Sıcaklıklarının Makine Öğrenmesi İle Belirlenmesi

Ebru ADIYAMAN^{1,*} , Ali Osman ER¹ 

¹Kırıkkale Üniversitesi, Makine Mühendisliği Bölümü, Kırıkkale, Türkiye

MAKALE BİLGİSİ

Alınma: 02.04.2024

Kabul: 26.04.2024

Anahtar Kelimeler:

Talaşlı imalat
Ön ısıtılmış işleme
İşleme sıcaklığı
CNC tornalama
Makine öğrenmesi

ÖZET

Talaşlı imalat, geleneksel bir işleme yöntemi olmasına rağmen diğer alternatif işleme yöntemlerine göre işlenmesi zor, yüksek mukavemetli ya da kırılabilir malzemelerin işlenmesine ve bunun yanı sıra yüzey kalitesinin de iyileştirilebilmesine olanak sağladığı için tercih sebebi olmaktadır. Yüksek mukavemetli titanyum alaşımlarının, paslanmaz çeliklerin, takım çeliklerinin, kompleks özelliklere sahip silisyum nitrür seramiklerin, yani işlenmesi zor malzemelerin geleneksel işlenmesi, düşük kesme hızlarının kullanılması nedeniyle verimsizdir. Bu durumun etkisini azaltmak ve üretkenliği artırmak için ileri kesici takımların tercih edilmesi, soğutma ve yağlama sistemlerinin kullanılması ve ön ısıtılmış işleme gibi yöntemler kullanılmaktadır. Bu çalışmada en uygun işleme sıcaklığını tespit etmek için makine öğrenmesi kullanılmıştır. Makine öğrenmesi modeli, Karar Ağacı Regresyon (Decision Tree Regression) ve Rastgele Orman Regresyon (Random Forest Regression) algoritmaları kullanılarak oluşturulmuştur. Makine öğrenmesi modelinin performans metriklerinden R^2 değeri her iki model için de 0.98 bulunurken, Ortalama Mutlak Yüzde Hata (MAPE) değeri Karar Ağacı Regresyonu için %1.27, Rastgele Orman Regresyonu için %1.87 olarak bulunmuştur. Bulunan metrikler değerlendirildiğinde, modelin performansının başarılı olduğu görülmektedir. Çalışmanın sonucunda verileri girilen malzemeler ve koşullar için istenilen işleme değişkenlerine karşılık uygun işleme sıcaklığını tespit edecek makine öğrenmesi gerçekleştirilmiştir.

Determination of the Most Suitable Machining Temperatures for Turning Hard-to-Cut Materials by Machine Learning

ARTICLE INFO

Received: 02.04.2024

Accepted: 26.04.2024

Keywords:

Machining
Preheated machining
Processing temperature
CNC turning
Machine learning

ABSTRACT

Although machining is a traditional machining method, it is preferred because it allows the processing of difficult-to-machine, high-strength or brittle materials compared to other alternative machining methods, as well as improving the surface quality. Conventional machining of high-strength titanium alloys, stainless steels, tool steels, silicon nitride ceramics with complex properties, i.e. difficult-to-machine materials, is inefficient due to the use of low cutting speeds. In order to reduce the impact of this situation and increase productivity, methods such as the preference of advanced cutting tools, the use of cooling and lubrication systems, and preheated machining are used. In this study, machine learning was used to determine the optimal processing temperature. The machine learning model was created using Decision Tree Regression and Random Forest Regression algorithms. Among the performance metrics of the machine learning model, the R^2 value was 0.98 for both models and the Mean Absolute Percentage Error (MAPE) value was 1.27% for Decision Tree Regression and 1.87% for Random Forest Regression. When the metrics found are evaluated, it is seen that the performance of the model is successful. As a result of the study, machine learning was performed to determine the appropriate machining temperature for the desired machining variables for the materials and conditions for which data were entered.

*Sorumlu yazar, e-posta: adymnnebru@gmail.com

To cite this article: E. Adıyaman, A. O. Er, İşlenmesi Zor Malzemelerin Tornalanması İçin En Uygun İşleme Sıcaklıklarının Makine Öğrenmesi İle Belirlenmesi, Manufacturing Technologies and Applications, 5(1),46-64, 2024.

<https://doi.org/10.52795/mateca.1463257>, This paper is licensed under a CC BY-NC 4.0

1. GİRİŞ (INTRODUCTION)

Talaşlı imalat, iş parçası üzerinden talaş kaldırılarak malzemeyi istenilen forma getirmek için kullanılan geleneksel bir imalat yöntemidir. Geleneksel bir imalat yöntemi olmasına rağmen talaşlı imalat, otomotiv, medikal, havacılık, savunma sanayi, makine imalatı vb. birçok sektör için geçmişte olduğu gibi gelecekte de önemini korumaya devam edecek olan bir sektördür. İmalat sektöründe bu kadar büyük öneme sahip olan talaşlı imalatın, avantajlarının yanı sıra dezavantajları da bulunmaktadır. İşlenmesi zor malzemelerin, işlenmesi sırasında açığa çıkan yüksek ısı nedeniyle işlenen malzeme ve kesici takımında deformasyonlar meydana gelmektedir. Aynı zamanda kaldırılan talaşın sünekliği nedeniyle de malzeme yüzeyinde pürüzler oluşmaktadır. Bütün bu durumlar maliyet ve zaman açısından istenmeyen durumlardır. Bu durumların önüne geçmek için kullanılan yöntemler arasında bulunan ön ısıtılmalı işleme yöntemleri, torna tezgahına monte edilmiş harici bir ısı kaynağı ile malzemeyi ısıtarak, direncini ve akma dayanımını azaltıp, normal işleme ile işlenmesi zor olan malzemeleri daha kolay işlemeyi, malzeme ve takım deformasyonunu en aza indirmeyi ve malzemenin yüzey kalitesini iyileştirmeyi hedeflemektedir. Günümüz teknolojisiyle birlikte imalat sektöründeki rekabetin artmasıyla, üreticilerden istenilen yalnızca uygun maliyetli ürünler değil, aynı zamanda yüksek kalitede ve en kısa sürede teslim edilen ürünler olmuştur[1]. Bu nedenle geleneksel imalat sektörünün daha verimli hale getirilebilmesi için, üretim süreçlerinin analiz edilerek iyileştirilmesi, modern teknolojilerin veya veri odaklı yaklaşımların uygulanması gerekmektedir. Binali vd, (2022), yaptıkları çalışmada S960QL yapı çeliğinin işlenebilirliğini artırmak için sonlu elemanlar yöntemini kullanmışlardır. İşlenmesi zor bir malzeme olan S960QL yapı çeliğinin, talaşlı imalatı sırasında yüksek güç tüketimi meydana gelmekte ve maliyeti artırmaktadır. Bu durumu en aza indirmek amacıyla, S960QL yapı çeliğinin frezelenmesinde, kesme parametrelerine bağlı olarak sonlu elemanlar yöntemi ile güç tüketimi modellemesi yapmışlardır. Çalışmanın sonucunda, işleme parametrelerinin güç tüketimine etkisinin belirlenmesi için FE modelinin uygun olduğunu tespit etmişlerdir[2]. Asiltürk vd. (2023), yaptıkları çalışmada AISI 4140 çeliğinin tormalanmasında kesme hızı, kesme derinliği ve ilerleme gibi kesme parametrelerinin, yüzey pürüzlülüğü ve titreşimler üzerindeki etkilerini araştırmışlardır. Tormalama işlemi sonrasında yüzey pürüzlülüğü ve akustik emisyon değerleri ölçülmüştür. Matlab programı kullanılarak kural tabanlı bulanık mantık modeli oluşturulmuş ve deney sonrası ölçülen değerler ile bulanık mantık modelinin tahmin sonuçları karşılaştırılarak değerlendirilmiştir. Değerlendirmeler sonucunda, kural tabanlı bulanık mantık modelinin başarılı olduğu tespit edilmiştir[3]. Gupta vd. (2022) yaptıkları çalışmada Ti6Al4V alaşımının kuru tormalama ve LN₂/CO₂ soğutma destekli tormalama işlemleri sırasında, kesme kuvvetlerini ve kesme sıcaklıklarını ölçmüşlerdir ve bu prosesin sonlu elemanlar yöntemi (FEM) ile simülasyonunu yaparak deney sonuçları ile simülasyon sonuçlarını karşılaştırmışlardır. Çalışmanın sonucunda, kesme sıcaklığı için sonlu elemanlar modeli ile deneysel sonuçlar arasındaki sapmaların; kuru, LN₂ ve CO₂ soğutma koşulları için sırasıyla ortalama %5,54, %5,18 ve %8,42 olduğunu, kesme kuvveti için sonlu elemanlar modeli ve deney sonuçları arasındaki sapmaların; kuru, LN₂ ve CO₂ soğutma koşulları için sırasıyla %3.74, %3.358 ve %3.03 olduğunu tespit etmişlerdir [4].

Bu çalışmanın amacı, işlenmesi zor malzemelerin tormalanmasında belirli malzemeler için en uygun işleme sıcaklığını, deneyleri yapılarak bulunmuş en düşük yüzey pürüzlülük değerlerini veren deney parametreleri ve deney esnasında ölçülen sıcaklık değerleri ile oluşturulan veri seti kullanılarak makine öğrenmesi modeli oluşturmak ve bu model ile ara değerler için de tahminler yapabilmektir. Çalışmanın sonucunda, veri seti baz alınarak istenilen değerlerde; kesme hızı, ilerleme hızı, kesme derinliği, malzeme, kesici takım ve yüzey pürüzlülük değeri parametreleri modele girilerek, en uygun işleme sıcaklığı tahmin edilebilecektir. İstenilen parametre değerleri girilerek, sıcaklık tahmininde bulunulacağı için, ara değerler için de yapılmak istenen deney için ön hazırlık ile belirlenmiş parametreler için de deneme yanılma yöntemine gerek kalmadan, tahmin edilen sıcaklığa göre işlem yapılabilir. Tespit edilen en uygun işleme sıcaklığı ile deney öncesinde uygun ortam koşulları sağlanarak deneye başlanacağı için kesme kuvvetinin, takım aşınmasının, iş parçasının aşınmasının/kırılmasının ve yüzey pürüzlülüğünün azaltılması sağlanarak

maliyetten ve zamandan tasarruf edilmiş olacaktır. Makine öğrenmesi için gerekli veri seti, diğer araştırmacılar tarafından deneyleri yapılarak elde edilmiş değerlerden oluşmaktadır.

2. İŞLENMESİ ZOR MALZEMELER (MATERIALS DIFFICULT TO CUT)

- Ti6Al4V, düşük yoğunluk ve yüksek mukavemet gibi önemli mekanik özelliklere sahiptir ve korozyona karşı oldukça dirençlidir. Bu özellikleri, uzay endüstrisi, havacılık, denizcilik, tıbbi implantlar ve diğer birçok uygulamada tercih edilmesini sağlamaktadır.
- Yüksek manganlı çelik, yüksek mukavemet, yüksek sertlik ve yüksek darbe dayanımı özelliklerine sahiptir. Diğer çelik türlerine göre oldukça zor işlenmektedir. Yüksek miktarda mangan içermesi sebebiyle, işleme esnasında sertleşebilir ve işleme için özel yöntem ve ekipmanlar gerektirebilmektedir. Yüksek manganlı çelik, aşınma direnci gerektiren uygulamalarda yaygın olarak tercih edilmektedir. Bunlar arasında, raylar, madencilik ekipmanları, inşaat makineleri, kırıcılar gibi alanlar bulunmaktadır.
- Basınçsız sinterlenmiş mullit seramikler, yüksek sıcaklık ve atmosfer basıncı altında sinterleme işlemiyle üretilmektedir. Sinterleme işlemi, yüksek sıcaklıkta seramik tozlarının yoğunlaştırılmasını sağlayarak mukavemetini ve yoğunluğunu artırmaktadır. Basınçsız sinterlenmiş mullit seramikler, refrakter malzemeler, termoelektrik uygulamalar, yüksek sıcaklıkta izolasyon, endüstriyel fırınlar, ısı motorları, metal eritme fırınları, potalar ve diğer yüksek sıcaklık gerektiren uygulamalarda yaygın olarak kullanılmaktadır.
- S960QL yapı çeliği, iyi tokluk, yüksek mukavemet, iyi korozyon direnci ve düşük sıcaklıklarda çatlama direnci gibi önemli özelliklere sahiptir. Soğuk iklimlerde veya düşük sıcaklık gerektiren uygulamalarda kullanılabilir. Çeşitli endüstriyel uygulamalarda, özellikle dayanıklı ve sağlam yapılar için tercih edilmektedir. Kara taşıtları, köprüler, ekskavatörler, tarım makineleri, vinçler, madencilik ekipmanları, vinç kolları ve diğer benzeri uygulamalar için kullanılmaktadır.
- AISI 4140 çeliği, yüksek sertlik, tokluk, kaynaklanabilirlik ve aşınma direnci gibi özelliklere sahiptir. Dişliler, miller, ağır makineler, kamyonlar ve diğer endüstriyel makineler için yapısal parçaların üretiminde kullanılmaktadır.
- AISI 4340 çeliği, yüksek mukavemet ve tokluk özellikleriyle bilinen bir alaşım çeliğidir. Genellikle sertleştirilmiş olarak kullanılmakta ve sertleştirildiğinde yüksek mukavemet, iyi bir yorulma direnci, sertlik ve darbe dayanımı gibi özelliklere sahip olmaktadır. Özellikle havacılık, otomotiv, savunma ve enerji sektörlerinde kullanılmaktadır. Uçak parçaları, şanzıman ve aks parçaları, askeri ekipmanlar, denizcilik ekipmanları gibi yüksek mukavemet ve tokluk gerektiren durumlarda tercih edilmektedir.


2.1. İşlenmesi Zor Malzemelerin Ön Isıtmalı Tornalama Deneyleri İle Tespit Edilen En Uygun İşleme Sıcaklıkları (Optimal Machining Temperatures Determined by Pre-Heated Turning Experiments for Difficult-to-Cut Materials)

Torna tezgahında farklı ısıtma yöntemleri kullanılarak işlenmiş titanyum alaşımı (Ti6Al4V) için en uygun işleme sıcaklıkları; alevle ısıtma yöntemi için 450 °C [5], CO₂ lazer ile ısıtma yöntemi için 250 °C [6], bir başka lazerle ısıtma yöntemi deneyinde ise 500W için yaklaşık 350°C ve 1000W için 600°C [7] olduğu deneylerle tespit edilmiştir. Tosun vd. (2002), yaptıkları çalışmada torna tezgahında sıvı petrol gazı aleviyle ısıtılan yüksek manganlı çelik numuneler kullanarak, ilerleme hızı, kesme derinliği, kesme hızları ve yüzey sıcaklıkları gibi farklı kesme koşulları altında deneyler yapmışlardır. Takım ömrünün tahmini için ANN (yapay sinir ağları) ve regresyon analizi yöntemlerini kullanmışlardır. Yapılan deneylerin sonuçları incelendiğinde, yüksek manganlı çelik numunelerin sıcak işlenmesinde takım ömrünün, oda sıcaklığındaki işlemeye göre oldukça arttığı gözlemlenmiştir. En uzun takım ömrü 600 °C sıcaklığında elde edilirken, 400 °C için de yaklaşık

olarak aynı değerler elde edildiği için iş parçasının mikro yapısı ve maliyeti göz önünde bulundurularak optimum işleme sıcaklığı 400 °C seçilmiştir [8]. Yüksek manganlı çelik kullanılarak yapılan bir başka çalışmada ise Maity vd. (2008), torna tezgahında alevle ısıtılarak işlenen yüksek manganlı çelik için en uygun işleme sıcaklığının 200-600°C aralığında olduğunu tespit etmişlerdir [9]. Rebro vd. (2004), yaptıkları çalışmada basınçsız sinterlenmiş mullit seramiklerin, lazer destekli işlenmesinin değerlendirilmesine odaklanmışlardır. Lazer ısı kaynağı olarak CO₂ lazer kullanmışlardır. Tornalama işlemi, CNC taret torna tezgahında gerçekleştirilmiştir. 1100-1300°C'lerde en iyi yüzey pürüzlülüğünü, takım aşınma direncini ve talaş formunu elde etmişlerdir [10]. AISI 4340 alaşımlı çeliğin, alevle ısıtılarak tornalanmasında ise en uygun işleme sıcaklığı 650 °C olarak bulunmuştur [5]. AISI 4340 alaşımlı çelik kullanılarak yapılan bir başka çalışmada, TIG kaynağı ile ısıtılarak yapılan tornalama işlemlerinde ise en düşük yüzey pürüzlülük değerini veren en uygun işleme sıcaklığı 469 °C olarak bulunmuştur. Aynı çalışmada 49HRC sertliğindeki AISI 4340 alaşımlı çeliğin tornalanmasında ise en düşük yüzey pürüzlülük değerini veren en uygun işleme sıcaklığı 497 °C olarak bulunmuştur [13]. Bu çalışmalar incelendiğinde büyük sorunlardan birinin işleme değişkenleri değiştikçe değişen uygun sıcaklığın belirlenmesi olduğu görülmektedir. Bu sebeple günümüzün önemli çalışma alanlarından olan yapay zeka kullanımı ve makine öğrenmesi ile bu problemin çözülebileceği düşünülmektedir.

3. MAKİNE ÖĞRENMESİ (MACHINE LEARNING)

Makine öğrenmesi, yapay zeka alanının önemli bir alt dalıdır. Temel olarak, bilgisayar sistemlerinin veri setlerini kullanarak, belirli görevleri yerine getirebilmesi için öğrenme yeteneği kazanmalarını sağlayan algoritmalar ve teknikler bütünüdür. Bu algoritmalar ve teknikler, bir modelin veri setindeki desenleri tanımasını, ilişkileri anlamasını ve tahminler yapabilmesini sağlamaktadır. Makine öğrenimi, denetimli öğrenme, denetimsiz öğrenme ve pekiştirilmiş öğrenme olmak üzere üç ana kategoride incelenmektedir.



Şekil 1. Makine öğrenimi türleri (Types of machine learning) [11]

3.1. Denetimli Öğrenme (Supervised Learning)

Modelin eğitilmesi için etiketlenmiş veriler kullanılmaktadır. Etiketler, giriş verileriyle ilişkilendirilmiş doğru çıktıları temsil etmektedir. Yani model veri setine bağlı olarak, kendisine öğretilen bağımsız değişkenleri (özellikleri) kullanarak, bağımlı (hedef) değişkeni tahmin etmektedir. Sınıflandırma ve regresyon problemlerini çözmek için kullanılmaktadır.

- Sınıflandırma: Algoritmanın amacı, giriş verilerini önceden tanımlanmış bir dizi kategoriye veya sınıfa atamaktır. Bir e-postanın spam veya spam olmayan olarak sınıflandırılması bu kategori için örnek gösterilebilir.
- Regresyon: Çıktı değişkeni sürekli bir sayısal değer olmakla birlikte algoritma, giriş verileri arasındaki ilişkiyi modelleyerek, belirli bir girdiye karşılık gelen bir çıktı değerini tahmin etmektedir. Bir evin fiyatının belirlenmesi için evin özelliklerine dayalı bir regresyon modeli kullanılarak, evin fiyatı hakkında tahminlerde bulunulması bu kategori için örnek gösterilebilir.
- Karar Ağacı Regresyon (Decision Tree Regression): Veri setindeki bağımsız değişkenler ile hedef değişken arasındaki ilişkiyi modellemek için kullanılmaktadır. Her bir bağımsız değişken için bir bölme kriteri belirlenerek veri seti bölünmekte ve bir ağaç yapısı oluşturulmaktadır. Ancak veri setindeki özelliklerin karmaşık ilişkilerini temsil etmek için tek ağaç yapısı kullanılması nedeniyle aşırı uyum (overfitting) riski taşımaktadır. Aşırı uyum, eğitim verilerine aşırı uyum sağlaması ya da eğitim verilerini ezberlemesi anlamına gelmektedir. Bu durum ise modelin performansını düşüreceği için istenilmeyen bir durumdur.
- Rastgele Orman Regresyon (Random Forest Regression): Birden fazla karar ağacının (ensemble) bir araya gelerek güçlü bir tahmin modelinin oluşturulduğu regresyon yöntemidir. Her bir ağaç, eğitim verilerinden rastgele örneklemeler (boots trap sampling) olarak oluşturulmaktadır. Bu yöntem, her ağacın farklı veri alt kümeleri üzerinde eğitilmesini sağladığı için ağaçlar birbirinden farklıdır ve genelleme yeteneği fazladır. Bu çeşitlilik ise ensemble modelinin aşırı uyum (overfitting) riskini azaltmaktadır.

3.2. Denetimsiz Öğrenme (Unsupervised Learning)

Veri setinde etiketlerin olmadığı durumları ele almaktadır. Algoritma, veri setindeki yapıları kendisi keşfetmeye çalışır ve veri noktalarını birbirlerine olan benzerliklerine göre gruplandırır. Kümeleme ve boyut azaltma gibi görevlerde kullanılmaktadır. Örneğin, bir sosyal medya platformundaki kullanıcıları farklı ilgi alanlarına göre gruplandırmak için denetimsiz öğrenme modeli kullanılmaktadır.

Makine öğrenmesi, kompleks veri setlerini analiz etmek, kararlar vermek, tahminler yapmak ve otomatik sistemler oluşturmak için geniş bir kullanım alanına sahiptir. Bu yöntem sağlık, üretim, otomotiv, finans ve daha birçok endüstriye uygulanabilmekte ve bu endüstrilerde veriye dayalı karar alma süreçlerini güçlendirmektedir. Makine öğrenmesi sağlık sektöründe, hastaların sağlık verilerini (örneğin, kan basıncı, nabız, oksijen seviyeleri) analiz ederek, sağlık durumlarını değerlendirmek ve belirli hastalıklara yakalanma risklerini tahmin etmek için kullanılmaktadır. Bu durum, belirli bir hastalığa yakalanma riski yüksek olan bireylerin tanımlanmasına ve proaktif tedbirler alınmasına yardımcı olmaktadır. Talaşlı imalat sektöründe ise Gündüz (2006) yaptığı çalışmada, CNC torna tezgahında PA malzemelerini işleyerek ilerleme, kesme hızı ve kesme derinliği parametrelerine bağlı olarak kesici uca etki eden kuvvetleri dinamometre yardımıyla ölçmüştür. Bulanık mantık ve yapay sinir ağları tekniklerini kullanarak, kesme kuvveti tahmin modelleri oluşturup, deneysel çalışmayla elde edilen değerler ile karşılaştırarak yorumlamış ve kesme kuvvetlerinin tahmininde hangi yöntemin daha uygun olduğunu araştırmıştır. Burada yapay zeka tekniklerine başvurulmasının amacı, ara değerlerdeki parametreler ile kesme kuvvetlerinin tespit edilmesinde maliyet ve zaman açısından çok sayıda deney yapmanın mümkün olmadığı durumlarda, ara değerlere göre de kesme kuvvetlerinin tahminlerinde bulunabilmektir [12]. Tosun vd. (2002), yaptıkları çalışmada torna tezgahında alevle ısıtılan yüksek manganlı çelik numuneler kullanarak, ilerleme hızı, kesme derinliği, kesme hızları ve yüzey sıcaklıkları gibi farklı kesme

koşulları altında deneyler yaparak takım ömrünün tahmini için yapay sinir ağları ve regresyon analizi yöntemlerini kullanmışlardır [8].

Yukarıdaki çalışmaların incelenmesi neticesinde işlenmesi güç malzemelerin belirli sıcaklıklarda daha kolay işlendiği görülmüş fakat bu sıcaklığın tahmin edilmesi için makine öğrenmesi ile bir çalışma yapılmadığı tespit edilmiştir. Bu sebeple çalışmanın sonucunda verileri girilen malzemeler ve koşullar için istenilen işleme değişkenlerine karşılık uygun işleme sıcaklığını tespit edecek makine öğrenmesi uygulaması gerçekleştirilmiştir.

4. YÖNTEM (METHOD)

Makine öğrenmesi modeli için kullanacağımız veri seti, Uğraş (2022), ‘İşlenmesi Zor Malzemelerin Yüksek Talaş Kaldırma Oranlarıyla İşlenmesi İçin Isı Destekli Hibrid Sistemin Geliştirilmesi Ve Çalışma Parametrelerinin Belirlenmesi’ isimli çalışmasında yaptığı deney parametrelerinden ve Kavak (2019), ‘İşlenmesi Zor Malzemenin Tornalanmasının Yüzey Pürüzlülüğüne Etkisinin İstatistiksel Yöntem İle İncelenmesi’ isimli çalışmasında yaptığı deney parametrelerinden oluşmaktadır [13,5].

Uğraş (2022), İşlenmesi Zor Malzemelerin Yüksek Talaş Kaldırma Oranlarıyla İşlenmesi İçin Isı Destekli Hibrid Sistemin Geliştirilmesi ve Çalışma Parametrelerinin Belirlenmesi isimli doktora tezi deney parametreleri Tablo 1’de gösterilmektedir [13].

Tablo 1. Deney parametreleri (Experimental parameters) [13]

Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme Hızı (mm/dev)	Yüzey Pürüzlülük Değeri (μm)	Malzeme	Kesici Takım	Sıcaklık ($^{\circ}C$)
275	1	0.11	0.871	AISI4340	Kaplamalı_Karbür	388
275	1	0.11	0.805	AISI4340	Kaplamalı_Karbür	463
275	1	0.11	0.787	AISI4340	Kaplamalı_Karbür	466
275	1	0.11	0.72	AISI4340	Kaplamalı_Karbür	475
275	1	0.18	1.412	AISI4340	Kaplamalı_Karbür	265
275	1	0.18	1.294	AISI4340	Kaplamalı_Karbür	453
275	1	0.18	1.254	AISI4340	Kaplamalı_Karbür	455
275	1	0.18	1.204	AISI4340	Kaplamalı_Karbür	455
275	1	0.24	2.655	AISI4340	Kaplamalı_Karbür	257
275	1	0.24	2.416	AISI4340	Kaplamalı_Karbür	394
275	1	0.24	2.388	AISI4340	Kaplamalı_Karbür	405
275	1	0.24	2.405	AISI4340	Kaplamalı_Karbür	410
305	1	0.11	0.827	AISI4340	Kaplamalı_Karbür	386
305	1	0.11	0.763	AISI4340	Kaplamalı_Karbür	447
305	1	0.11	0.684	AISI4340	Kaplamalı_Karbür	449
305	1	0.11	0.649	AISI4340	Kaplamalı_Karbür	472
305	1	0.18	1.404	AISI4340	Kaplamalı_Karbür	263
305	1	0.18	1.273	AISI4340	Kaplamalı_Karbür	441
305	1	0.18	1.261	AISI4340	Kaplamalı_Karbür	446
305	1	0.18	1.233	AISI4340	Kaplamalı_Karbür	446
305	1	0.24	2.542	AISI4340	Kaplamalı_Karbür	255
305	1	0.24	2.406	AISI4340	Kaplamalı_Karbür	387
305	1	0.24	2.371	AISI4340	Kaplamalı_Karbür	392
305	1	0.24	2.418	AISI4340	Kaplamalı_Karbür	405

335	1	0.11	0.817	AISI4340	Kaplamalı_Karbür	383
335	1	0.11	0.745	AISI4340	Kaplamalı_Karbür	435
335	1	0.11	0.673	AISI4340	Kaplamalı_Karbür	445
335	1	0.11	0.646	AISI4340	Kaplamalı_Karbür	469
335	1	0.18	1.38	AISI4340	Kaplamalı_Karbür	261
335	1	0.18	1.27	AISI4340	Kaplamalı_Karbür	428
335	1	0.18	1.268	AISI4340	Kaplamalı_Karbür	433
335	1	0.18	1.228	AISI4340	Kaplamalı_Karbür	444
335	1	0.24	2.429	AISI4340	Kaplamalı_Karbür	253
335	1	0.24	2.381	AISI4340	Kaplamalı_Karbür	360
335	1	0.24	2.366	AISI4340	Kaplamalı_Karbür	368
335	1	0.24	2.378	AISI4340	Kaplamalı_Karbür	401
159	1	0.11	0.833	49HRC_AISI4340	Kaplamalı_Karbür	458
159	1	0.11	0.788	49HRC_AISI4340	Kaplamalı_Karbür	492
159	1	0.11	0.757	49HRC_AISI4340	Kaplamalı_Karbür	495
159	1	0.11	0.648	49HRC_AISI4340	Kaplamalı_Karbür	501
159	1	0.18	1.681	49HRC_AISI4340	Kaplamalı_Karbür	441
159	1	0.18	1.539	49HRC_AISI4340	Kaplamalı_Karbür	476
159	1	0.18	1.509	49HRC_AISI4340	Kaplamalı_Karbür	479
159	1	0.18	1.513	49HRC_AISI4340	Kaplamalı_Karbür	493
159	1	0.24	2.513	49HRC_AISI4340	Kaplamalı_Karbür	398
159	1	0.24	2.326	49HRC_AISI4340	Kaplamalı_Karbür	453
159	1	0.24	2.328	49HRC_AISI4340	Kaplamalı_Karbür	474
159	1	0.24	2.353	49HRC_AISI4340	Kaplamalı_Karbür	479
176	1	0.11	0.812	49HRC_AISI4340	Kaplamalı_Karbür	451
176	1	0.11	0.741	49HRC_AISI4340	Kaplamalı_Karbür	486
176	1	0.11	0.733	49HRC_AISI4340	Kaplamalı_Karbür	490
176	1	0.11	0.671	49HRC_AISI4340	Kaplamalı_Karbür	500
176	1	0.18	1.623	49HRC_AISI4340	Kaplamalı_Karbür	435
176	1	0.18	1.549	49HRC_AISI4340	Kaplamalı_Karbür	469
176	1	0.18	1.56	49HRC_AISI4340	Kaplamalı_Karbür	471
176	1	0.18	1.42	49HRC_AISI4340	Kaplamalı_Karbür	488
176	1	0.24	2.441	49HRC_AISI4340	Kaplamalı_Karbür	397
176	1	0.24	2.352	49HRC_AISI4340	Kaplamalı_Karbür	452
176	1	0.24	2.305	49HRC_AISI4340	Kaplamalı_Karbür	462
176	1	0.24	2.275	49HRC_AISI4340	Kaplamalı_Karbür	475
194	1	0.11	0.793	49HRC_AISI4340	Kaplamalı_Karbür	447
194	1	0.11	0.744	49HRC_AISI4340	Kaplamalı_Karbür	484
194	1	0.11	0.658	49HRC_AISI4340	Kaplamalı_Karbür	489
194	1	0.11	0.631	49HRC_AISI4340	Kaplamalı_Karbür	497
194	1	0.18	1.526	49HRC_AISI4340	Kaplamalı_Karbür	432
194	1	0.18	1.414	49HRC_AISI4340	Kaplamalı_Karbür	467
194	1	0.18	1.448	49HRC_AISI4340	Kaplamalı_Karbür	470
194	1	0.18	1.446	49HRC_AISI4340	Kaplamalı_Karbür	486
194	1	0.24	2.509	49HRC_AISI4340	Kaplamalı_Karbür	394
194	1	0.24	2.455	49HRC_AISI4340	Kaplamalı_Karbür	442
194	1	0.24	2.394	49HRC_AISI4340	Kaplamalı_Karbür	443
194	1	0.24	2.343	49HRC_AISI4340	Kaplamalı_Karbür	465

Kavak (2019), ‘İşlenmesi Zor Malzemenin Tornalanmasının Yüzey Pürüzlülüğüne Etkisinin İstatistiksel Yöntem ile İncelenmesi’ isimli yüksek lisans tezi deney parametreleri Tablo 2’de gösterilmektedir.[5]

Tablo 2. Deney parametreleri (Experimental parameters) [5]

Kesme Hızı (<i>m/dak</i>)	Kesme Derinliği (<i>mm</i>)	İlerleme Hızı (<i>mm/dev</i>)	Yüzey Pürüzlülük Değeri (μm)	Malzeme	Kesici Takım	Sıcaklık ($^{\circ}\text{C}$)
92.67	1	0.098	1.26	Ti6Al4V	KSZ	20
92.67	1	0.098	1.12	Ti6Al4V	KSZ	250
92.67	1	0.098	0.95	Ti6Al4V	KSZ	450
92.67	1	0.098	1.57	Ti6Al4V	KSZ	650
92.67	1	0.196	2.6	Ti6Al4V	KSZ	20
92.67	1	0.196	2.31	Ti6Al4V	KSZ	250
92.67	1	0.196	1.93	Ti6Al4V	KSZ	450
92.67	1	0.196	3.11	Ti6Al4V	KSZ	650
185.35	1	0.098	1.34	Ti6Al4V	KSZ	20
185.35	1	0.098	1.24	Ti6Al4V	KSZ	250
185.35	1	0.098	1.07	Ti6Al4V	KSZ	450
185.35	1	0.098	1.7	Ti6Al4V	KSZ	650
185.35	1	0.196	2.87	Ti6Al4V	KSZ	20
185.35	1	0.196	2.54	Ti6Al4V	KSZ	250
185.35	1	0.196	2.17	Ti6Al4V	KSZ	450
185.35	1	0.196	3.45	Ti6Al4V	KSZ	650
278.03	1	0.098	1.61	Ti6Al4V	KSZ	20
278.03	1	0.098	1.47	Ti6Al4V	KSZ	250
278.03	1	0.098	1.35	Ti6Al4V	KSZ	450
278.03	1	0.098	2.03	Ti6Al4V	KSZ	650
278.03	1	0.196	3.34	Ti6Al4V	KSZ	20
278.03	1	0.196	2.98	Ti6Al4V	KSZ	250
278.03	1	0.196	2.62	Ti6Al4V	KSZ	450
278.03	1	0.196	3.98	Ti6Al4V	KSZ	650
92.67	1	0.098	1.34	Ti6Al4V	KPL	20
92.67	1	0.098	1.25	Ti6Al4V	KPL	250
92.67	1	0.098	1.13	Ti6Al4V	KPL	450
92.67	1	0.098	1.65	Ti6Al4V	KPL	650
92.67	1	0.196	2.81	Ti6Al4V	KPL	20
92.67	1	0.196	2.53	Ti6Al4V	KPL	250
92.67	1	0.196	2.25	Ti6Al4V	KPL	450
92.67	1	0.196	3.46	Ti6Al4V	KPL	650
185.35	1	0.098	1.41	Ti6Al4V	KPL	20
185.35	1	0.098	1.34	Ti6Al4V	KPL	250
185.35	1	0.098	1.24	Ti6Al4V	KPL	450
185.35	1	0.098	1.77	Ti6Al4V	KPL	650
185.35	1	0.196	3.07	Ti6Al4V	KPL	20
185.35	1	0.196	2.71	Ti6Al4V	KPL	250
185.35	1	0.196	2.43	Ti6Al4V	KPL	450

185.35	1	0.196	3.64	Ti6Al4V	KPL	650
278.03	1	0.098	1.73	Ti6Al4V	KPL	20
278.03	1	0.098	1.59	Ti6Al4V	KPL	250
278.03	1	0.098	1.5	Ti6Al4V	KPL	450
278.03	1	0.098	2.15	Ti6Al4V	KPL	650
278.03	1	0.196	3.62	Ti6Al4V	KPL	20
278.03	1	0.196	3.31	Ti6Al4V	KPL	250
278.03	1	0.196	2.95	Ti6Al4V	KPL	450
278.03	1	0.196	4.35	Ti6Al4V	KPL	650
92.67	1	0.098	1.12	Ti6Al4V	KİG	20
92.67	1	0.098	1.03	Ti6Al4V	KİG	250
92.67	1	0.098	0.79	Ti6Al4V	KİG	450
92.67	1	0.098	1.35	Ti6Al4V	KİG	650
92.67	1	0.196	2.25	Ti6Al4V	KİG	20
92.67	1	0.196	2.15	Ti6Al4V	KİG	250
92.67	1	0.196	1.65	Ti6Al4V	KİG	450
92.67	1	0.196	2.71	Ti6Al4V	KİG	650
185.35	1	0.098	1.24	Ti6Al4V	KİG	20
185.35	1	0.098	1.12	Ti6Al4V	KİG	250
185.35	1	0.098	0.94	Ti6Al4V	KİG	450
185.35	1	0.098	1.45	Ti6Al4V	KİG	650
185.35	1	0.196	2.51	Ti6Al4V	KİG	20
185.35	1	0.196	2.37	Ti6Al4V	KİG	250
185.35	1	0.196	1.9	Ti6Al4V	KİG	450
185.35	1	0.196	2.83	Ti6Al4V	KİG	650
278.03	1	0.098	1.41	Ti6Al4V	KİG	20
278.03	1	0.098	1.35	Ti6Al4V	KİG	250
278.03	1	0.098	1.19	Ti6Al4V	KİG	450
278.03	1	0.098	1.77	Ti6Al4V	KİG	650
278.03	1	0.196	3.05	Ti6Al4V	KİG	20
278.03	1	0.196	2.81	Ti6Al4V	KİG	250
278.03	1	0.196	2.29	Ti6Al4V	KİG	450
278.03	1	0.196	3.44	Ti6Al4V	KİG	650
92.67	1	0.098	2.03	AISI4340	KSZ	20
92.67	1	0.098	1.68	AISI4340	KSZ	250
92.67	1	0.098	1.46	AISI4340	KSZ	450
92.67	1	0.098	1.29	AISI4340	KSZ	650
92.67	1	0.196	4.08	AISI4340	KSZ	20
92.67	1	0.196	3.4	AISI4340	KSZ	250
92.67	1	0.196	3.01	AISI4340	KSZ	450
92.67	1	0.196	2.94	AISI4340	KSZ	650
185.35	1	0.098	1.78	AISI4340	KSZ	20
185.35	1	0.098	1.44	AISI4340	KSZ	250
185.35	1	0.098	1.2	AISI4340	KSZ	450
185.35	1	0.098	1.15	AISI4340	KSZ	650
185.35	1	0.196	3.55	AISI4340	KSZ	20
185.35	1	0.196	2.81	AISI4340	KSZ	250
185.35	1	0.196	2.51	AISI4340	KSZ	450

185.35	1	0.196	2.45	AISI4340	KSZ	650
278.03	1	0.098	1.59	AISI4340	KSZ	20
278.03	1	0.098	1.27	AISI4340	KSZ	250
278.03	1	0.098	1.15	AISI4340	KSZ	450
278.03	1	0.098	1.49	AISI4340	KSZ	650
278.03	1	0.196	3.31	AISI4340	KSZ	20
278.03	1	0.196	2.59	AISI4340	KSZ	250
278.03	1	0.196	2.34	AISI4340	KSZ	450
278.03	1	0.196	3.35	AISI4340	KSZ	650
92.67	1	0.098	1.66	AISI4340	KPL	20
92.67	1	0.098	1.42	AISI4340	KPL	250
92.67	1	0.098	1.2	AISI4340	KPL	450
92.67	1	0.098	1.06	AISI4340	KPL	650
92.67	1	0.196	3.41	AISI4340	KPL	20
92.67	1	0.196	2.81	AISI4340	KPL	250
92.67	1	0.196	2.43	AISI4340	KPL	450
92.67	1	0.196	2.33	AISI4340	KPL	650
185.35	1	0.098	1.4	AISI4340	KPL	20
185.35	1	0.098	1.16	AISI4340	KPL	250
185.35	1	0.098	0.93	AISI4340	KPL	450
185.35	1	0.098	0.87	AISI4340	KPL	650
185.35	1	0.196	2.71	AISI4340	KPL	20
185.35	1	0.196	2.25	AISI4340	KPL	250
185.35	1	0.196	1.89	AISI4340	KPL	450
185.35	1	0.196	1.76	AISI4340	KPL	650
278.03	1	0.098	1.25	AISI4340	KPL	20
278.03	1	0.098	1.02	AISI4340	KPL	250
278.03	1	0.098	0.85	AISI4340	KPL	450
278.03	1	0.098	0.76	AISI4340	KPL	650
278.03	1	0.196	2.54	AISI4340	KPL	20
278.03	1	0.196	1.95	AISI4340	KPL	250
278.03	1	0.196	1.67	AISI4340	KPL	450
278.03	1	0.196	1.62	AISI4340	KPL	650
92.67	1	0.098	1.88	AISI4340	KİG	20
92.67	1	0.098	1.55	AISI4340	KİG	250
92.67	1	0.098	1.29	AISI4340	KİG	450
92.67	1	0.098	1.16	AISI4340	KİG	650
92.67	1	0.196	3.65	AISI4340	KİG	20
92.67	1	0.196	3	AISI4340	KİG	250
92.67	1	0.196	2.61	AISI4340	KİG	450
92.67	1	0.196	2.45	AISI4340	KİG	650
185.35	1	0.098	1.55	AISI4340	KİG	20
185.35	1	0.098	1.29	AISI4340	KİG	250
185.35	1	0.098	1.09	AISI4340	KİG	450
185.35	1	0.098	0.98	AISI4340	KİG	650
185.35	1	0.196	3.01	AISI4340	KİG	20
185.35	1	0.196	2.45	AISI4340	KİG	250
185.35	1	0.196	2.11	AISI4340	KİG	450

185.35	1	0.196	2.05	AISI4340	KİG	650
278.03	1	0.098	1.4	AISI4340	KİG	20
278.03	1	0.098	1.12	AISI4340	KİG	250
278.03	1	0.098	1.01	AISI4340	KİG	450
278.03	1	0.098	1.27	AISI4340	KİG	650
278.03	1	0.196	2.85	AISI4340	KİG	20
278.03	1	0.196	2.23	AISI4340	KİG	250
278.03	1	0.196	1.91	AISI4340	KİG	450
278.03	1	0.196	2.81	AISI4340	KİG	650

Uğraş (2022), çalışmasında 72 adet deney yapmıştır. Yapılan bu deneylerde AISI 4340 çeliği için; 275, 305 ve 335 m/dak hızlarında, kesme derinliği 1 mm olacak şekilde sabit tutularak ve ilerleme hızları; 0.11 mm/dev için 4 adet deney, 0.18 mm/dev için 4 adet deney ve 0.24 mm/dev için 4 adet deney olmak üzere 12'şer adet, toplamda 36 deney yapmıştır. 49 HRC sertliğindeki AISI 4340 çeliği içinse; 159, 176 ve 194 m/dak hızlarında, kesme derinliği 1 mm olacak şekilde sabit tutularak ve ilerleme hızları; 0.11 mm/dev için 4 adet deney, 0.18 mm/dev için 4 adet deney ve 0.24 mm/dev için 4 adet deney olmak üzere 12'şer adet toplamda 36 deney yapmıştır.

Kavak (2019) çalışmasında, kesme derinliği 1 mm olacak şekilde sabit tutularak toplam 144 adet deney yapmıştır. Yapılan bu deneylerde Ti6Al4V titanyum alaşımı için, KİG (kriyojenik işlem görmüş karbür) kesici takım kullanarak, hız: 92,67 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 185,35 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 278,03 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney olmak üzere toplam 24 adet deney, KPL (PVD kaplamalı karbür) kesici takım kullanarak, hız: 92,67 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 185,35 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 278,03 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney olmak üzere toplam 24 adet deney, KŞZ (kaplamasız karbür) kesici takım kullanarak, hız: 92,67 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 185,35 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 278,03 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney olmak üzere toplam 24 adet deney, genel toplamda ise 72 adet deney yapmıştır. AISI 4340 çeliği için aynı şekilde, KİG (kriyojenik işlem görmüş karbür) kesici takım kullanarak, hız: 92,67 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 185,35 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 278,03 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney olmak üzere toplam 24 adet deney, KPL (PVD kaplamalı karbür) kesici takım kullanarak, hız: 92,67 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 185,35 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 278,03 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney olmak üzere toplam 24 adet deney, KŞZ (kaplamasız karbür) kesici takım kullanarak, hız: 92,67 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 185,35 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney, hız: 278,03 m/dak için; 0.098 mm/dev ilerleme hızında 4 adet deney, 0.196 mm/dev ilerleme hızında 4 adet deney olmak üzere toplam 24 adet deney, genel toplamda ise 72 adet deney yapmıştır.

Veri setimiz (dataset) ise, en uygun işleme sıcaklığını tespit etmeyi amaçladığımız için; aynı parametreler ile 4'er adet tekrarlanarak ölçülen yüzey pürüzlülük değerleri arasından, en düşük yüzey pürüzlülüğünün ölçüldüğü sıcaklık değerleri ve deney parametreleri seçilerek oluşturulmuştur. Bu şekilde, Uğraş (2022) ve Kavak (2019) tarafından deneyleri yapılarak elde edilmiş toplam 216 adet olan veri sayısı (Tablo 1 ve Tablo 2'de gösterilmiştir), en düşük yüzey pürüzlülüğünün elde edildiği sıcaklık değerleri seçilerek oluşturulduğu için 54 adede düşürülmüştür. Oluşturulan veri seti Tablo 3'te gösterilmektedir.

Tablo 3. Veri seti (Data set) [13,5]

	Kesme_Hızı	Kesme_Derinliği	İlerleme	YPD	Malzeme	Kesici_Takım	Sıcaklık
1	275	1	0.11	0.72	AISI4340	Kaplamalı_Karbür	475
2	275	1	0.18	1.204	AISI4340	Kaplamalı_Karbür	455
3	275	1	0.24	2.388	AISI4340	Kaplamalı_Karbür	405
4	305	1	0.11	0.649	AISI4340	Kaplamalı_Karbür	472
5	305	1	0.18	1.233	AISI4340	Kaplamalı_Karbür	446
6	305	1	0.24	2.371	AISI4340	Kaplamalı_Karbür	392
7	335	1	0.11	0.646	AISI4340	Kaplamalı_Karbür	445
8	335	1	0.18	1.228	AISI4340	Kaplamalı_Karbür	444
9	335	1	0.24	2.366	AISI4340	Kaplamalı_Karbür	368
10	159	1	0.11	0.648	49HRC_AISI4340	Kaplamalı_Karbür	501
11	159	1	0.18	1.509	49HRC_AISI4340	Kaplamalı_Karbür	479
12	159	1	0.24	2.326	49HRC_AISI4340	Kaplamalı_Karbür	453
13	176	1	0.11	0.671	49HRC_AISI4340	Kaplamalı_Karbür	500
14	176	1	0.18	1.42	49HRC_AISI4340	Kaplamalı_Karbür	488
15	176	1	0.24	2.275	49HRC_AISI4340	Kaplamalı_Karbür	475
16	194	1	0.11	0.631	49HRC_AISI4340	Kaplamalı_Karbür	497
17	194	1	0.18	1.414	49HRC_AISI4340	Kaplamalı_Karbür	467
18	194	1	0.24	2.343	49HRC_AISI4340	Kaplamalı_Karbür	465
19	92.67	1	0.098	0.79	Ti6Al4V	KİG	450
20	92.67	1	0.196	1.65	Ti6Al4V	KİG	450
21	92.67	1	0.098	0.95	Ti6Al4V	KSZ	450
22	92.67	1	0.196	1.93	Ti6Al4V	KSZ	450
23	92.67	1	0.098	1.29	AISI4340	KSZ	650
24	92.67	1	0.196	2.94	AISI4340	KSZ	650
25	92.67	1	0.098	1.16	AISI4340	KİG	650
26	92.67	1	0.196	2.45	AISI4340	KİG	650
27	92.67	1	0.098	1.06	AISI4340	KPL	650
28	92.67	1	0.196	2.33	AISI4340	KPL	650
29	92.67	1	0.098	1.13	Ti6Al4V	KPL	450
30	92.67	1	0.196	2.25	Ti6Al4V	KPL	450
31	185.35	1	0.098	0.94	Ti6Al4V	KİG	450
32	185.35	1	0.196	1.9	Ti6Al4V	KİG	450
33	185.35	1	0.098	1.07	Ti6Al4V	KSZ	450
34	185.35	1	0.196	2.17	Ti6Al4V	KSZ	450
35	185.35	1	0.098	1.15	AISI4340	KSZ	650
36	185.35	1	0.196	2.45	AISI4340	KSZ	650
37	185.35	1	0.098	0.98	AISI4340	KİG	650
38	185.35	1	0.196	2.05	AISI4340	KİG	650

39	185.35	1	0.098	0.87	AISI4340	KPL	650
40	185.35	1	0.196	1.76	AISI4340	KPL	650
41	185.35	1	0.098	1.24	Ti6Al4V	KPL	450
42	185.35	1	0.196	2.43	Ti6Al4V	KPL	450
43	278.03	1	0.098	1.19	Ti6Al4V	KİG	450
44	278.03	1	0.196	2.29	Ti6Al4V	KİG	450
45	278.03	1	0.098	1.35	Ti6Al4V	KSZ	450
46	278.03	1	0.196	2.62	Ti6Al4V	KSZ	450
47	278.03	1	0.098	1.15	AISI4340	KSZ	450
48	278.03	1	0.196	2.34	AISI4340	KSZ	450
49	278.03	1	0.098	1.01	AISI4340	KİG	450
50	278.03	1	0.196	1.91	AISI4340	KİG	450
51	278.03	1	0.098	0.76	AISI4340	KPL	650
52	278.03	1	0.196	1.62	AISI4340	KPL	650
53	278.03	1	0.098	1.5	Ti6Al4V	KPL	450
54	278.03	1	0.196	2.95	Ti6Al4V	KPL	450

Makine öğrenmesi modeli Python dili kullanılarak Google Colab üzerinde yazılmıştır. Karar Ağacı Regresyon ve Rastgele Orman Regresyon algoritmaları kullanılarak oluşturulan makine öğrenmesi modelinin performans metrikleri (R^2 , MAE, MSE, MAPE) değerlendirilmiştir.

- R-squared (R^2 , R-kare): Modelin veri setine bağlı olarak ne kadar doğru tahminler yaptığını gösteren bir ölçüttür. Yüzde olarak ifade edilir. 0 ile 1 arasında değer alır ve 1'e yakın olması modelin performansının daha iyi olduğunu ve daha iyi uyum sağladığını gösterir.
- MSE (Mean Squared Error-Ortalama Kare Hata): Tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasıdır. MSE ne kadar düşüğe tahminler gerçek değerlere o kadar yakındır. Yani model daha iyi bir performans gösterir.
- MAE (Mean Absolute Error-Ortalama Mutlak Hata): Tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak değerleri alınır ve bu değerlerin ortalaması hesaplanarak bulunur. Regresyon modelinde tahmin edilen değerlerin gerçek değerlerden ne kadar uzaklıkta olduğunu ölçen bir hata metriğidir. MAE değerinin düşük olması modelin daha doğru tahminler yaptığını gösterir.
- MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata): Tahmin edilen değerlerin gerçek değerlere oranla yüzde olarak ne kadar hata yaptığını ölçer. MAPE değerinin düşük olması modelin yüzde olarak daha az hata yaptığını gösterir.

Makine öğrenmesi modelini kurmak için ilk önce gerekli olan Pandas ve Numpy kütüphaneleri çağırıldı. Bu kütüphanelerden Pandas kütüphanesi, veri analizi ve veri manipülasyonu için kullanılmaktadır. Bu kütüphane, verileri işlemek, temizlemek, analiz etmek ve dönüştürmek için bir dizi veri yapıları ve fonksiyonlar sağlamaktadır. Pandas'ın temel veri yapıları Series ve DataFrame'dir. Numpy kütüphanesi ise, bilimsel hesaplamalar yapmak için kullanılan temel bir kütüphanedir. Numpy, çok boyutlu diziler (arrays) oluşturmak ve bu diziler üzerinde hızlı matematiksel işlemler gerçekleştirmek için kullanılmaktadır.

```
[ ] 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_Deriniği	İlerleme	YPD	Sıcaklık	Malzeme_49HRC_AISI4340	Malzeme_AISI4340	Malzeme_Ti6Al4V	Kesici_Takım_KPL	Kesici_Takım_KSZ	Kesici_Takım_Kaplamalı_Karbür	Kesici_Takım_KİG
0	275.0	1	0.11	0.720	475	False	True	False	False	False	True	False
1	275.0	1	0.18	1.204	455	False	True	False	False	False	True	False
2	275.0	1	0.24	2.388	405	False	True	False	False	False	True	False
3	305.0	1	0.11	0.649	472	False	True	False	False	False	True	False
4	305.0	1	0.18	1.233	446	False	True	False	False	False	True	False

Şekil 2. Google Colab ile yazılan makine öğrenmesi modelinin 1.bölümünün ekran görüntüsü (Screenshots of the first part of the machine learning model written with Google Colab)

Şekil 2’de görüldüğü üzere Pandas kütüphanesi kullanılarak ‘VeriSeti’ isimli ve excel uzantılı veri seti çağırıldı. Daha sonra veri setinde bulunan bütün değerlerin numerik olması gerektiği için ‘Malzeme ve Kesici_Takım’ sütunları Pandas’ın ‘get_dummies’ metodu ile kategorik verilere dönüştürüldü. 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

[ ] x_train, x_test, y_train, y_test = train_test_split(x,y, train_size=0.85, random_state=16)
```

Şekil 3. Google Colab ile yazılan makine öğrenmesi modelinin devamının ekran görüntüsü (Screenshot of the continuation of the machine learning model written with Google Colab)

Şekil 3’te ise tahmin modelini kurmak 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 ifade etmektedir. Daha sonra verilerin özelliklerini standartlaştırmak için kullanılan bir ön işleme tekniği olan StandardScaler sınıfı kullanıldı. Bu metot, veri özelliklerini (değişkenleri) ortalama değeri sıfır ve standart sapması bir olacak şekilde dönüştürmektedir. Daha sonra ise bağımsız (x) ve bağımlı (y) değişkenleri, eğitim ve test olmak üzere parçalara ayrılarak teste tabi tutuldu ve daha güvenilir bir makine öğrenmesi gerçekleştirildi. Burada eğitim için %85’lik bir parça ayrıldı ve %85’lik kısmı öğrenmesi istenildi. Geriye kalan %15’lik kısım içinse teste tabi tutularak tahminlerde bulunması istenildi.

```
[ ] 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)
```

0.983444879106377

```
[ ] from sklearn.ensemble import RandomForestRegressor
rf= RandomForestRegressor (n_estimators=100, random_state=13)
model=rf.fit(x_train, y_train)
tahmin_random_regression = model.predict(x_test)
model.score(x_test,y_test)
```

0.982117463590517

Şekil 4. Google Colab ile yazılan makine öğrenmesi modelinin devamının ekran görüntüsü (Screenshot of the continuation of the machine learning model written with Google Colab)

Şekil 4’te ise eğitim ve test olmak üzere iki parçaya ayrılarak oluşturulan makine öğrenmesi modelinin Karar Ağacı Regresyon (Decision Tree Regression) ve Rastgele Orman Regresyonu (Random Forest Regression) performans skorları gösterilmektedir.

5. ÇALIŞMANIN BULGULARI (FINDINGS OF THE STUDY)

Makine öğrenmesi algoritmaları ile oluşturulan modelimizin yapacağı tahminlere ait performans metrikleri, her iki regresyon modeli için de doğruluk oranının yüksek olduğunu göstermektedir.

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

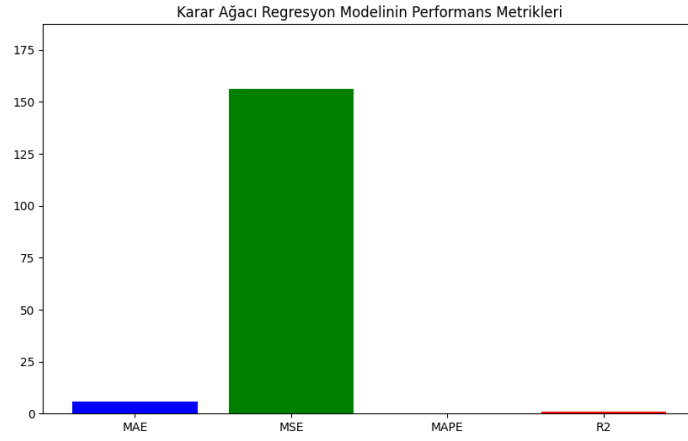
```
[ ] r2= r2_score(y_test,tahmin_tree_regression)
mse= mean_squared_error(y_test, tahmin_tree_regression)
mae= mean_absolute_error(y_test, tahmin_tree_regression)
mape= mean_absolute_percentage_error(y_test, tahmin_tree_regression)
```

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

r2_score: 0.983444879106377, MSE: 156.11111111111111, MAE: 5.888888888888889, MAPE: 0.012733170368707466

Şekil 5. Google Colab İle yazılan makine öğrenmesi modelinin devamının ekran görüntüsü (Screenshot of the continuation of the machine learning model written with Google Colab)

Şekil 5’te Karar Ağacı Regresyon (Decision Tree Regression) modelinin performans metrikleri gösterilmektedir. Bulunan metrikler değerlendirildiğinde. Karar Ağacı Regresyon algoritması kullanılarak oluşturulan modelin R2 değerinin 0.98 bulunduğu ve 1’e yakın olduğu için çok iyi bir performansa sahip olduğu görülmektedir. MSE değerinin ise 156.1 bulunduğu ve iyileştirilebilir olduğu görülmektedir. MAE (5.8) ve MAPE (%1.27) değerlerinin ise oldukça düşük olduğu ve bulunan metrikler bir bütün olarak değerlendirildiğinde, modelin performansının başarılı olduğu görülmektedir. Karar Ağacı Regresyon modeli performans metrik grafiği Şekil 6’da gösterilmektedir.



Şekil 6. Karar ağacı regresyon modelinin performans metrikleri (Performance metrics of decision tree regression model)

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

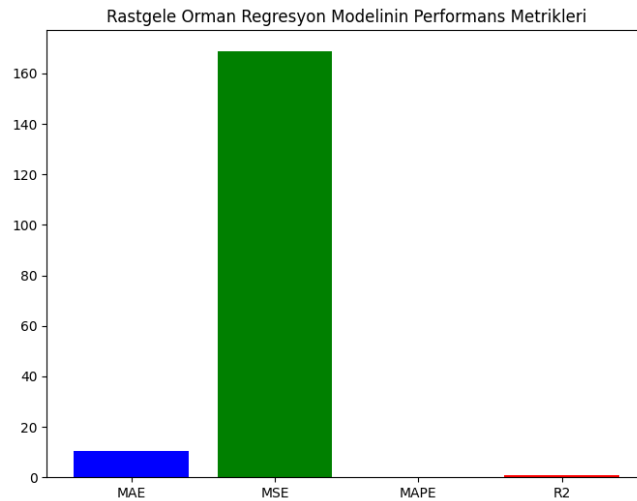
```
[ ] R2= r2_score(y_test,tahmin_random_regression)
MSE= mean_squared_error(y_test, tahmin_random_regression)
MAE= mean_absolute_error(y_test, tahmin_random_regression)
MAPE= mean_absolute_percentage_error(y_test, tahmin_random_regression)
```

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

```
r2_score: 0.982117463590517, MSE: 168.62834444444444, MAE: 10.469999999999995, MAPE: 0.018746633508780395
```

Şekil 7. Google Colab ile yazılan makine öğrenmesi modelinin devamının ekran görüntüsü (Screenshot of the continuation of the machine learning model written with Google Colab)

Şekil 7’de ise Rastgele Orman Regresyon (Random Forest Regression) modelinin performans metrikleri gösterilmektedir. Bulunan metrikler değerlendirildiğinde, Rastgele Orman Regresyon algoritması kullanılarak oluşturulan modelin R2 değerinin 0.98 bulunduğu ve 1’e yakın olduğu için çok iyi bir performansa sahip olduğu görülmektedir. MSE değerinin ise 168.62 bulunduğu ve iyileştirilebilir olduğu görülmektedir. MAE (10.46) ve MAPE (%1.87) değerlerinin ise oldukça düşük olduğu ve bulunan metrikler bir bütün olarak değerlendirildiğinde, modelin performansının başarılı olduğu görülmektedir. Rastgele Orman Regresyon modeli performans metrik grafiği Şekil 8’de gösterilmektedir.



Şekil 8. Rastgele orman regresyon modelinin performans metrikleri (Performance metrics of random forest regression model)

İncelenen skorlar neticesinde, makine öğrenmesi modelinin her iki yöntem için de yapacağı tahminlerin doğruluk oranlarının yüksek olduğu görülmektedir. Ancak aşırı uyum (overfitting) riskinin daha az ve yapacağı tahminlerin daha güvenilir olması nedeniyle Rastgele Orman Regresyon (Random Forest Regression) algoritması tercih edilmiştir.

```
[ ] df.head()
  Kesme_Hızı Kesme_Derinliği İlerleme YPD Sıcaklık Malzeme_49HRC_AISI4340 Malzeme_AISI4340 Malzeme_Ti6Al4V Kesici_Takım_KPL Kesici_Takım_KSZ Kesici_Takım_Kaplamalı_Karbür Kesici_Takım_KİG
0 275.0 0.8 0.1 0.65 475 False True False False False True False
1 275.0 1.1 0.35 2.4 455 False True False False False True False
2 172.0 0.7 0.2 1.8 447.07 False True False False False True False
3 300.0 0.5 0.65 2.1 446.54 False True False False False True False
4 98.0 0.8 0.12 1.2 433.85 False True False False False True False

[ ] model.predict([[270,0.8,0.10,0.65,0,1,0,0,0,1,0]])
array([438.3])
```

Şekil 9. Google Colab İle yazılan makine öğrenmesi modelinin tahmin bölümünün ekran görüntüsü (Screenshot of the prediction section of the machine learning model written with Google Colab)

Şekil 9’da ise veri setimiz baz alınarak, eğitim ve test olmak üzere iki parçaya ayrılarak oluşturulan makine öğrenmesi modelinin. Rastgele Orman Regresyon (Random Forest Regression) algoritmasını kullanarak bir tahminde bulunması istenilmiştir. Kendi belirlediğimiz parametreler ile kesme hızı:270 m/dak. kesme derinliği:0.8 mm, ilerleme:0.10 mm/dev, YPD (yüzey pürüzlülük değeri):0.65 μ m, malzeme: AISI4340 ve kesici takım: kaplamalı karbür olacak şekilde bir tahmin yapmasını istediğimizde, tahmin ettiği en uygun sıcaklık değerinin 438.3 $^{\circ}$ C olduğu görülmektedir.

Tablo 4. Tahmin edilen sıcaklık değerleri (The estimated temperature values)

Kesme Hızı (m/dak)	Kesme Derinliği (mm)	İlerleme (mm/dev)	YPD (μ m)	AISI4340 49HRC	AISI4340	Ti6Al4V	Kaplamalı karbür	KPL	KSZ	KİG	Tahmin Edilen Sıcaklık ($^{\circ}$ C)
270	0.8	0.1	0.65	0	1	0	1	0	0	0	438.3
320	1.1	0.35	2.4	0	1	0	1	0	0	0	428.53
172	0.7	0.2	1.8	1	0	0	1	0	0	0	447.07
300	0.5	0.65	2.1	1	0	0	1	0	0	0	446.54
98	0.8	0.12	1.2	0	0	1	0	0	0	1	433.85
105	0.9	0.2	1.82	0	0	1	0	0	1	0	447.16
180	1	0.22	2.5	0	0	1	0	1	0	0	444.35
253	0.95	0.087	1.92	0	1	0	0	0	0	1	452.43
315	1.2	0.2	3	0	1	0	0	0	1	0	447.83
166	1.3	0.18	0.75	0	1	0	0	1	0	0	587.75

Tablo 4’te örnek olarak, kendi oluşturduğumuz ara değerlere göre makine öğrenmesi modelimizin tahmin ettiği en uygun sıcaklık değerleri gösterilmektedir.

6. SONUÇLAR VE ÖNERİLER (CONCLUSIONS AND RECOMMENDATIONS)

Çalışmanın sonucunda, belirli malzemeler için kesme hızı, yüzey pürüzlülük değeri, ilerleme hızı, kesme derinliği, malzeme ve kesici takım parametreleri girilerek en uygun işleme sıcaklığını tahmin etmek için Karar Ağacı Regresyon (Decision Tree Regression) ve Rastgele Orman Regresyon (Random Forest Regression) algoritmaları kullanılarak makine öğrenmesi modeli oluşturulmuştur. İncelenen skorlar neticesinde, oluşturulan modellerin R^2 değerinin 0.98 bulunduğu ve 1’e yakın olduğu için çok iyi bir performansa sahip olduğu görülmektedir. Ortalama Mutlak Yüzde Hata (MAPE) değeri. Karar Ağacı Regresyon için %1.27 ve Rastgele Orman Regresyon için

%1.87 olarak bulunmuştur. Makine öğrenmesi modelinin, her iki yöntem için de yapacağı tahminlerin doğruluk oranlarının yüksek olduğu tespit edilmiştir. Ancak aşırı uyum (overfitting) riskinin daha az ve yapacağı tahminlerin daha güvenilir olması nedeniyle Rastgele Orman Regresyon algoritması tercih edilmiştir.

Özellikle her alanda otomasyona geçilen günümüzde bu bilgilerin tahmin edilmesine her geçen gün daha fazla ihtiyaç duyulmaktadır. Tahmin edilen uygun sıcaklığın kullanılması sayesinde kesme kuvvetinin, takım aşınmasının, iş parçasının aşınmasının/kırılmasının ve yüzey pürüzlülüğünün azaltılması sağlanarak maliyetten ve zamandan tasarruf edilmiş olacaktır.

Veri setindeki değerler baz alınmak suretiyle, istenilen parametre değerleri girilerek sıcaklık tahmininde bulunulacağı için, ara değerler için de yapılmak istenen deney için ön hazırlık ile belirlenmiş parametreler için de deneme yanılma yöntemine gerek kalmadan tahmin edilen sıcaklığa göre işlem yapılabilecektir.

Bu çalışmada en uygun işleme sıcaklığını tespit etmek için, en düşük yüzey pürüzlülük değerleri kullanılmıştır. Aynı şekilde en düşük kesme kuvveti ve en az takım aşınması değerlerini içeren deney parametreleri kullanılarak oluşturulan yeni veri setleri ile de en uygun işleme sıcaklıkları tahmin edilebilir.

Makine öğrenmesi modelinin performansı, veri setindeki deney parametre değerlerinin artırılması ile daha iyi olacaktır. Bu sayede daha fazla tahminde bulunabilir. Ayrıca farklı malzemeler için yapılacak çalışmalar yapay zeka uygulamaları için veri tabanı oluşturulmasına yardımcı olacaktır.

KAYNAKLAR (REFERENCES)

1. R. Binali, S. Yıldız, S. Neşeli, S960QL yapı çeliğinin işlenebilirliğinin sonlu elemanlar yöntemi ile incelenmesi, *European Journal of Science and Technology*, 31:85-91,2021.
2. R. Binali, S. Yıldız, S. Neşeli, Investigation of power consumption in the machining of S960QL steel by finite elements method. *European Journal of Technique*, 12, 2022.
3. İ. Asiltürk, M. Kuntoğlu, R. Binali, H. Akkuş, E. Salur, 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, 2023.
4. M.K. Gupta, M.E. Korkmaz, M. Sarıkaya, G.M. Krolczyk, M. Günay, 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, 2022.
5. Y. Kavak, İşlenmesi zor malzemenin tornalanmasının yüzey pürüzlülüğüne etkisinin istatistiksel yöntem ile incelenmesi, Yüksek Lisans Tezi, Düzce Üniversitesi, Fen Bilimleri Enstitüsü, Düzce, Türkiye, 2019.
6. C.R. Dandekar, Y.C. Shin, J. Barnes, Machinability improvement of titanium alloy (Ti-6Al-4V) via LAM and hybrid machining, *International Journal of Machine Tools and Manufacture*, 50(2): 174–182, 2010.
7. Y. Ayed, G. Germain, W. Ben Salem, H. Hamdi, Experimental and numerical study of laser-assisted machining of Ti6Al4V titanium alloy, *Finite Elements in Analysis and Design*, 92: 72–79, 2014.
8. N. Tosun, L. Özler, A study of tool life in hot machining using artificial neural Networks and regression analysis method, *Journal of Materials Processing Technology*, 124(1–2): 99–104,2002.
9. K.P. Maity, P.K. Swain, An experimental investigation of hot-machining to predict tool life, *Journal of Materials Processing Technology*, 198(1–3):344–349, 2008.
10. P.A. Rebro, Y.C. Shin, F.P. Incropera, Design of operating conditions for crack free laser-assisted machining of mullite, *International Journal of Machine Tools and Manufacture*, 44(7–8): 677–694, 2004.
11. J. Peng, E. C. Jury, P. Dönnies, C. Ciurtin. Machine learning techniques for personalised medicine approaches in immune-mediated chronic inflammatory diseases: Applications and challenges, *Frontiers in Pharmacology*, 12, 2021.
12. A. Gündüz, Tornalama işleminde oluşan kesme kuvvetlerinin bulanık mantık ve yapay sinir ağlarıyla tahmini, Yüksek Lisans Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, Türkiye, 2006.

13. A. Uğraş, İşlenmesi zor malzemelerin yüksek talaş kaldırma oranlarıyla işlenmesi için ısı destekli hibrid sistemin geliştirilmesi ve çalışma parametrelerinin belirlenmesi, Doktora Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, Türkiye, 2022.