



POLİTEKNİK DERGİSİ

*JOURNAL of POLYTECHNIC*

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



# Yüzey pürüzlülüğünün makine öğrenmesi ile tahmin edilmesi

## *Predicting surface roughness with machine learning*

Yazar(lar) (Author(s)): B. Sercan Bayram<sup>1</sup>, Oktay Yıldız<sup>2</sup> ve İhsan Korkut<sup>3</sup>

ORCID<sup>1</sup>: 0000-0002-9092-6274

ORCID<sup>2</sup>: 0000-0001-9155-7426

ORCID<sup>3</sup>: 0000-0002-5001-4449

**To cite to this article:** Bayram B.S., Yıldız O. ve Korkut V., “Yüzey Pürüzlülüğünün Makine Öğrenmesi ile Tahmin Edilmesi”, *Journal of Polytechnic*, 28(1): 187-195, (2025).

**Bu makaleye şu şekilde atıfta bulunabilirsiniz:** Bayram B.S., Yıldız O. ve Korkut V., Yüzey Pürüzlülüğünün Makine Öğrenmesi ile Tahmin Edilmesi”, *Politeknik Dergisi*, 28(1): 187-195, (2025).

**Erişim linki (To link to this article):** <http://dergipark.org.tr/politeknik/archive>

**DOI:** 10.2339/politeknik.1447279

# Yüzey Pürüzlülüğünün Makine Öğrenmesi ile Tahmin Edilmesi

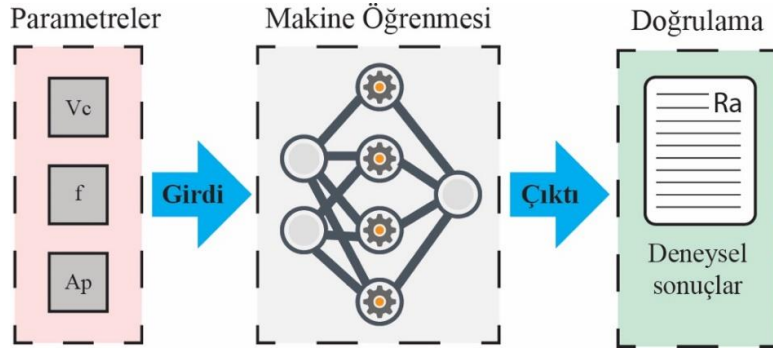
## Predicting Surface Roughness with Machine Learning

### Önemli noktalar (Highlights)

- ❖ Makine öğrenmesi / Machine learning
- ❖ Modelleme / Modelling
- ❖ Yüzey pürüzlülüğü tahmini / Surface roughness

### Grafik Özet (Graphical Abstract)

Tornalanmış parçaların yüzey pürüzlülüklerini tahmin etmek için makine öğrenmesi algoritmaları kullanılarak matematiksel tahmin modeli geliştirilmiştir. / A mathematical prediction model was developed using machine learning algorithms to predict the surface roughness of turned parts.



Şekil. Metodoloji akış diyagramı / Figure. Methodology flow diagram

### Amaç (Aim)

Makine öğrenmesi teknikleri kullanılarak geliştirilen modeller, işleme parametrelerini girdi olarak alır ve çıktı olarak yüzey pürüzlülük değerlerini sağlar. / Models developed using machine learning techniques take the machining parameters as an input and provide surface roughness values as an output.

### Tasarım ve Yöntem (Design & Methodology)

Tahmin modellerinin geliştirilmesinde Yapay Sinir Ağları (YSA) ve Çoklu Lineer Regresyon (ÇLR) yöntemleri kullanılmıştır. Modellerin performansları deneysel ölçümlerle değerlendirilmiştir. / Artificial Neural Networks (ANN) and Multiple Linear Regression (MLR) methods were used to develop prediction models. The performance of the models was evaluated by experimental measurements.

### Özgünlük (Originality)

Yüzey pürüzlülüğünü tahmin etmek için çeşitli makine öğrenme algoritmaları kullanıldı ve performansları karşılaştırıldı. / Several machine learning algorithms were used to predict surface roughness and their performance was compared.

### Bulgular (Findings)

Makine öğrenmesi algoritmaları ile yüzey pürüzlülüğü tahminleri yapılmıştır. Tahminlerin deneysel ölçümlere benzer olduğu görüldü. / Surface roughness predictions were made with machine learning algorithms. The predictions were found to be similar to experimental measurements.

### Sonuç (Conclusion)

Makine öğrenmesinin yüzey pürüzlülüğünü tahmin etmek için kullanılabileceği ve YSA algoritmasının tahmin performansının ÇLR algoritmasından daha iyi olduğu gösterilmiştir. / It has been shown that machine learning can be used to predict surface roughness and that the prediction performance of the ANN algorithm is better than that of the MLR algorithm.

### Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

# Yüzey Pürüzlülüğünün Makine Öğrenmesi ile Tahmin Edilmesi

*Araştırma Makalesi / Research Article*

**B. Sercan BAYRAM<sup>1\*</sup>, Oktay YILDIZ<sup>2</sup>, İhsan KORKUT<sup>1</sup>**

<sup>1</sup>Gazi Üniversitesi, Teknoloji Fakültesi, İmalat Mühendisliği Bölümü, 06500, Yenimahalle/ANKARA

<sup>2</sup>Gazi Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 06570, Maltepe/ANKARA

(Geliş/Received : 05.03.2024 ; Kabul/Accepted : 23.05.2024 ; Erken Görünüm/Early View : 01.07.2024)

## ÖZ

CNC tornalama genellikle metal parçaları işlemek için kullanılır. Son yüzeyin pürüzlülük değerleri, çıktı kalitesinin değerlendirilmesi ve işleme koşullarının belirlenmesi için temel verilerdir. İşleme parametreleri ve yüzey pürüzlülüğü arasındaki karmaşık ilişkilerin araştırılması ve tahmini kesme sürecinin ve çıktı kalitesinin iyileştirilmesi açısından önemlidir. Yapay Sinir Ağı (YSA) modelleri, karmaşık ilişkileri öğrenme ve tahmin etme yetenekleri nedeniyle kesme koşullarının yüzey pürüzlülüğü (Ra) değerleri üzerinde ilişki kurmak için kullanılabilir. Bu çalışmada, tornalama sonrası yüzey pürüzlülüğü değerlerini tahmin etmek için Çoklu Lineer Regresyon (MLR) ve YSA algoritmaları kullanılarak matematiksel tahmin modelleri geliştirilmiştir. Algoritmaların eğitim ve test veri setlerinin oluşturulması amacıyla kuru kesme koşulları altında DIN 1.2344 sıcak iş takım çeliği malzemesi üzerinde tornalama deneyleri yapılmıştır. Kontrol faktörleri ve seviyeleri, kesme hızı (300, 350 ve 400 m/dak), kesme derinliği (0.25, 0.5 ve 0.75 mm) ve ilerleme hızı (0.07, 0.1 ve 0.13 mm/dev) şeklinde belirlenmiştir. İşlenen numunelerin yüzey pürüzlülük değerleri profilometre cihazı ile ölçülmüştür. Tahmin modelleri deneysel ölçümlerle doğrulanmış ve performansları değerlendirilmiştir. YSA tahminlerinin gerçek değerlere göre %87,6 doğruluğa sahip olduğu, MLR tahminlerinin ise %78,4 doğruluğa sahip olduğu hesaplanmıştır. Sonuçlar YSA yönteminin MLR yönteminden daha yüksek bir performansa sahip olduğunu ve yüzey pürüzlülüğü değerlerini tahmin etmek için kullanılabileceğini göstermiştir.

**Anahtar Kelimeler:** Makine öğrenmesi, modelleme, yüzey pürüzlülüğü.

## Predicting Surface Roughness with Machine Learning

### ABSTRACT

CNC turning is commonly used to machine metal parts. The roughness values of the final surface are fundamental data for evaluating the output quality and determining the machining conditions. Investigating and predicting complex relationships between machining parameters and surface roughness is essential for improving the cutting process and output quality. Artificial neural network (ANN) models can be used to correlate cutting conditions with surface roughness (Ra) values due to their ability to learn and predict complex relationships. In this study, mathematical prediction models were developed using Multiple Linear Regression (MLR) and ANN algorithms to predict surface roughness values after turning. Turning experiments were conducted on DIN 1.2344 hot work tool steel material under dry-cutting conditions to generate training and test data sets for the algorithms. The control factors and levels were determined as cutting speed (300, 350, and 400 m/min), depth of cut (0.25, 0.5, and 0.75 mm), and feed rate (0.07, 0.1, and 0.13 mm/rev). Surface roughness values of the machined specimens were measured with a profilometer. The prediction models were validated with experimental measurements, and their performance was evaluated. It was calculated that ANN predictions had an accuracy of 87.6% compared to the actual values, while MLR predictions had an accuracy of 78.4%. The results showed that the ANN method performs more than the MLR method and can be used to predict surface roughness values.

**Keywords:** Machine learning, modelling, surface roughness.

### 1. GİRİŞ (INTRODUCTION)

Talaşlı imalat sürecinin optimize edilmesi ürünün genel maliyetlerine ve kalitesine olan katkısı nedeniyle üzerinde durulması gereken önemli bir konudur. Çıktıların kalitesi için önemli bir değerlendirme kriteri olan yüzey pürüzlülüğü üzerinde kesme parametreleri, kesici takım seçimi, soğutma şekli, tezgah titreşimi ve iş parçası malzemesi gibi faktörlerin önemli etkileri vardır [1]. Tüm faktörlerin doğru şekilde seçimi kalite ve performansı artırır. Özellikle, kontrol edilebilir olan kesme parametrelerinin uygun aralıklarda belirlenmesi performans için bir gerekliliktir. İstenen çıktı kriterlerine göre kesme parametrelerini tahmin eden modellerin geliştirilmesi sürecin optimize edilmesini bakımından

önemlidir [2]. Kesme parametreleri, kesme kuvvetleri, kesici takım geometrisi, iş parçası malzemesi ve kesme sıcaklığı gibi tüm değişkenler birbirleri ile doğrudan ilişkilidir ve çıktılar üzerinde önemli etkileri vardır [3], [4]. Bu yüzden, dinamik faktörlerin birbirleri arasındaki karmaşık ilişkilerin iyi anlaşılması ve modellenmesi, kesme sürecinin iyileştirilmesi açısından gereklidir. YSA gibi akıllı yöntemler kullanılarak karmaşık ilişkiler matematiksel olarak doğrusal fonksiyonlarla ifade edilebilir.

Tornalama, frezeleme ve taşlamada ana kalite parametresi yüzey pürüzlülüğüdür [4-6]. Çok sayıda çalışmada, tornalamada yüzey pürüzlülüğü değerlerinin tahminine odaklanılmıştır. Sadece [8], silindirik yuvarlak

\*Sorumlu Yazar (Corresponding Author)  
e-posta: sercanbayram@gazi.edu.tr

çeliğin işlenmesi sürecinin iyileştirilmesi için YSA tekniğini kullanarak ortalama yüzey pürüzlülük değerleri ve talaş kaldırma oranını tahmin eden modeller geliştirmiştir. Levenberg Marquardt (LM) ve Scaled Conjugate Gradient (SCG) eğitim algoritmaları ile geliştirdiği tahmin modelleri ve algoritmaların performanslarını değerlendirmiştir. Tahmin modelleri için girdi parametreleri kesme hızı, kesme derinliği ve ilerleme hızı, çıktı parametreleri ise talaş kaldırma oranı ve yüzey pürüzlülük değeri şeklinde belirlemiştir. İki farklı algoritma için 10 ila 40 nöron arasında bir aralıkta yaptığı topolojik değişimlerle YSA'nın en iyi performansının 10 nörondan oluşan gizli katmanlı topolojik yapıdaki modeller ile elde etmiştir. Nöron sayısındaki artışın ağırlık karmaşıklığında bir artışa neden olduğunu bildirmiştir. Bununla birlikte, SCG algoritmasının daha yavaş bir yakınsama oranına sahip olduğunu belirtmiş ve sebebinin algoritmanın ağırlıklarının güncelleme yöntemine atfetmiştir. Elde ettiği sonuçlara göre, LM algoritmasının ortalama karekök sapması (RMSE) ve korelasyon ( $R^2$ ) açısından en iyi performansı sunduğunu ifade etmiştir. Suresh ve diğerleri [9], sertleştirilmiş kalıp çeliklerinin tornalanmasında, işleme parametrelerinin takım aşınması üzerindeki etkilerini incelemek için yanıt yüzeyi metodu (RSM) ve YSA tekniğini kullanmışlar. RSM, bağımlı değişken ile bağımsız değişkenler arasında ilişki kurmak ve girdi değişkenlerinin, yanıt değişkenleri üzerindeki etkilerini kontrol eden bir model oluşturmak için kullanılan istatistiksel bir yöntemdir. Dikkate alınan girdi parametreleri, kesme hızı, kesme derinliği, ilerleme hızı ve kesme süresi şeklinde belirtilmiştir. Deneysel tasarım için merkezi kompozit tasarım yöntemi kullanılmış. Tornalama deneylerinde iş parçası, çapı 100 mm ve işleme boyutu 400 mm olacak şekilde 52 HRC sertlikte kalıp çeliği (AISI H3) şeklinde belirlenmiş. Kesici takım olarak CVD kaplamalı karbür, PVD kaplamalı TiN seramik ve kaplamasız seramik ISO CNMG120408 standartlarında takımlar kullanılmış. Her bir takım için kontrol faktörlerinin etkisi varyans analizi (ANOVA) ile gerçekleştirilmiş. ANOVA sonuçlarına göre takım aşınması üzerinde en etkili faktörlerin kesme hızı ve işleme süresinin olduğu belirtilmiş. RSM ve YSA ile yaptıkları tahminler ve deneysel ölçümler, takımın yan yüzeyinde çok fazla aşınma olduğunu göstermiş. Deneysel sonuçlar ile tahmin modeli doğrulanmıştır. Elsheikh ve diğerleri [10], Inconel 718 malzemesinin tornalanmasında oluşan kalıntı gerilmeleri tahmin eden yeni bir model geliştirmişler. Inconel 718 düşük ısı iletimine sahip, işlenmesi oldukça zor bir malzemedir. Kalıntı gerilmeler işlenmiş parçaların yorulma özellikleri etkileyen önemli bir parametredir [11]. Bu yüzden, kalıntı gerilmelerin kontrolü için tahmin modellerinin geliştirilmesi önemlidir. YSA'nın performansı, hiper parametreleri ile doğrudan ilgilidir. Elsheikh ve ark. çalışmalarında hiper parametrelerin iyileştirilmesinde sürü optimizasyonu algoritmalarını kullanarak hibrit bir model sunmuşlar. Optimizasyon için Güvercin Optimizasyonu Algoritması (POA) ve Parçacık Sürüsü

Optimizasyonu (PSO) algoritması kullanılmış. Amaç fonksiyonu olarak tahmin edilen değerler ile gerçek değer arasındaki hata oranları temel alınmıştır. YSA-POA, YSA-PSO ve YSA teknikleri ile kalıntı gerilmelerin tahmin performanslarını değerlendirmek için korelasyon katsayısı ve ortalama karekök hataları metriklerini kullanmışlar. Modellerin tahmin performansında korelasyon skoru sırasıyla %99.1, %93.8 ve %58.5 iken ortalama karekök hataları sırasıyla 11.870, 31.487 ve 119.437 olduğu bildirilmiş ve tahminlerin doğruluğunu artırmak için POA algoritmasının kullanımı önerilmiştir. Dubey ve ark. [12], çalışmalarında AISI 304 çeliğinin en az miktarda yağlama (MQL) ile işlenmesi sırasında, kesme sıvısındaki nanopartikül boyutlarına göre oluşan yüzey pürüzlülüklerinin tahmini için makine öğrenmesi algoritmalarını kullanmışlar. Lineer regresyon, rastgele orman ve destek vektör makineleri olmak üzere üç farklı makine öğrenmesi algoritmaları ile yaptıkları tahminlerin performanslarını deneysel ölçümlerle değerlendirmişler. Sundukları çalışmada, deney tasarımı RSM yöntemi ile yapılmış. Kesme sıvısı için parçacık boyutları 30 nm ve 40 nm olan su bazlı alümina ile zenginleştirilmiş soğutucu kullanılmış. Deneysel ölçümlere göre, 40 nm parçacık boyutlu soğutucu ile 30 nm parçacık boyuna sahip soğutucuya göre daha düşük yüzey pürüzlülüğü değerleri elde edilmiş. Kullandıkları üç farklı makine öğrenmesi algoritması arasında, her iki parçacık boyutu için en iyi performansı rastgele orman algoritmasının verdiği görülmüş. Dilipak ve ark. [13], YSA tekniklerini kullanarak frezeleme sonrası elde edilen yüzey pürüzlülüğü değerlerinin tahminine yönelik matematiksel modeller oluşturmuşlardır. Çalışmada, 1.2738 kalıp çeliğinin işlenmesinde MQL tekniğinin yüzey pürüzlülüğü üzerindeki etkilerini, adaptif ağ tabanlı bulanık mantık çıkarım sistemi (ANFIS) ve regresyon yaklaşımı ile modellemişlerdir. Modellerin performans sonuçları ANFIS yöntemi için %100 doğrulukta oranında sağlanırken, regresyon modeli %71 doğruluk oranında performans göstermiştir. Gürbüz ve ark. [14], AISI 4140 çeliğinin tornalanmasında, kesme hızı, ilerleme oranı ve MQL yönteminin, esas kesme kuvveti ve ortalama yüzey pürüzlülüğü üzerindeki etkilerini Taguchi sinyal/gürültü (S/N) oranları ve YSA teknikleri ile değerlendirmişlerdir. Taguchi S/N oranı ve YSA yönteminin esas kesme kuvveti ve Ra değerlerini tahmin etmede başarılı olduğunu deneysel olarak göstermişlerdir. Seguy ve diğerleri [15], yaptıkları çalışmada otlama kararsızlığı ile yüzey pürüzlülüğü arasındaki etkileşimi incelemişler. Otlama, işleme sırasında ortaya çıkan titreşimlerin neden olduğu istenmeyen bir kararsızlık durumudur. Yüzey kalitesi, takım aşınması ve tezgah bileşenleri üzerinde olumsuz etkiler neden olur. Seguy ve ark., frezeleme işleminde, otlamanın yüzey pürüzlülüğü üzerindeki etkilerini baskılamak için doğrusal kararlılık loblarını kullanmışlar. Analitik olarak elde edilen kararlılık loblarının ince duvarlı parçaların yüzey pürüzlülüğünün iyileştirilmesine katkı sağladığı tespit edilmiş. Risbood ve ark. [16], tornalamada takım tutucunun radyal

titreşiminin ivme değerinin geri bildirim olarak alınması ile yüzey kalitesinin YSA kullanılarak tahmin edilebileceğini göstermişler. Özel ve Karpaz [17], ısıtılmış işlem uygulanmış AISI 52100 çeliğinin tornalanması sırasında çeşitli koşullar için yüzey pürüzlülüğü değerini ve takım yan aşınmasını tahmin etmek için YSA tekniğini kullanmışlar. Lakhdar ve ark. [18], sertleştirilmiş AISI D3 çeliğinin işlenmesinde seramik ve kaplamalı seramik uçlar kullanılarak gerçekleştirilen finiş işleminde yüzey pürüzlülüğü ve kesme kuvvetlerini incelemişler. Kesme kuvvetleri ve yüzey pürüzlülüğünün modellenmesinde hem RSM hem de YSA kullanmışlar. Muthuram ve Frank [19], Titanyum alaşımının tornalanmasında işleme parametrelerinin optimize edilmesi için YSA tekniğini kullanmışlar. Bu sayede, malzeme kaldırma oranını maksimuma çıkartırken yüzey pürüzlülüğü değerlerini en aza indiren en iyi parametreleri elde etmişler. Gürbüz ve ark. [20], kesici uçlar için farklı talaş kırıcı formlarının yüzey pürüzlülüğü üzerindeki etkilerini YSA yöntemini kullanarak modellemişler ve tahmin değerlerini deneysel olarak doğrulamışlar. Elde edilen sonuçların, kabul edilebilir bir aralıkta başarı sağladığını bildirmişler. Senthilkumar ve ark. [21], çok katmanlı, kaplamalı karbür kesici uçların performanslarını tahmin etmek için farklı işleme koşulları altında deneysel ölçümler yapmışlar. Elde ettikleri sonuçlar ile Taguchi-Grey ilişkisel analiz yöntemini kullanarak matematiksel tahmin modelleri geliştirmişler. Chandrasekar ve ark. [22] Al-SiC Metal matrisli kompozitlerin tornalaması sonrasında yüzey pürüzlülüğü değerlerinin tahmin edilmesi için YSA tekniğini kullanmışlar. Sundukları yöntemde PSO algoritması YSA modeline entegre edilerek tahmin performansını artırmışlar. Geliştirdikleri yöntemi farklı işleme parametrelerinde deneysel olarak doğrulamışlar. Abbas ve ark. [23], Magnezyum alaşımlarının tornalanmasında elde edilen yüzey pürüzlülüğü ve işleme sürelerinin tahmininde YSA için yeni bir optimizasyon metodu ortaya koymuşlar. Edgeworth-Pareto optimizasyonu olarak isimlendirilen

Makine öğrenmesi teknikleri, birçok faktörün birbiri arasında doğrusal ilişki kurmak için oldukça kullanışlıdır. Ancak kullanılan yöntemin probleme uygun seçilmesi, modellemenin başarısı için önemlidir. Bu çalışmada, işleme parametrelerini girdi olarak alan ve çıktı olarak yüzey pürüzlülüğü değerlerini veren matematiksel tahmin modelleri iki farklı makine öğrenmesi algoritması YSA ve MLR kullanılarak geliştirilmiştir. Geliştirilen modeller aynı veri seti ile eğitilmiş ve performansları aynı test veri seti ile değerlendirilmiştir. YSA yönteminin MLR yöntemine göre yüzey pürüzlülüğü değerlerini daha iyi tahmin ettiği görülmüştür. Sunulan yöntemlerin, endüstriyel çalışmalarda yüzey pürüzlülüğü açısından işleme parametrelerinin belirlenmesinde kullanılabileceği gösterilmiştir.

## 2. MATERYAL VE METOD (MATERIAL AND METHOD)

### 2.1. Deneysel Tasarım (Experimental Design)

YSA ve MLR yöntemlerinin eğitiminde kullanılmak üzere bir dizi deney gerçekleştirilmiştir. Kontrol faktörleri, üç seviyeli kesme hızı (Faktör A), üç seviyeli ilerleme hızı (Faktör B) ve üç seviyeli kesme derinliği (Faktör C) şeklinde tanımlanmış ve Çizelge 1'de verilmiştir. Kontrol faktörlerinin tüm seviyeleri, kesici takım üreticisi kataloğunda tavsiye edilen kesme parametreleri değer aralıkları dikkate alınarak belirlenmiştir. Kontrol faktörlerinin birbirleri ile olan ilişkilerini değerlendirebilmek için, tam faktöriyel deney tasarımı yöntemi tercih edilmiştir. Tam faktöriyel deney tasarımı, bir deneyin tüm faktör seviyelerinin kombinasyonlarını içeren bir deney tasarımı yöntemidir. Deney tasarımının temel amacı, her bir faktörün seviyesini diğer tüm faktörlerin seviyeleri ile sistematik bütünlük içerisinde birleştirerek, faktörlerin etkileşimlerini ve etkilerini kontrollü değişkenler ile neden-sonuç ilişkisi kurularak analiz edilmesini

**Çizelge 1.** Test faktörleri ve seviyeleri (Test factors and levels)

Parametreler	Sembol	Seviye 1	Seviye 2	Seviye 3
Kesme hızı, $V_c$ (m/dak)	A	300	350	400
Kesme derinliği, $z$ (mm)	B	0,25	0,5	0,75
İlerleme hızı, $f$ (mm/dev)	C	0,07	0,1	0,13

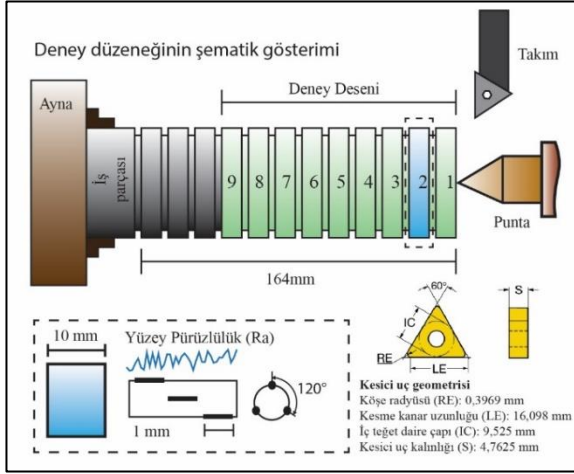
**Çizelge 2.** DIN 1.2344 Sıcak iş takım çeliği malzemesinin kimyasal bileşimi (DIN 1.2344 Chemical composition of hot work tool steel material)

C	Si	Mn	P	S	Cr	Mo	V	Sertlik
0,35-0,42	0,8-1,2	0,25-0,5	< 0,03	< 0,02	4,8-5,5	1,2-1,5	0,85-1,15	210 HB

metot, üç boyutlu bir işleme probleminde maliyetlerin minimize edilmesi için kullanılmış. Hoang ve ark. [24], frezeleme metodu ile işlenen ürün kalitesini tolerans aralıklarında tutmak için takım aşınmasını dikkate alan, gerçek zamanlı kendi kendini ayarlayabilen bir kontrol sistemi geliştirmişler. Bunun için ANOVA ve YSA tekniklerinden faydalanmışlar.

sağlamaktır. Bu çalışma için yapılan deneylerde iş parçası olarak DIN 1.2344 (X40CrMoV5-1) sıcak iş takım çeliği kullanılmıştır. İş parçasının kimyasal bileşimi ve mekanik özellikleri Çizelge 2'de sunulmuştur. Kesici takım için, ISO'ya göre TNMG 160404 geometrisine (Şekil 2 – Kesici uç geometrisi) sahip TiCN+Al<sub>2</sub>O<sub>3</sub>+TiN kaplamalı sementit karbür

takımlar tercih edilmiştir. Yüzey pürüzlülük değerlerinin ölçümleri Mitutoyo SJ-410 marka ve model profilometre cihazı ile üç tekrarlı olarak yapılmıştır. Deney düzeneğinin şematik gösterimi Şekil 1’de verilmiştir.



Şekil 2. Deney düzeneği (Experimental setup)

İş parçası numunesinin kesme deneylerinden önce boyuna işlenerek yüzeyi temizlenmiştir. Bu sayede, ham parçanın düzensiz yüzeyinin neden olduğu değişkenliklerin ölçüm sonuçlarına etkileri en aza indirilmiştir. Aynı şekilde takım aşınmasının yüzey pürüzlülüğü üzerindeki etkilerini sabit tutmak adına, kesme deneylerinde kontrol faktörlerinin her biri için ayrı kesici kenarlar kullanılmıştır.

Kuru kesme şartları altında yapılan tornalama işlemi sonrası, iş parçası yüzeyinin üç bölgesinden yüzey pürüzlülük ( $\mu\text{m}$ ) değerleri ölçülmüştür. Her faktör ve seviyesi için alınan üç tekrarlı ölçümlerin ortalaması hesaplanarak Çizelge 3’te verilmiştir.

## 2.2 Çoklu Lineer Regresyon (Multiple Linear Regression)

Bağımsız değişken sayısına göre lineer regresyon çeşidi basit lineer veya çoklu lineer regresyon şeklinde sınıflandırılabilir. Basit regresyon çeşidinde bağımlı değişken tek bir bağımsız değişken ile aşağıdaki gibi açıklanabilir:

$$y = \beta_0 + \beta_1 x + e \quad (1)$$

Eş. 1’de verilen ifadeye  $\beta_0$  ve  $\beta_1$  regresyon katsayılarını,  $e$  katsayısı ise hata oranını ifade ederler. Regresyon katsayıları bağımlı ve bağımsız değişken arasındaki doğrusal ilişkiyi ifade eden matematiksel katsayılardır.

Çoklu lineer regresyonda ise, bağımlı değişken ile bağımsız değişken arasındaki ilişkileri açıklayan katsayıların, birden fazla ve birbirinden bağımsız olmaları gerekir. Buna göre MLR’de bağımlı değişken ile bağımsız değişken arasındaki doğrusal ilişki Eş. 2’de verildiği gibi ifade edilebilir [25]:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n + e \quad (2)$$

MLR, ekonomi, finans, biyoistatistik, mühendislik ve sosyal bilimler gibi birçok alanda veri setindeki örneklemeler arasında ilişkiler kurmak ve tahminler yürütmek için sıklıkla kullanılmaktadır.

## 2.3 Yapay Sinir Ağları (Artificial Neural Networks)

Yapay Sinir Ağları (YSA), biyolojik sinir sistemlerini taklit ederek oluşturulan algoritmalar ve matematiksel modellerdir. Sinir hücreleri (nöronlar) ve nöronlar arasındaki bağlantıları temsil eden katmanlar, temel bileşenlerini oluşturur. Bu katmanlar; giriş, gizli ve çıkış şeklinde adlandırılırlar. Giriş katmanı, sistemdeki verileri alır ve nöronlara iletir. Gizli katmanlar, bu giriş verilerini işleyen ve öğrenen katmanlardır. Her gizli katmandaki nöronlar, belirli özellikleri tanıma veya öğrenme görevini üstlenir. Çıkış katmanı, sonuçları üretir. YSA’lar, örüntü

Çizelge 3. Tam faktöriyel deney tasarımı ve yüzey pürüzlülük değerleri (Full factorial design of experiments and values for surface roughness)

Deney	Faktör A	Faktör B	Faktör C	Ra
1	1	1	1	0,234
2	1	1	2	0,675
3	1	1	3	0,830
4	1	2	1	0,269
5	1	2	2	0,518
6	1	2	3	0,105
7	1	3	1	0,385
8	1	3	2	0,607
9	1	3	3	1,078
10	2	1	1	0,387
11	2	1	2	0,639
12	2	1	3	1,161
13	2	2	1	0,345
14	2	2	2	0,608
15	2	2	3	0,541
16	2	3	1	0,378
17	2	3	2	0,826
18	2	3	3	1,421
19	3	1	1	0,322
20	3	1	2	0,717
21	3	1	3	1,103
22	3	2	1	0,360
23	3	2	2	0,554
24	3	2	3	0,516
25	3	3	1	0,439
26	3	3	2	0,717
27	3	3	3	1,066

Faktör A: Kesme hızı (m/dak), Faktör B: Kesme derinliği (mm), Faktör C: İlerleme hızı (mm/dev), Ra: Yüzey pürüzlülüğü ( $\mu\text{m}$ )

tanıma, genelleme ve öğrenme yetenekleri ile benzer olmayan veriler üzerinde doğru tahminlerde bulunabilirler. Çünkü eğitildikleri veri setleri arasındaki karmaşık ilişkileri öğrenme yolu ile kurabilirler.

Özellikle derin öğrenme olarak bilinen derin sinir ağı yapıları çok katmanlı ve karmaşık öğrenme süreçleri ile büyük veri setlerinde başarılı sonuçlar elde edebilir [26]. Yapay Sinir Ağları görüntü işleme, doğal dil işleme, otomatik sürüş sistemleri, tıp, finans ve endüstriyel otomasyon dahil olmak üzere çok çeşitli alanlarda başarıyla kullanılmaktadır. Örneğin, görüntü tanıma sistemleri nesnelere tanıyabilir ve sınıflandırabilir. Doğal dil işleme alanında ise duygu analizi, konuşma tanıma ve metin çevirisi gibi görevleri yerine getirebilir. Nöronlar, yapay sinir ağının en temel yapı taşlarıdır. Her nöron, giriş değerlerini alır, ağırlıklarla çarpar, bir aktivasyon fonksiyonundan geçirir ve çıkış değerini üretir. Üretilen değer, bir sonraki katmanda yer alan nörona veya çıkış katmanına iletilir. Ağırlıklar, sinir ağının öğrenme yeteneğini temsil eder. Başlangıçta rastgele atanırlar ve eğitim süreci boyunca optimize edilirler. Eğitim, sinir ağının öğrenme sürecidir ve giriş katmanından alınan veriler kullanılarak gerçekleşir. YSA, eğitim süreci sonucunda genelleme veya tahmin yürütebilme yeteneği kazanabilir. Sonuç olarak YSA, öğrenme yetenekleri ile karmaşık problemlerin çözümü için etkili bir hesaplama yöntemi sunabilir.

Bu çalışmada, çok katmanlı algılayıcı (MLP), ileri beslemeli yapay sinir ağı modeli kullanılmıştır. Bir MLP giriş, gizli ve çıkış katmanı olmak üzere en az üç katmandan oluşur. Giriş dışındaki her düğüm noktası, doğrusal olmayan bir aktivasyon fonksiyonu kullanan bir nörondur. MLP, eğitim için geri yayılım şeklinde isimlendirilen bir öğrenme tekniği kullanır [27]. Geliştirilen YSA modelinin yapısı Şekil 2'de verilmiş olup, üç girişe sahip bir giriş katmanı, bir çıkış katmanı ve sırasıyla 9-7-5 nöron sayılarından oluşan üç gizli katman olmak üzere toplam beş katmandan oluşmaktadır. Aktivasyon fonksiyonu olarak Identity, optimizasyonu için Adaptif Momentum (ADAM) ve öğrenme oranı 0,001 şeklinde belirlenmiştir. Nöronları matematiksel olarak ifade etmek istersek aşağıda verilen eşitliği kullanabiliriz:

$$a = \varphi(\sum_j \omega_j x_j + b_0) \quad (3)$$

Burada  $\omega_j$  nöron için ağırlık değeri,  $x_j$  girdiler ve  $b_0$  bias değeridir. Denklemde verilen  $\varphi$  aktivasyon fonksiyonudur.

Çok katmanlı yapıya sahip YSA'da tüm nöronlar birbiri ile bağlantılı olduğundan, her bir nöron bir önceki katmandaki tüm nöronlardan girdi değerlerini alır. Yapıda her katmandaki birimlerin kendi ağırlıkları vardır. Çok katmanlı ağa sahip yapının hesaplamaları aşağıdaki gibi verilebilir:


$$h_i^1 = \varphi_1(\sum_j \omega_{ij}^1 x_j + b_i^1) \quad (4)$$

$$h_i^2 = \varphi_2(\sum_j \omega_{ij}^2 h_j^1 + b_i^2) \quad (5)$$

$$h_i^3 = \varphi_3(\sum_j \omega_{ij}^3 h_j^2 + b_i^3) \quad (6)$$

$$y_i = \varphi_4(\sum_j \omega_{ij}^4 h_j^3 + b_i^4) \quad (7)$$

Burada, farklı katmanlarda farklı aktivasyon fonksiyonları kullanılabilirdiğinden  $\varphi_i$  birbirlerinden farklı olarak tanımlanmıştır.



Şekil 2. Yapay sinir ağı diyagramı (Artificial neural network diagram)

### 3. SONUÇLAR VE TARTIŞMA (RESULTS AND DISCUSSION)

Kesme parametreleri işlenmiş parçanın yüzey pürüzlülüğünü etkileyen önemli faktörlerdir. Kontrol edilebilir kesme parametrelerinden birisi olan kesme hızı, yüksek oranlarda genellikle daha düşük yüzey pürüzlülüğü değerlerine neden olur. Diğer taraftan, aşırı yüksek kesme hızlarında oluşan ısı termal deformasyonlara, yetersiz takım ömrüne ve pürüzlülük değerlerinin artmasına neden olabilir. Bir diğer önemli parametre ilerleme oranıdır. Düşük ilerleme oranları yüzey pürüzlülüğü değerlerini azaltırken, yüksek ilerleme oranları sıcaklık ve basınç artışına, dolayısıyla takım ömrünün azalmasına ve yüzey pürüzlülüğü değerlerinin artmasına neden olabilir. Yüzey pürüzlülük değerlerini etkileyen üçüncü bir parametre ise kesme derinliğidir. Kesme derinliği kesme kuvvetleri, talaş biçimi ve ısı oluşumuna etkisi ile yüzey pürüzlülük değerini etkileyen bir faktördür. Sonuç olarak, kararlı bir kesme işlemi için kesme parametrelerinin optimal düzeyde seçilmesi kalite, takım ömrü ve maliyetler bakımından önemlidir.

Yapılan çalışmada, kesme parametrelerine göre yüzey pürüzlülüğü değerlerini tahmin eden modeller MLR ve YSA yöntemi ile geliştirilmiştir. Geliştirilen modellerin eğitiminde Çizelge 3'de sunulan deneysel veriler kullanılmıştır. Eğitim sonucunda hesaplanan katsayılar aşağıda verilmiştir. MLR ile geliştirilen model için katsayılar Eş. 8'de, YSA ile geliştirilen model için hesaplanan ağırlık ve bias değerleri Çizelge 4 ve Çizelge 5'te sunulmuştur.

Çoklu lineer regresyon, A, B ve C faktörü arasında doğrusal bir ilişki kurmuş ve bu ilişkiyi matematiksel olarak aşağıda verildiği gibi modellemiştir. Katsayılar incelendiğinde, yüzey pürüzlülüğü üzerindeki en etkili parametrenin C faktörü olduğu anlaşılmaktadır.

$$y = 1,214x10^{-3}A + 1,887x10^{-1}B + 8,707C \quad (8)$$

**Çizelge 4.** YSA için hesaplanan ağırlık katsayıları (Weight coefficients calculated for ANN)

Girdi	$\omega_1$	$\omega_2$	$\omega_3$	$\omega_4$	$\omega_5$	$\omega_6$	$\omega_7$	$\omega_8$	$\omega_9$
X <sub>1</sub>	-0,145	0,665	0,293	0,171	-0,461	-0,45	-0,649	0,489	0,183
X <sub>2</sub>	0,238	-0,764	0,668	0,404	-0,503	0,44	-0,341	-0,193	0,064
X <sub>3</sub>	-0,047	-0,217	0,149	-0,451	-0,205	-0,191	-0,164	0,328	-0,444
X <sub>4</sub>	-0,185	-0,568	0,233	-0,015	-0,406	-0,072	-0,52		
X <sub>5</sub>	0,417	-0,194	0,154	-0,319	-0,063	0,152	-0,465		
X <sub>6</sub>	0,528	0,398	0,546	0,433	0,071	0,572	-0,549		
X <sub>7</sub>	-0,31	-0,642	-0,195	-0,07	-0,215	0,327	-0,118		
X <sub>8</sub>	-0,333	0,137	-0,46	0,301	-0,588	0,673	0,274		
X <sub>9</sub>	-0,43	-0,525	0,372	0,188	0,217	0,405	-0,579		
X <sub>10</sub>	-0,121	-0,539	0,444	0,207	-0,153	-0,596	-0,182		
X <sub>11</sub>	-0,157	0,207	0,175	0,535	0,025	-0,533	0,315		
X <sub>12</sub>	0,377	-0,003	0,343	0,054	0,088	-0,159	-0,527		
X <sub>13</sub>	-0,175	0,411	-0,338	-0,551	-0,343				
X <sub>14</sub>	-0,544	0,681	0,496	0,251	0,465				
X <sub>15</sub>	0,497	-0,525	0,493	-0,009	0,496				
X <sub>16</sub>	0,504	-0,192	-0,499	-0,331	-0,155				
X <sub>17</sub>	0,414	0,531	-0,663	0,05	-0,151				
X <sub>18</sub>	-0,462	-0,464	-0,165	0,693	-0,314				
X <sub>19</sub>	-0,03	0,363	-0,141	0,721	0,603				
X <sub>20</sub>	0,307								
X <sub>21</sub>	-0,047								
X <sub>22</sub>	-0,874								
X <sub>23</sub>	-0,518								
X <sub>24</sub>	0,759								

**Çizelge 5.** YSA için bias değerleri (Bias values for ANN)

Katman	b <sub>1</sub>	b <sub>2</sub>	b <sub>3</sub>	b <sub>4</sub>	b <sub>5</sub>	b <sub>6</sub>	b <sub>7</sub>	b <sub>8</sub>	b <sub>9</sub>
L <sub>1</sub>	-0,025	0,066	-0,623	0,101	-0,541	-0,626	0,722	0,722	0,438
L <sub>3</sub>	-0,425	-0,647	0,173	-0,168	0,068	0,433	-0,255		
L <sub>4</sub>	-0,287	-0,075	-0,341	-0,366	-0,596				
L <sub>5</sub>	-0,461								

**3.1. Modelin Test Edilmesi** (Testing of The Model)

Makine öğrenmesi algoritmaları eğitim ve test olmak üzere iki temel aşamadan oluşur. Eğitim aşaması sonuçları bilinen bir dizi eğitim veri seti ile gerçekleştirilir. Modelin performansını değerlendirmek için eğitim verileri dışında, bir dizi test verisi kullanılır. Bu aşamada geliştirilen model ile test verileri için tahminler yapılır, tahmin değerleri test verilerindeki sonuçlar ile karşılaştırılarak modelin performansı

değerlendirilir. Bu çalışma için Şekil 2'de yapısal diyagramı verilen YSA ve MLR, Çizelge 3'te sunulan veri seti ile eğitilmiştir. Eğitilen modeller için hesaplanan katsayılar daha önceden Çizelge 4 ve Çizelge 5'te paylaşılmıştı. Bu katsayılar kullanılarak geliştirilen matematiksel tahmin modellerini doğrulamak ve performanslarını değerlendirmek için Çizelge 6'da paylaşılan test veri seti kullanılmıştır. Yapılan



**Çizelge 6.** Test veri seti ve tahmin edilen Ra (µm) değerleri (Test dataset and predicted Ra (µm) values)

Deney	A	B	C	Ra (Ölçülen)	Ra (MLR)	Ra (YSA)
1	300	0,25	0,07	0,242	0,253	0,240
2	300	0,75	0,09	0,492	0,522	0,467
3	300	0,25	0,09	0,652	0,427	0,456
4	350	0,25	0,09	0,532	0,488	0,503
5	350	0,25	0,11	0,659	0,662	0,719
6	350	0,25	0,13	0,989	0,836	0,936
7	350	0,5	0,09	0,543	0,535	0,508
8	350	0,5	0,11	0,796	0,709	0,724
9	350	0,5	0,13	1.040	0,883	0,941

tahminlerin gerçek değerlere göre performansları Çizelge 6'da ilgili algoritmalar için sunulmuştur.

$$MSE = \frac{\sum_{m=1}^n (y_{tahmin,m} - y_{ölçülen,m})^2}{n} \quad (9)$$

$$RMSE = \sqrt{\frac{\sum_{m=1}^n (y_{tahmin,m} - y_{ölçülen,m})^2}{n}} \quad (10)$$

$$MAPE = \frac{1}{n} \sum_{m=1}^n \left[ \frac{|y_{ölçülen,m} - y_{tahmin,m}|}{y_{ölçülen,m}} \right] \times 100 \quad (11)$$


$$R^2 = 1 - \frac{\sum_{m=1}^n (y_{tahmin,m} - y_{ölçülen,m})^2}{\sum_{m=1}^n (y_{ölçülen,m})^2} \quad (12)$$

Burada n veri sayısını, m değeri ilgili veri setindeki ölçülen ve tahmin edilen değer için veri indisini gösterir. MLR ve YSA modellerinin tahmin performansları, Ortalama Kare Hatası (MSE) Eş. 9, Kök Ortalama Kare Hatası (RMSE) Eş. 10, Ortalama Mutlak Yüzde Hatası (MAPE) Eş. 11 ve Belirleme katsayısı (R2) Eş. 12 metrikleri ile değerlendirilmiştir. Gerçekleştirilen tahminlerin performansları Çizelge 7'de verildiği gibidir.


**Çizelge 7.** Tahmin edilen değerler ile ölçülen değerlerin performansları (Performance of predicted values and measured values)

Metot	MSE	RMSE	MAPE	R <sup>2</sup>
MLR	0,012	0,110	0,796	0,784
YSA	0,007	0,083	0,090	0,876

Elde edilen sonuçlara göre YSA modeli MLR yöntemine göre %11,7 daha iyi performans göstermiştir. Ölçüm sonuçları ile tahmin edilen değerlerinin karşılaştırılmasının histogram grafiği Şekil 3'te verilmiştir.

**Şekil 3.** Ölçüm ve tahmin değerlerinin karşılaştırılması (Comparison of measured and predicted values)

YSA yönteminin problemin çözüm performansını değerlendirmek için kayıp fonksiyonunun eğrisi Şekil 4'te paylaşılmıştır.

**Şekil 4.** Model yakınsama grafiği (Model convergence graph)

#### 4. SONUÇ (CONCLUSION)

Bu çalışmada, verilen kesme parametrelerine göre tormalanmış parçaların yüzey pürüzlülük değerlerini önceden etmek için matematiksel modeller geliştirilmiştir. Tahmin modellerinin geliştirilmesinde iki farklı makine öğrenme algoritması MLR ve YSA tercih edilmiştir. Geliştirme ortamı olarak genel programlama dili Python kullanılmıştır. Tahmin modelleri girdi olarak üç seviyeli kesme hızı (m/dak), ilerleme oranı (mm/dev) ve kesme derinliği (mm) parametrelerini almakta ve çıktı olarak yüzey pürüzlülük değeri Ra (µm)'yı vermektedir. Deneysel ölçüm verileri kullanılarak makine öğrenmesi algoritmaları eğitilmiş ve test veri seti ile modeller doğrulanmıştır.

Yapılan çalışmada elde edilen sonuçlar aşağıda özetlenmiştir.

- YSA ve MLR modellerinin test verileri için tahmin performansları korelasyon katsayısına göre sırasıyla, %87,6 ve %78,4 bulunmuştur.
- YSA Yöntemi tahmin performansı MLR yöntemine göre %11,7 daha iyi olduğu görülmüştür.
- YSA için verilen kayıp fonksiyon grafiği incelendiğinde, YSA çözüme yaklaşık 100 iterasyon gibi bir değerle oldukça hızlı yakınsamıştır.

- En düşük ortalama yüzey pürüzlülüğü değerleri A1B2C3 seviyesinde 0,105 Ra ( $\mu\text{m}$ ) olarak elde edilmiştir.
- Yüzey pürüzlülük değeri üzerinde en etkili parametrenin C faktörü olduğu görülmektedir.
- Kesme parametrelerinin girdi olarak kullanıldığı YSA modeli ile yüzey pürüzlülük değerlerinin yüksek doğruluk oranında tahmin edilebileceği kanıtlanmıştır.

Sunulan yöntemin işleme performansının iyileştirilmesi, kesme parametrelerinin optimizasyonu, takım aşınması ve yüzey pürüzlülüğü değerlerinin iyileştirilmesi gibi alanlarda kullanılması tavsiye edilir.

#### TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma Gazi Üniversitesi Bilimsel Araştırma Projeleri tarafından desteklenmiştir (Proje no: BAP-FGA-2023-8750).

#### ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

#### YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

**B. Sercan BAYRAM:** Verilerin toplanması, modellerin geliştirilmesi ve makale yazım işlemlerinin gerçekleştirilmesi.

**Oktay YILDIZ:** Modellerin geliştirilmesi, sonuçların analizi ve yorumu.

**İhsan KORKUT:** Makalenin genel yazım düzeni ve sonuçların kontrol edilmesi

#### ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

#### KAYNAKLAR (REFERENCES)

- [1] Lakshmanan S., Kumar M. P., and Dhananchezian M., "Optimization of turning parameter on surface roughness, cutting force and temperature through TOPSIS" *Materials Today: Proceedings*, 72(4): 2231-2237, (2023).
- [2] Merchant M. E., "An interpretive look at 20th century research on modeling of machining", *Machining Science and Technology*, 2(2), 157-163, (1998).
- [3] Madić M. and Radovanović M., "Modeling and analysis of correlations between cutting parameters and cutting force components in turning AISI 1043 steel using ANN", *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 35: 111-121, (2013).
- [4] Çakıroğlu R., Yağmur S., Acır A., and Şeker U., "Delme İşlemlerinde Meydana Gelen Kesme Bölgesi Sıcaklığının ve Kesme Kuvvetlerinin Yapay Sinir Ağları Kullanılarak Modellenmesi," *Politeknik Dergisi*, 20(2): 333-340, (2017).
- [5] Cao Y., Zhu Y., Ding W., Qiu Y., Wang L., and XU J., "Vibration coupling effects and machining behavior of ultrasonic vibration plate device for creep-feed grinding of Inconel 718 nickel-based superalloy," *Chinese Journal of Aeronautics*, 35(2): 332-345, (2022).
- [6] Miao Q., Ding W., Kuang W., and Yang C., "Grinding force and surface quality in creep feed profile grinding of turbine blade root of nickel-based superalloy with microcrystalline alumina abrasive wheels", *Chinese Journal of Aeronautics*, 34(2): 576-585, (2021).
- [7] Bennett J. M., "Recent developments in surface roughness characterization", *Meas Sci Technol*, 3(12): 1119, (1992).
- [8] Sada S. O., "Improving the predictive accuracy of artificial neural network (ANN) approach in a mild steel turning operation", *The International Journal of Advanced Manufacturing Technology*, 112: 2389-2398, (2021).
- [9] Suresh R., Joshi A. G., and Manjaiah M., "Experimental investigation on tool wear in AISI H13 die steel turning using RSM and ANN methods", *Arabian Journal Science Engineering*, 46(3): 2311-2325, (2021).
- [10] Elsheikh A. H. *et al.*, "Fine-tuned artificial intelligence model using pigeon optimizer for prediction of residual stresses during turning of Inconel 718", *Journal of Materials Research and Technology*, 15: 3622-3634, (2021).
- [11] Moussaoui K., Mousseigne M., Senatore J., and Chieragatti R., "The effect of roughness and residual stresses on fatigue life time of an alloy of titanium", *The International Journal of Advanced Manufacturing Technology*, 78: 557-563, (2015).
- [12] Dubey V., Sharma A. K., and Pimenov D. Y., "Prediction of surface roughness using machine learning approach in MQL turning of AISI 304 steel by varying nanoparticle size in the cutting fluid", *Lubricants*, 10(5): 81, (2022).
- [13] Dilipak H., Asal Ö., Yalçınkaya A., and Ünal Ş., "Minimum Miktarla Yağlama Tekniği ile Frezeleme İşleminde Yüzey Pürüzlülüğünün Anfis ile Modellenmesi," *International Journal of Innovative Engineering Applications*, 5(2): 162-170, (2021).
- [14] Gürbüz H. and E. Y. Gönülaçar, "Farklı kesme parametreleri ve MQL debileri elde edilen deneysel değerlerin S/N oranları ve YSA ile analizi," *Politeknik Dergisi*, 24(3): 1093-1107, (2021).
- [15] Seguy S., Dessein G., and Arnaud L., "Surface roughness variation of thin wall milling, related to modal interactions", *International Journal of Machine Tools and Manufacture*, 48(3): 261-274, (2008).
- [16] Risbood K. A., Dixit U. S., and Sahasrabudhe A. D., "Prediction of surface roughness and dimensional deviation by measuring cutting forces and vibrations in turning process", *Journal of Materials Processing Technology*, 132(1-3): 203-214, (2003).
- [17] Özel T. and Karpat Y., "Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks", *International Journal of Machine Tools and Manufacture*, 45(4): 467-479, (2005).
- [18] Lakhdar B., Athmane Y. M., Salim B., and Haddad A., "Modelling and optimization of machining parameters during hardened steel AISI D3 turning using RSM, ANN and DFA techniques: comparative study", *Journal of Mechanical Engineering and Sciences*, 14(2): 6835-6847, (2020).

- [19] Muthuram N. and Frank F. C., “Optimization of machining parameters using artificial Intelligence techniques”, *Materials Today Proceedings*, 46: 8097–8102, (2021).
- [20] Gürbüz H., Sözen A., and Şeker U., “Tornalama Operasyonlarında Farklı Talaş Kırıcı Formlarının Yüzey Pürüzlülüğü Üzerinde Etkilerinin Yapay Sinir Ağları Kullanılarak Modellenmesi,” *Politeknik Dergisi*, 19(1): 71–83, (2016).
- [21] Senthilkumar N., Tamizharasan T., and Anandkrishnan V., “An hybrid Taguchi-grey relational technique and cuckoo search algorithm for multi-criteria optimization in hard turning of AISI D3 steel”, *Journal of Advanced Engineering Research*, 1(1): 16–31, (2014).
- [22] Chandrasekaran M. and Tamang S., “ANN-PSO integrated optimization methodology for intelligent control of MMC machining”, *Journal of The Institution of Engineers (India): Series C*, 98: 395–401, (2017).
- [23] Abbas A. T., Pimenov D. Y., Erdakov I. N., Taha M. A., Soliman M. S., and El Rayes M. M., “ANN surface roughness optimization of AZ61 magnesium alloy finish turning: Minimum machining times at prime machining costs”, *Materials*, 11(5): 808, (2018).
- [24] Hoang T. D., Nguyen Q. V., Nguyen V. C., and Tran N. H., “Self-adjusting on-line cutting condition for high-speed milling process”, *Journal of Mechanical Science and Technology*, 34: 3335–3343, (2020).
- [25] Tranmer M. and Elliot M., “Multiple linear regression”, *The Cathie Marsh Centre for Census and Survey Research (CCSR)*, 5(5), 1–5, (2008).
- [26] Özdemir V., “Determination of Turkey’s Carbonization Index Based on Basic Energy Indicators by Artificial Neural Networks,” *Journal of the Faculty of Engineering and Architecture of Gazi University*, 26(1): 9-15, (2011).
- [27] Rosenblatt F., “*Principles of neurodynamics: Perceptrons and the theory of brain mechanisms*”, Cornell Aeronautical Lab Inc., Washington DC, (1962).