

St37 Çeliğinin Tornalanmasında Yüzey Pürüzlülüğünün Destek Vektör Regresyonu Kullanılarak Tahmini

Turan GÜRGENÇ^{1*} ve Osman ALTAY²

¹Otomotiv Mühendisliği, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

²Yazılım Mühendisliği, Manisa Celal Bayar Üniversitesi, Manisa, Türkiye

*tgurgenc@firat.edu.tr, osman.altay@cbu.edu.tr

(Geliş/Received: 15/06/2022;

Kabul/Accepted: 20/08/2022)

Öz: St37 çeliği birçok yapısal elemanda sıklıkla tercih edilen bir malzemedir. Düşük yüzey pürüzlülük değerine sahip parçalar yorulma, aşınma ve korozyon açısından tercih sebebidir. Yüzey pürüzlülüklerinin deneysel olarak belirlenmesi zaman alıcı ve maliyetli olduğundan makine öğrenmesi yöntemleri ile yüzey pürüzlülükleri tahmin edilerek bu durumlar elemine edilebilir. Bu çalışmada, St37 çeliği CNC torna tezgâhında farklı parametrelerde işlenmiştir. Deneysel numunelerin yüzey pürüzlülükleri (Ra, µm) farklı işlem parametreleri için ayrı ayrı profilometre ile ölçülmüş ve 72 adet veri elde edilmiştir. Elde edilen deneysel değerler destek vektör regresyon (DVR) kullanılarak modellenmiştir. DVR iki farklı çekirdek fonksiyon kullanarak modellenmiştir. Bunlar lineer ve Gauss çekirdek fonksiyonlarıdır. Modellerde giriş parametreleri olarak iki farklı koşul (kuru ve ıslak durum), iş mili hızı (dev/dak) ve ilerleme hızı (mm/dev) kullanılmıştır. Çıkış parametresi ise yüzey pürüzlülüğüdür (Ra, µm) Tasarlanan modellerin sonucunda Gauss çekirdek fonksiyonunun kullanıldığı DVR'nin daha iyi performans gösterdiği görülmüştür. Bu modelde R-kare değeri 0.8876 olarak elde edilirken lineer fonksiyona sahip DVR'de 0.7231 olarak elde edilmiştir. Gauss çekirdek fonksiyonuna sahip DVR'nin tornalama ile St37 çeliğinden parçalar üreten endüstrilerde kullanılmasıyla zaman, malzeme ve maliyet kayıplarının azaltılabileceği beklenmektedir.

Anahtar kelimeler: Destek vektör regresyon, Çekirdek fonksiyonları, Makine öğrenmesi, Yüzey pürüzlülüğü, Tornalama

Prediction of Surface Roughness in Turning of St37 Steel Using Support Vector Regression

Abstract: St37 steel is a frequently preferred material in many structural elements. Parts with low surface roughness values are preferred in terms of fatigue, wear, and corrosion. Since the experimental determination of surface roughness is time-consuming and costly, these situations can be eliminated by predicting the surface roughness with machine learning methods. In this study, St37 steel was machined in different parameters on a CNC lathe. The surface roughness (Ra, µm) of the experimental samples was measured separately for different process parameters with a profilometer, and 72 different data were obtained. The experimental values obtained were modeled using support vector regression (SVR). The SVR is modeled using two different core functions. These are linear and Gaussian kernel functions. Two different conditions (dry and wet conditions), spindle speed (rpm) and feed rate (mm/rev) were used as input parameters in the models. The output parameter is the surface roughness (Ra, µm). As a result of the designed models, it has been seen that the SVR using the Gaussian kernel function performs better. In this model, the R-square value was obtained as 0.8876, while it was obtained as 0.7231 in the DVR with linear function. Time, material, and cost losses can be reduced by using the SVR with Gaussian core function in industries producing parts from St37 steel by turning.

Keywords: Support vector regression, Kernel functions, Machine learning, Surface roughness, Turning.

1. Giriş

St37 çeliği yüksek mukavemetli bir malzemedir ve genellikle gemi, köprü, civata ve perçin gibi yüksek mukavemetli uygulamalarda tercih edilir [1]. Dönen bir parçanın yüzeyinden kuvvet uygulayarak talaş kaldırma işlemine tornalama denir. Tornalama işleminde yüzey pürüzlülüğünü etkileyen birçok parametre vardır. Bu parametrelerden bazıları takım geometrisi, kesme derinliği, soğutma durumu, iş mili hızı, ilerleme hızı, takım malzemesi, iş parçası malzemesinin mekanik özellikleri vb.'dir. Yüzey pürüzlülüğü, işlenen malzemelerin yorulma mukavemeti, sürtünme katsayısı, aşınma ve korozyon direnci gibi önemli özelliklerini etkileyen önemli bir faktördür [2, 3].

* Sorumlu yazar: tgurgenc@firat.edu.tr. Yazarların ORCID Numarası: ¹0000-0002-7678-2673, ²0000-0003-3989-2432.

Torna tezgâhında üretilen parçaların yüksek yüzey pürüzlülüğü yorulma mukavemetini, aşınma ve korozyon direncini azalttığından torna tezgâhında işlenen yüzeylerin yüzey pürüzlülüğünün kontrol edilmesi oldukça önemlidir. Bunun yanında düşük yüzey pürüzlülüğü, estetik olarak üretilmiş parçaların görünümünü iyileştirir [4]. Yüzey pürüzlülüğü, uzun yıllardır yeni bir parça tasarlanırken üzerinde durulan önemli bir tasarım faktörüdür. İşlem planlamasında kesme parametrelerinin seçiminde en önemli faktörlerden biri toleransların yanı sıra yüzey pürüzlülüğüdür [5]. Karmaşık bir süreç olan ve imalat sanayinde sıklıkla kullanılan talaşlı imalat işlemlerinin karmaşık dinamik mekanizmalarının modellenmesi ve makine öğrenmesi yöntemleri ile yüzey pürüzlülüğünün tahmin edilmesi ile zamandan, işçilikten ve malzeme kaybından tasarruf etmek mümkündür [6, 7].

Makine öğrenmesi yöntemleri tıp [8], inşaat [9], otomotiv [10], enerji [11], malzeme araştırma ve üretim endüstrisi [12-15] gibi farklı alanlarda başarıyla kullanılmaktadır. Karayel [16], çalışmada St 50.2 çeliğini CNC torna tezgâhında farklı kesme derinlikleri, kesme hızları ve ilerleme hızlarında işlemiştir. Yapay sinir ağlarını (YSA) kullanarak farklı parametrelerde deneysel olarak elde ettiği yüzey pürüzlülük değerlerini tahmin etmiştir. Pal ve Chakraborty [17], YSA kullanarak yumuşak çeliğin yüzey pürüzlülüğünü tahmin etmişlerdir. Torna tezgâhında işlenen Ti-6Al-4V'nin yüzey pürüzlülüğü YSA tarafından tahmin edilmiştir [18]. Torna tezgâhında farklı parametrelerle işlenen AISI 4140 çeliğinin yüzey pürüzlülüğü ve kesme kuvvetleri YSA ve farklı makine öğrenmesi yöntemleri ile tahmin edilmiştir [19]. Çaydaş ve Ekici AISI 304 çeliğinin tornalanmasında yüzey pürüzlülüğünü destek vektör makinesi (DVM) ile tahmin etmişlerdir [20]. Wang vd. polimetil metakrilat iş parçasının tornalanmasında yüzey pürüzlülüğünü DVM ile tahmin etmişlerdir [21]. Bir başka çalışmada, torna ile işlenmiş AISI 4340 ve AISI D2 çeliklerinin yüzey pürüzlülükleri DVM ile tahmin edilmiştir [22].

Bu çalışmada St37 çeliği, CNC torna tezgâhında altı farklı iş mili hızında ve altı farklı ilerleme hızında kuru ve ıslak koşullarda işlenmiştir. Makine öğrenmesi yöntemlerinden biri olan destek vektör regresyon (DVR) yöntemi kullanılarak yüzey pürüzlülük değerleri tahmin edilmiştir. Farklı çekirdek fonksiyonlarına sahip DVR yöntemleri kullanılarak tahmin edilen yüzey pürüzlülük değerleri hedef değerlere yakındır. Tasarlanan modelin talaşlı imalat yöntemleri ile makine parçaları üreten endüstrilerde kullanılabileceği görülmüştür.

Yapılan çalışmanın ikinci bölümünde verilerin deneysel olarak elde edilişi, DVR yöntemi, çekirdek fonksiyonları, k-katlamalı çapraz doğrulama ve değerlendirme metrikleri ayrıntılı bir şekilde anlatılmıştır. Üçüncü bölümde ise elde sonuçlar verilmiş ve iki farklı yöntemin performansları karşılaştırılmıştır. Son olarak dördüncü bölümde sonuçlar kısmına yer verilmiştir.

2. Materyal ve Metot

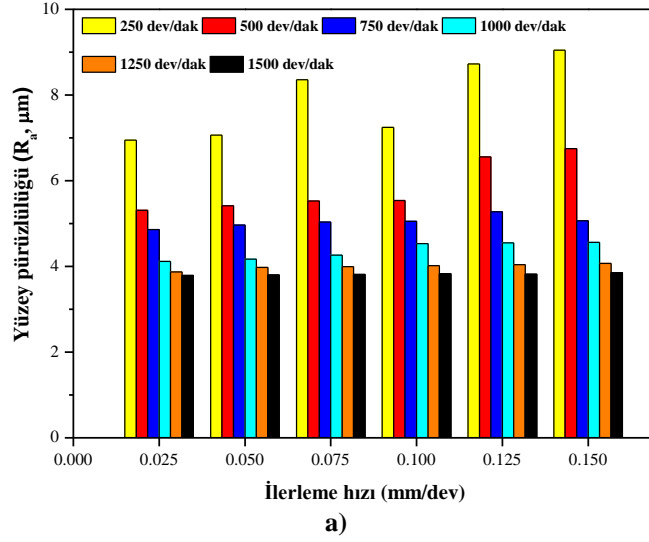
2.1. Veri Setinin Elde Edilişi

Bu çalışmada iş parçası olarak 20 mm çapında ve 120 mm uzunluğunda St37 çeliği kullanılmıştır. İş parçası, torna aynasında 35 mm iş parçası kalacak şekilde iş parçası tutucusuna bağlanmıştır. Tornalama işlemi Şekil 1'de gösterilen VOGUA CK6140S marka CNC torna tezgâhında altı farklı iş mili hızında (250, 500, 750, 1000, 1250 ve 1500 dev/dak), altı farklı ilerleme hızında (0.025, 0.05, 0.075, 0.100, 0.125 ve 0.150 mm/dev) ve iki farklı koşul (kuru ve ıslak) gerçekleştirilmiştir. Islak durumda CNC torna kesme sıvısı kullanılmıştır.

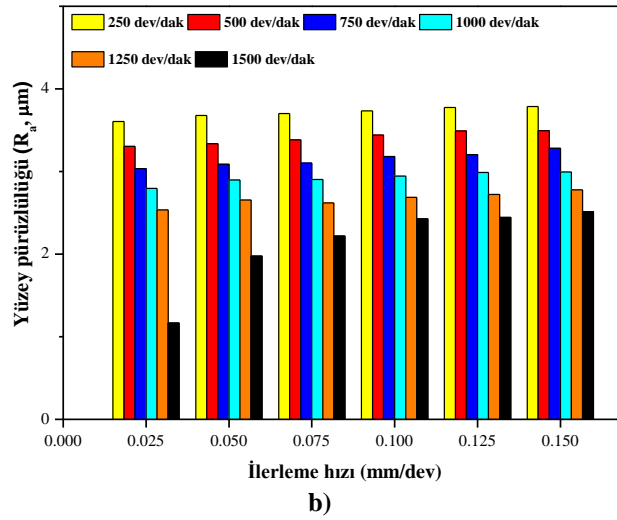
Yüzeyler 0.5 mm kesme derinliği ve 10 mm kesme uzunluğu ile işlenmiştir. Tornalama işlemi için 12 numune kullanılmış ve her numunede hız sabit tutularak farklı ilerleme hızlarında 6 adet talaş (0.5 mm kesme derinliği ve 10 mm kesme uzunluğu) uzaklaştırılmıştır. Her talaş kaldırma işlemi arasında 3 mm'lik bir mesafe bırakılmıştır. Her bir işlemden sonra iş parçasının soğuması için 10 dakika beklenmiştir. Numuneler işlendikten sonra yüzeyde kalan yağlar ve kirlerin uzaklaştırılması için ultrasonik banyoda sırasıyla aseton ve alkolle 5'er dakika yıkanmıştır. Daha sonra numuneler yine ultrasonik banyoda saf su ile durulanmıştır ve pası önlemek için hemen fırında 100 °C' de 1 saat süreyle kurutulmuştur. Numuneler oda sıcaklığına geldikten sonra işlenen numunelerin yüzey pürüzlülüğü (Ra, µm) Mitutoyo SJ-201 profilometre ile işleme yönüne paralel olarak on farklı noktadan ölçüldü ve ardından ortalamaları alındı. Numunelerin yüzey pürüzlülük değerleri Şekil 2'de görülmektedir.



Şekil 1. VOGUA CK6140S marka CNC torna tezgâhına iş parçasının bağlanması.



a)



b)

Şekil 2. Torna ile işlenen numunelerin yüzey pürüzlülükleri a) kuru şartlar ve b) ıslak şartlar.

2.2. Destek Vektör Regresyon

Destek vektör makinesi, sınıflandırma ve regresyon problemlerini çözmede kullanılan istatistiksel öğrenme teorisine dayanan genel bir yöntemdir. DVM, kayıp fonksiyonu uygulanarak regresyon problemlerinde başarı ile uygulanmaktadır [23, 24]. DVR, sınırlı sayıda öğrenme verisi kullandığı durumlarda bile, yapısal risk minimizasyonunu ilkesini kullanarak yüksek genelleme özelliği sayesinde etkili sonuçlar elde etmektedir [25, 26]. Doğrusal olmayan giriş ve çıkış değerleri arasındaki haritalama aşağıdaki Denklem 1’de verilmiştir.

$$k(z) = \langle v, \phi(z) \rangle + c \quad (1)$$

Burada z giriş değerini, $\phi(z)$ giriş verilerini yüksek değere atamak için düzensiz bir fonksiyonu göstermektedir. $v \in R$ olmak üzere ayırt edici düzlemi ve $c \in R$ skaler eşiği göstermektedir. Vapnik'in ε -duyarsız kayıp fonksiyonu Denklem 2’deki gibi tanımlanmıştır;

$$|y - k(z)|_\varepsilon = \max\{0, |y - k(z)| - \varepsilon\}, \varepsilon > 0 \quad (2)$$

Burada y çıkış değerlerini, temsil etmektedir. v değeri ne kadar küçük bir değer alırsa o kadar iyi bir denklem düzlüğü elde edilmektedir. Pratikte, ε değerinden küçük tüm veri noktaları için bir hata sağlamak bir fonksiyonda imkânsıza yakındır. Daha fazla hatayı elde edebilmek için slack değişken $\varepsilon_i, \varepsilon_i^*$ önerilmiştir. Böylece, DVR’deki optimizasyon fonksiyonu Denklem 3 ve Denklem 4’teki gibi tanımlanmaktadır;

$$\text{minimizasyon: } \frac{1}{2} \|v\|^2 + C \sum_{i=1}^n (\varepsilon_i - \varepsilon_i^*) \quad (3)$$

$$\text{kısıtlar: } \begin{cases} y_i - \{v \cdot \phi(z) + c\} \leq \varepsilon + \varepsilon_i \\ \{v \cdot \phi(z) + c\} - y_i \leq \varepsilon + \varepsilon_i^* \\ \varepsilon_i, \varepsilon_i^* \geq 0 \end{cases} \quad (4)$$

burada n değeri eğitim verisinin boyutunu, C değeri düzenleme sabitini ifade etmektedir. Optimizasyon probleminin çözümünün son hali Denklem 5 ve Denklem 6’da verilmiştir.

$$\text{maksimizasyon: } -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(z_i, z_j) - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n (\alpha_i - \alpha_i^*) \quad (5)$$

$$\text{kısıtlar: } \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \text{ and } \alpha_j^* \in [0, t] \quad (6)$$

Burada $K(z_i, z_j)$ çekirdek fonksiyon olarak tanımlanmaktadır. Bir üstteki denklem çözüldükten α_i, α_i^* değerleri için son hali Denklem 7’de verilmiştir.

$$k(z) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(z_i, z_j) + c \quad (7)$$

Burada hesaplama maliyetlerini azaltmak için farklı çekirdek fonksiyonları kullanılmaktadır. Regresyonda yaygın olarak lineer çekirdek fonksiyonu ve Gauss çekirdek fonksiyonu kullanılmaktadır [27]. Denklemleri sırasıyla Denklem 8 ve Denklem 9’da verilmiştir.

$$K(z_i, z_j) = z_i^t z_j \quad (8)$$

$$K(z_i, z_j) = \exp\left(-\frac{\|z_i - z_j\|^2}{2\sigma^2}\right) \quad (9)$$

Burada denklemde d çekirdek parametresinin derecesini, σ çekirdek parametresinin genişliğini ifade etmektedir.

2.3. K-katlamalı Çapraz Doğrulama

k -katlı çapraz doğrulama, veri seti rastgele olarak eğitim ve test veri kümesine bölen bir yöntemdir. Bu yöntemde, veri kümesi, bir örneğin test için kullanıldığı ve geri kalan $k - 1$ veri kümesinin eğitim amacıyla kullanıldığı k alt örneklerine bölünür. k -kat çapraz doğrulama yönteminde, eğitim ve test veri setleri değiştirilerek tüm süreç k kez tekrarlanır.

2.4. Değerlendirme Metrikleri

Regresyon modellerinin tahmin başarısının ölçülmesinde literatürde farklı metrikler kullanılmaktadır. Yapılan bu çalışmada 3 farklı metrik kullanarak modellerin performansları karşılaştırılmıştır. Bunlar R-kare (R^2), ortalama kare hata (OKH) ve ortalama mutlak hata (OMH) metrikleridir. R^2 değeri 0 ile 1 arasında değer alırken 1'e ne kadar yakınsa model performansı o kadar iyidir. OKH ve OMH metriklerinin değerlerinin ise 0'a yakın olması beklenmektedir. Kullanılan metrikler R^2 , OKH ve OMH'a ait denklemler sırasıyla Denklem 10, Denklem 11 ve Denklem 12'de verilmiştir.

$$R^2 = 1 - \left(\frac{\sum_j (t_j - o_j)^2}{\sum_j (t_j - \bar{t})^2} \right) \quad (10)$$

$$MSE = \left(\frac{1}{n} \right) \times \sum_j |t_j - o_j|^2 \quad (11)$$

$$MAE = \frac{1}{n} \sum_{j=1}^n |t_j - o_j| \quad (12)$$

3. Bulgular ve Tartışma

Yapılan çalışmada St37 çeliği, CNC torna tezgâhında altı farklı iş mili hızında ve altı farklı ilerleme hızında, kuru ve ıslak koşullarda işlenmiştir. Deneysel olarak 72 farklı örnek veri elde edilmiştir. Giriş parametreleri olarak iki farklı koşul (kuru ve ıslak durum), iş mili hızı (dev/dak) ve ilerleme hızı (mm/dev) alınmıştır. Çıkış parametresi olarak yüzey pürüzlülüğünün tahmin edilmesi için iki farklı (lineer ve Gauss) çekirdek fonksiyona sahip DVR modelleri tasarlanmıştır. Tasarlanan modellerin test edilmesi için 5 katlı çapraz doğrulama yöntemi kullanılmıştır. İki farklı modelin birbiri ile karşılaştırılmasının adil olması için eğitim ve test verileri rastgele olarak seçilirken her iki modelde aynı eğitim ve test verileri kullanılmıştır. Tablo 1'de DVR yöntemlerine parametreler verilmiştir.

Modellerin performanslarının karşılaştırılması için 3 farklı değerlendirme metriği kullanılmıştır. Bunlar R-kare, OKH ve OMH metrikleridir. Yapılan çalışmanın sonucunda metriklerden elde edilen değerler Tablo 2'de verilmiştir. Tablo incelendiği zaman Gauss çekirdek fonksiyonuna sahip DVR'nin, lineer çekirdek fonksiyonuna sahip DVR'ye göre çok daha iyi bir performans gösterdiği görülmektedir. DVR (lineer) ve DVR (Gauss) sırasıyla R-kare değerinde 0.7231 ve 0.8876 değerlerini elde etmiştir. DVR (Gauss), DVR (lineer)'e göre R-kare değerinde yüzde 22.7 oranında daha iyi performans göstermiştir. DVR (lineer) ve DVR (Gauss) sırasıyla OKH değerinde 0.6628 ve 0.2691 değerlerini elde etmiştir. DVR (Gauss), DVR (Lineer)'e göre OKH değerinde yüzde 59.3 oranında daha iyi performans göstermiştir. DVR (lineer) ve DVR (Gauss) sırasıyla OMH değerinde 0.4549 ve 0.2713 değerlerini elde etmiştir. DVR (Gauss), DVR (Lineer)'e göre OKH değerinde yüzde 40.4 oranında daha iyi performans göstermiştir.

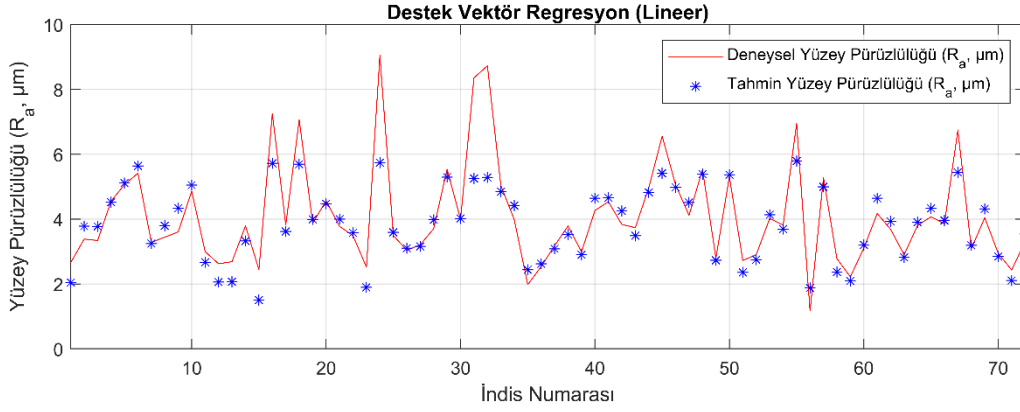
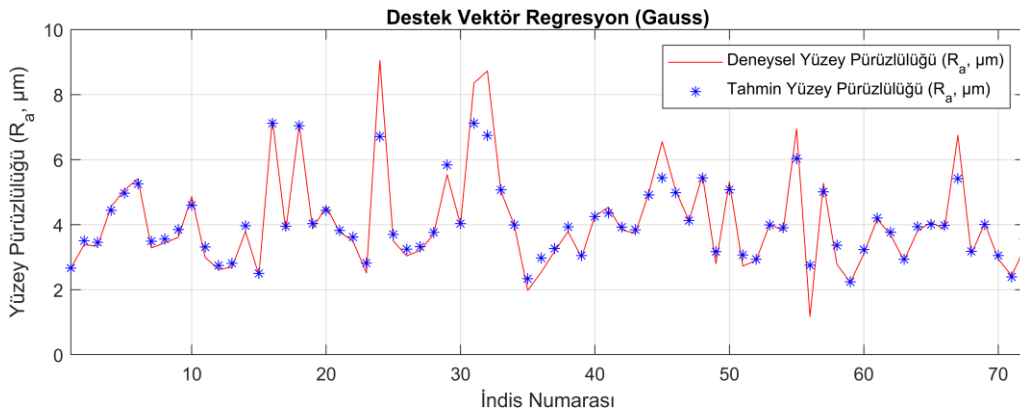
Tablo 1. DVR parametreleri.

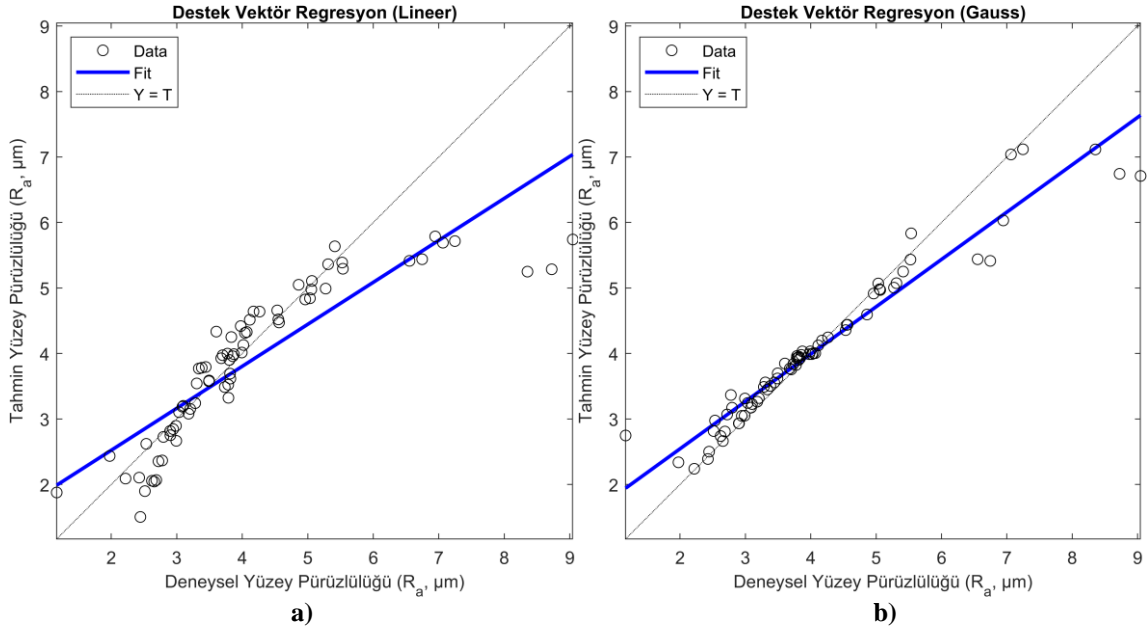
DVR parametreleri		
Çekirdek fonksiyonu	Lineer	Gauss
Kutu kısıtlaması	1	1.4804
Epsilon	0.1480	0.1480
Çekirdek ölçeği	1	Otomatik

Tablo 2. Yüzey pürüzlülüğü için tasarlanan modellerin değerlendirme metrikleri sonucunda elde ettikleri performans.

	R ²	OKH	OMH
DVR (Lineer)	0.7231	0.6628	0.4549
DVR (Gauss)	0.8876	0.2691	0.2713

Şekil 3'te yüzey pürüzlülüğüne ait deneysel değerler ve lineer çekirdek fonksiyonuna sahip DVR'den elde edilen tahmin değerleri verilmiştir. Şekil 4'te yüzey pürüzlülüğüne ait deneysel değerler ve Gauss çekirdek fonksiyonuna sahip DVR'den elde edilen tahmin değerleri verilmiştir. Şekil 3 ve Şekil 4 incelendiği zaman Gauss çekirdek fonksiyonuna sahip DVR yönteminin, lineer çekirdek fonksiyonuna sahip DVR yöntemine bariz bir üstünlük sağladığı görülmektedir. Şekilde 5'te tasarlanan iki modele ait serpilme grafikleri verilmiştir. Şekil incelendiği zaman Gauss çekirdek fonksiyonuna sahip DVR'nin, lineer çekirdek fonksiyonuna sahip DVR'ye göre uygunluk çizgisine daha yakın değerler elde ettiği ve daha az serpildiği rahatlıkla görülmektedir. Önerilen modellerden Gauss çekirdek fonksiyonuna sahip DVR'nin tornalama ile parça işleyen endüstrilerde kullanılmasıyla yeni bir parça tasarlanırken oluşan maliyet, zaman, malzeme ve iş gücü kayıpları azaltılabilir. Parçaların işlenmesinden önce en uygun işleme parametrelerinin önceden bilinmesi ile tasarım mühendislerine esneklik ve zaman kazandırılabilir.

**Şekil 3.** DVR (Gauss) tahmin ve deneysel yüzey pürüzlülüğü değerleri.**Şekil 4.** DVR (Lineer) tahmin ve deneysel yüzey pürüzlülüğü değerleri.



Şekil 5. Serpilme grafikleri a) DVR (Lineer) b) DVR (Gauss).

4. Sonuçlar

St37 çeliğinin torna ile işlenmesinde farklı işlem parametrelerinden doğan yüzey pürüzlülükleri makine öğrenmesi yöntemleri ile tahmin edilmiştir. Regresyon için kullanılan makine öğrenmesi yöntemlerinden DVR lineer ve Gauss olmak üzere iki farklı çekirdek fonksiyonu ile uygulanmıştır. DVR'nin yüzey pürüzlülüklerini başarıyla tahmin edilebileceği yapılan çalışmanın sonucunda görülmüştür. Yapılan çalışmanın ışığında Gauss çekirdek fonksiyonuna sahip DVR'nin imalat endüstrisinde torna ile parça imalatı gerçekleştirilen endüstrisinde kullanılmasıyla, zaman, maliyet, iş gücü ve malzeme kayıplarının azaltılması açısından avantaj sağlayacağı düşünülmektedir. Ayrıca işlem parametrelerine göre yüzey kalitelerinin önceden bilinmesi tasarım mühendislerine tasarım esnekliği sağlayabilir.

Teşekkür

T.G ve O.A., fikir sahibi, T.G. deneyleri gerçekleştirdi, T.G. ve O.A. modellemeyi gerçekleştirdi, T.G. ve O.A. sonuçları yorumladı, T.G. ve O.A. makaleyi yazdı.

Kaynaklar

- [1] Solomon M M, Gerengi H, Kaya T, Kaya E, Umoren S A. Synergistic inhibition of St37 steel corrosion in 15% H2SO4 solution by chitosan and iodide ion additives. *Cellulose* 2017; 24(2): 931-950.
- [2] Khalilpourazary S, Kashtiban P, Payam N. Optimizing turning operation of St37 steel using grey relational analysis. *J. Comput. Appl. Res. Mech. Eng.* 2014; 3(2): 135-144.
- [3] Singh D, Rao P V. A surface roughness prediction model for hard turning process. *Int. J. Adv. Manuf. Technol.* 2007; 32(11): 1115-1124.
- [4] Asiltürk I, Çunkaş M. Modeling and prediction of surface roughness in turning operations using artificial neural network and multiple regression method. *Expert Syst. Appl.* 2011; 38(5): 5826-5832.
- [5] Wang X, Feng C. Development of empirical models for surface roughness prediction in finish turning. *Int. J. Adv. Manuf. Technol.* 2002; 20(5): 348-356.
- [6] Barzani M M, Zalnezhad E, Sarhan A A, Farahany S, Ramesh S. Fuzzy logic based model for predicting surface roughness of machined Al-Si-Cu-Fe die casting alloy using different additives-turning. *Measurement* 2015; 61: 150-161.
- [7] Khorasani A, Yazdi M R S. Development of a dynamic surface roughness monitoring system based on artificial neural networks (ANN) in milling operation. *Int. J. Adv. Manuf. Technol.* 2017; 93(1): 141-151.

- [8] Garg A, Mago V. Role of machine learning in medical research: A survey. *Comput. Sci. Rev.* 2021; 40: 100370.
- [9] Altay O, Ulas M, Alyamac K E. DCS-ELM: a novel method for extreme learning machine for regression problems and a new approach for the SFRSCC. *PeerJ Comput. Sci.* 2021; 7: e411.
- [10] Okcu M, Fırat M, Varol Y, Altun Ş, Kamışlı F, Atila O. Combustion of high carbon (C7-C8) alcohol fuels in a reactivity controlled compression ignition (RCCI) engine as low reactivity fuels and ANN approach to predict RCCI emissions. *Fuel* 2022; 319: 123735.
- [11] Altay E V, Gurgenc E, Altay O, Dikici A. Hybrid artificial neural network based on a metaheuristic optimization algorithm for the prediction of reservoir temperature using hydrogeochemical data of different geothermal areas in Anatolia (Turkey). *Geothermics* 2022; 104: 102476.
- [12] Xia C, Pan Z, Polden J, Li H, Xu Y, Chen S. Modelling and prediction of surface roughness in wire arc additive manufacturing using machine learning. *J. Intell. Manuf.* 2022; 33(5): 1467-1482.
- [13] Ramesh P, Mani K. Prediction of surface roughness using machine learning approach for abrasive waterjet milling of alumina ceramic. *Int. J. Adv. Manuf. Technol.* 2022; 119(1): 503-516.
- [14] Ulas M, Altay O, Gurgenc T, Özel C. A new approach for prediction of the wear loss of PTA surface coatings using artificial neural network and basic, kernel-based, and weighted extreme learning machine. *Friction* 2020; 8: 1102-1116.
- [15] Gurgenc T, Altay O. Surface roughness prediction of wire electric discharge machining (WEDM)-machined AZ91D magnesium alloy using multilayer perceptron, ensemble neural network, and evolving product-unit neural network. *Mater. Test.* 2022; 64(3): 350-362.
- [16] Karayel D. Prediction and control of surface roughness in CNC lathe using artificial neural network. *J. Mater. Process. Technol.* 2009; 209(7): 3125-3137.
- [17] Pal S K, Chakraborty D. Surface roughness prediction in turning using artificial neural network. *Neural Computing & Applications* 2005; 14(4): 319-324.
- [18] Sahu N K, Andhare A B, Andhale S, Abraham R R, Prediction of surface roughness in turning of Ti-6Al-4V using cutting parameters, forces and tool vibration. *IOP Conf. Ser.: Mater. Sci. Eng.* 2018; 346(1): 012037.
- [19] Meddour I, Yaltese M A, Bensouilah H, Khellaf A, Elbah M. Prediction of surface roughness and cutting forces using RSM, ANN, and NSGA-II in finish turning of AISI 4140 hardened steel with mixed ceramic tool. *Int. J. Adv. Manuf. Technol.* 2018; 97(5): 1931-1949.
- [20] Çaydaş U, Ekici S. Support vector machines models for surface roughness prediction in CNC turning of AISI 304 austenitic stainless steel. *J. Intell. Manuf.* 2012; 23(3): 639-650.
- [21] Wang X, Kang M, Fu X, Li C. Predictive modeling of surface roughness in lenses precision turning using regression and support vector machines. *Int. J. Adv. Manuf. Technol.* 2016; 87(5): 1273-1281.
- [22] Zhang N, Shetty D. An effective LS-SVM-based approach for surface roughness prediction in machined surfaces. *Neurocomputing* 2016; 198: 35-39.
- [23] Cortes C. WSupport-vector network. *Machine learning* 1995; 20: 1-25.
- [24] Drucker H, Burges C J, Kaufman L, Smola A J, Vapnik V, Support vector regression machines. *Adv. Neural. Inf. Process. Syst.* 1996; 9: 155-161.
- [25] Dash R K, Nguyen T N, Cengiz K, Sharma A. Fine-tuned support vector regression model for stock predictions. *Neural. Comput. Appl.* 2021; 1-15.
- [26] Gurgenc T, Altay O, Ulas M, Ozel C. Extreme learning machine and support vector regression wear loss predictions for magnesium alloys coated using various spray coating methods. *J. Appl. Phys.* 2020; 127(18): 185103.
- [27] Tang Y, Guo W, Gao J. Efficient model selection for support vector machine with Gaussian kernel function. *IEEE Symposium on Computational Intelligence and Data Mining. IEEE Nashville, TN 2009*; 40-45.