

YÜZEY PÜRÜZLÜLÜĞÜNÜN YAPAY SİNİR AĞI VE REGRESYON MODELLERİ İLE BELİRLENMESİ VE KARŞILAŞTIRILMASI

Şakir TAŞDEMİR

Selçuk Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri
Bölümü, stasdemir@selcuk.edu.tr Konya, Türkiye

Özet

İmalat teknolojisinde, malzemenin kullanılabilirliğini ve maliyetleri etkileyen en önemli hususların başında ürün yüzey kalitesinin belirlenmesi gelmektedir. Bu nedenle imalat aşamasından önce en uygun yüzey pürüzlülüğü değerlerini belirlemek için değişik modeller geliştirmişlerdir. Bu çalışmada, endüstride önemli yer tutan tornalama işlemlerindeki uygun pürüzlülük değerlerinin tahmin edilmesi amaçlanmıştır. Bunun için Regression Modeli (RM) ve yapay zeka tekniği olan Yapay Sinir Ağı (YSA) ayrı ayrı kullanılmış ve karşılaştırılmıştır. Bu iki ayrı model için giriş parametreleri; uç radyüsü (r), yaklaşma açısı (κ), talaş açısı (γ) ve çıkış parametresi; yüzey pürüzlülüğü (R_a) olarak kullanılmıştır. Bu modellemeler ile yüzey pürüzlülük değerleri tahmin edilmiştir. Deneysel veriler ile geliştirilen YSA ve RM modellerinden elde edilen veriler istatistiksel olarak karşılaştırıldığında, tasarlanan modellerin başarılı sonuçlar verdiği görülmüştür ($P>0.001$). YSA ve RM ile elde edilen veriler deneysel veriler ile ayrı ayrı karşılaştırıldığında ise YSA ile elde edilen verilerin deneysel verilere RM ile elde edilen verilerden daha yakın olduğu ve yüzey pürüzlülük tahmini için kullanılabileceği görülmektedir.

Anahtar Kelimeler: Yüzey Pürüzlülük; Yapay Sinir Ağlar, Regresyon Analizi.

THE COMPARATIVE STUDY TO DETERMINE SURFACE ROUGHNESS WITH ARTIFICIAL NEURAL NETWORK AND REGRESSION MODEL

Abstract

In manufacturing technology, one of the most important factors affecting the usage and cost of materials is to determine the surface quality of products. Therefore, various models are developed in order to determine the most suitable roughness values before manufacturing stage. This study aims to predict the suitable surface roughness in

turning, which is important in industry. For this, Regression Model (RM) and Artificial Neural Network (ANN), which is an artificial intelligence technique, are used separately and compared with each other. For these two models, input parameters are used as tool nose radius (r), approach angle (κ), rake angle (γ) and the output parameter is determined as surface roughness (R_a). With these models, R_a values are predicted. When experimental data are compared with developed RM and ANN statistically, the designed models are seen to be successful ($P>0.001$). When ANN and RM are compared separately, ANN values are seen to be closer to experimental data. These results show that these models can be used for estimating surface roughness.

Keywords: Surface Roughness, Artificial Neural Network, Regression Analysis

1. Giriş

İmalat teknolojisinde, malzemenin kullanılabilirliğini ve maliyetleri etkileyen en önemli hususların başında ürün yüzey pürüzlülük değerinin belirlenmesi gelmektedir. Tornalama işlemiyle üretilen ürünlerde aranan özellikler içinde yüzey pürüzlülüğü, malzemenin maliyetini, kalitesini, aşınma direncini, yorulma mukavemetini, sürtünme katsayısını, yağlamayı ve korozyon direncini etkileyen başlıca etkendir. Özellikle birbiriyle çalışan eş parçaların çalışma verimliliğinin artırılması en uygun yüzey pürüzlülük değerlerinin belirlenmesi ile mümkün olmaktadır. Sadece operatörün tecrübesi gözetiminde yapılacak işlemlerde, yetersiz bilgi ve beceri eksikliği düşünülünce ulaşılmak istenen yüzey pürüzlülüğü değeri hayal olacaktır. İstenen yüksek performanslı kesme ve yüzey pürüzlülüğüne ulaşabilmek, tecrübenin yanında uygun kesme koşullarının sağlanmasıyla mümkündür. Bu amaçla günümüzde imalat mühendisleri yüzey pürüzlülüğü karakteristiği ve değerini tahmin etmek için değişik modeller geliştirmişlerdir [1, 2].

Literatürde yüzey pürüzlülüğünün tahmin edilmesi için kullanılan en yaygın dört metot sırasıyla Çoklu Regresyon Analizi, Matematiksel Modelleme, Bulanık Küme Tabanlı Teknik ve YSA sayılabilir [2]. Yüzey pürüzlülüğü mekanizmasının formülize edilmesi, esasen talaş kaldırma işlemine bağlı karmaşık bir süreçtir. Bu yüzden analitik olarak pürüzlülük değerinin bulunması oldukça zordur. Sistemlerin matematiksel modellemelerinin çıkartılması sistemi etkileyen tüm parametrelerin hızlı ve etkin bir şekilde değerlendirilmesini gerektirmektedir. Bu değerlendirme her zaman tam olarak

doğru olamayacağından hata oranı oluşturmaktadır. Dolayısıyla bu işlem için en uygun yöntemlerden bir tanesi çoklu regresyon modeli kullanmaktır. Çünkü işleme esnasındaki tüm parametrelerin, oluşturulan istatistiksel modele dahil edilebilirliği sonucun doğruluğunu olumlu bir şekilde etkilemektedir. [2-5].

Bir deneysel çalışmanın yapılabilmesi için öncelikle bir deney ortamını oluşturmak gereklidir. Ayrıca bu konuda bir uzmana, özel araç ve gereçlere ihtiyaç duyulmaktadır. Bununla birlikte oldukça fazla zamana ve maliyete de gereksinim vardır. Yapay zeka yöntemleri, özellikle YSA klasik yöntemlerle zor çözülebilen, matematiksel olarak formüle edilemeyen veya çözülmesi mümkün olmayan karmaşık, lineer olmayan problemleri çok kolay çözülebilmekte, yukarıda sayılan bu tür kısıtlamaları ve dezavantajları elimine ederek çok başarılı bir şekilde kullanılmaktadır. YSA'lar tahmin, sınıflandırma, örüntü tanıma, teşhis, yorumlama, veri filtreleme ve ilişkilendirme gibi birçok fonksiyonu gerçekleştirerek endüstri, finansal, askeri, sağlık, iletişim, mühendislik gibi birçok uygulama alanlarında kullanılmaktadırlar [6-9].

Literatürde, YSA kullanarak arzu edilen yüzey pürüzlülüğü değerlerine ulaşabilmek için birçok çalışma yapılmıştır. Bunlardan bazıları, tornalama işleminde yüzey pürüzlülüğü tahmini için bilgi tabanlı sistem kullanımı [10], YSA ile kalıp parçalarının yüzey pürüzlülüğünü belirleme [11], tornalamada kesme koşullarının yüzey pürüzlülüğü üzerine etkisinin YSA ile modellenmesi [12], işleme sürecinde yüzey pürüzlülüğünün tahmini [13] v.b. alanlardır.

Bu çalışmada, silindirik tornalama operasyonunda değişken takım geometrisine bağlı olarak yüzey pürüzlülüğü değeri (Ra) tahmini için bir RM ve YSA yaklaşımı sunulmuştur. Daha sonra deneyde [5, 14] ölçülen pürüzlülük değerleri ile RM ve YSA yaklaşım ile elde edilen değerler arasındaki tutarlılığa bakılarak, karşılaştırılmıştır.

2. Regresyon Analizi

İstatistik'in en fazla kullanım alanı bulan konularından birisini regresyon analizidir. Bir olayı etkileyen birden fazla faktör olması durumunda sebep-sonuç ilişkisinin araştırılması çoklu regresyon analiziyle mümkün olacaktır. Bir regresyon modeli bağımlı ve bağımsız değişkenlerden oluşmaktadır. Bağımsız değişken, bağımlı değişkeni açıklamak için kullanılan tesadüfi olmayan değişkendir. Genelde çoklu

regresyon analizi bağımlı değişkene ilişkin ortalama çıkış değerlerinin bulunması amacıyla kullanılır [17].

Basit doğrusal regresyon modelin fonksiyonel biçimi bir yığın için denklem şeklinde yazılabilir [18].

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (1)$$

Bu modelde;

Y:Bağımlı değişken değeri,

X:Bağımsız değişken değeri,

β_0 :Yığın için Y keseni (sabit terim),

β_1 :Yığın regresyon doğrusunun eğimi,

ε :Hata terimi,

Bunun için Tablo 1’de verilen kesme şartlarında, deneysel [14-16] olarak elde edilmiş olan verilerden faydalanılarak istatistiksel analiz yöntemiyle sistemin tekli ve çoklu regresyon denklemleri SPSS programı ile oluşturulmuştur. RM ile elde edilen matematiksel ifade ile pürüzlülük değeri (Ra) tahmin edilmiş ve deneysel sonuçlarla karşılaştırılmıştır. Ayrıca YSA yöntemi kullanılarak Ra değerleri tahmin edilmiş ve her iki yöntemle alınan sonuçlar karşılaştırılmıştır.

Tablo 1. Ra sonuçları için kullanılan kesme koşulları [14].

Takım Uç Radyüsü (r)	Yaklaşma Açısı (κ)	Talaş Açısı (γ)	Takım Sarkma Miktarı (L)	Yardımcı Talaş Açısı (γ _x)	Talaş Derinliği (d)	Devir Sayısı (n)	Kesme Hızı (V _c)	İlerleme Miktarı (f)
0.4	60°	-3°						
0.8	75°	-6°	30 mm	-6°	0.5 mm	1200 rpm.	150 m/min.	0.15 mm/rev.
1.2	90°	-9°						

Bu çalışmada yüzey pürüzlülüğüne etki eden faktörlerden, uç radyüsü (r), yaklaşma açısı (κ) ve talaş açısı (γ) alınarak regresyon denklemleri bu üç parametre kullanılarak oluşturulmuştur. SPSS yazılımında oluşturulan regresyon eşitlikleri ile, her bir değişkenin durumu, elde edilen korelasyon ve determinasyon katsayıları hesaplanmıştır.

En yüksek korelasyon (R=0.935) bu üç değişken kullanılarak oluşturulan doğrusal çoklu regresyon denklemi ile elde edilmiştir. Ve bu şekilde deneye en yakın sonuçlar elde edilmiştir. Ayrıca çoklu regresyon denklemi ile Ra tahmin edildiğinde

determinasyon katsayısının ($R^2=0.874$) olarak bulunmuştur. Bu değerler istatistiksel olarak anlamlı ve uyumlu olduğunu göstermektedir. Bulunan korelasyon değerlerine göre RM ile hesaplanan R_a 'lar ile deneyde ölçülen R_a arasında aynı yönlü, genelde kuvvetli bir ilişki olduğu Tablo 2'de r sütununda görülmektedir.

Tablo 2. Giriş Parametrelerin lineer etkileri ve regresyon analizi ile R_a tahmin eşitliği

Tahmin Denklemi (y)	Lineer Çoklu Regresyon Katsayıları				R	R^2	P
	Sabit (a_0)	r (b_1)	κ (b_2)	γ (b_3)			
$a+b_1x_1+b_2x_2+b_3x_3$	-5.404***	4.331***	0.069***	0.339***	0.935	0.874	0.000

*** $P<0.001$

Bu şekilde elde edilen doğrusal çoklu regresyon denklemi aşağıdaki şekilde ifade edilmiş ve sistem tahmin edilmiştir (denklem 2).

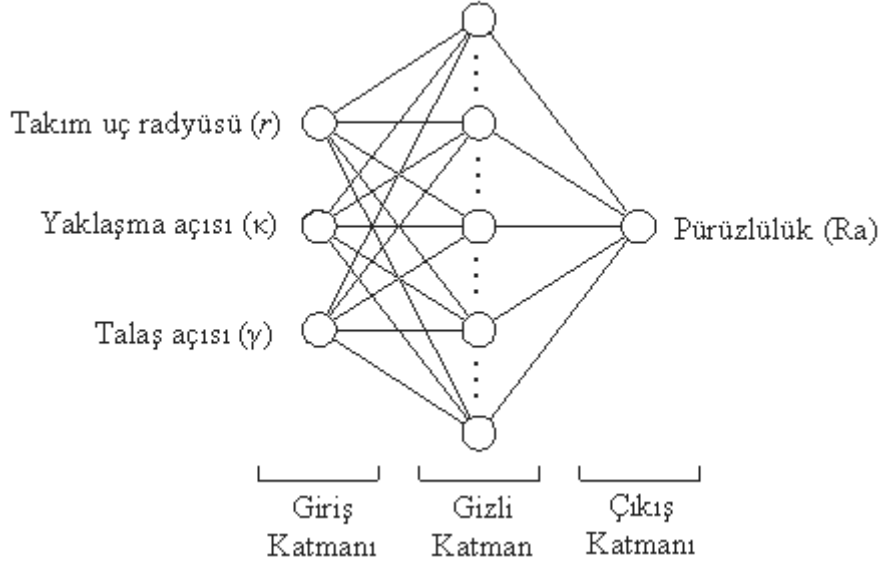
$$R_a = -5.404 + 4.331 r + 0.069 \kappa + 0.339 \gamma \quad (2)$$

3. YSA Modeli ve Uygulaması

YSA'lar biyolojik sinir ağı modelinin yapısını ve işlevini taklit ederek oluşturulan bir zeki sistemdir. YSA'nın eğitilebilmesi ve hedef çıktılara ulaşılması için çok sayıda girdi ve girdilere ilişkin çıktı dizisine gereksinim duyulur. YSA'nın yapısını temelde giriş, gizli ve çıkış katmanları oluşturmaktadır. Bu katmanlarda neuron, bağlantılar ve ağırlıklar olmak üzere bileşenler bulunmaktadır. Bu üç bileşen ağın yapısı oluşturulduktan sonra eğitim ve test aşaması olarak bilinen matematiksel süreçte kullanılmaktadır. Tasarlanan YSA modelinin yapısı ve bileşenleri Şekil 1'de gösterilmiştir [5, 7, 8].

Bu çalışmada mühendislik uygulamalarında tahmin amaçlı olarak yaygın olarak kullanılan ileri beslemeli çok katmanlı geri yayılım algoritması (ÇKGYA) kullanılmıştır. Oluşturulan YSA 3 girişli ve 1 çıkışlıdır (Şekil 1). Bu model için giriş parametreleri; uç radyüsü (r), yaklaşma açısı (κ), talaş açısı (γ) ve çıkış parametresi; yüzey pürüzlülüğü (R_a) olarak toplam dört parametreden oluşmaktadır. Sistemin modellenmesi yani YSA eğitim ve test işlemi için, bu değişkenlere ait deneyden [5, 14, 16] elde edilmiş her parametreden 27, toplam 108 veri dizi seti kullanılmıştır.

YSA'nın çalıştırılmasında kullanılan bilgisayar, Intel Core i3-2310 2.10 GHz işlemci, 2GB RAM donanımsal özelliklerine sahiptir. Bu verilerin eğitimi ve testi için yazılım olarak Matlab R2008b yazılımını kullanılmıştır.



Şekil 1. Uygulaması Gerçekleştirilen YSA Ağ Yapısı

Gerçek deney verileri eğitim ve test verileri olarak ayrılmış ve bunlar 0-1 arasında normalize (denklem 3) edilmiştir.

$$V_N = \frac{V - V_{\min}}{V_{\max} - V_{\min}} \quad (3)$$

Burada; V_N bir parametredeki normalize değeri, V bir parametredeki gerçek değeri, V_{\max} ve V_{\min} bir parametredeki maksimum ve minimum değerleri ifade etmektedir.

Uygulamada, ilk işlem olarak hangi eğitim algoritmasının daha başarılı sonuçlar verdiği MSE (Mean Square Error- Hata Kareler Ortalaması) (denklem 4) hata oranı dikkate alınarak belirlenmiştir. En iyi algoritma yapısı belirlenirken epoch ve gizli katmandaki neron sayısı dikkate alınmıştır. Bu hata oranının en küçük olduğu durumdaki eğitim algoritması seçilmiştir. Bu amaçla eğitim ve test verilerin hangi eğitim algoritması gerçek deneysel değerlere daha yaklaşık sonuçlar verdiğini tespit edebilmek için Matlab'de geliştirilen yazılım çalıştırılmıştır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (d_i - O_i)^2 \quad (4)$$

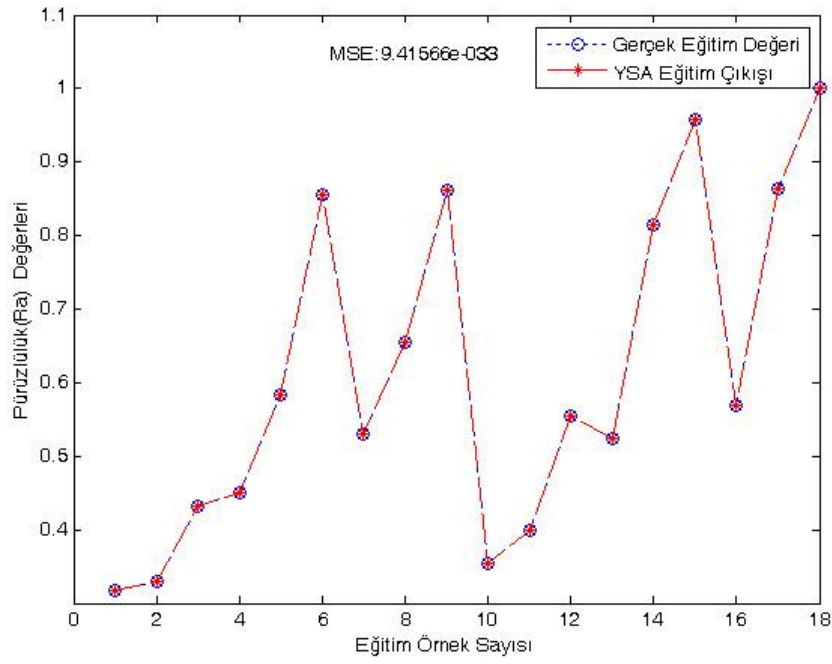
Burada d_i hedeflenen veya gerçek değer (elle ölçüm ve dijital kantar), O_i çıkış veya tahmin edilen değer (RM ve YSA), n çıkış verileri sayısıdır.

27 veriden 19 tanesi eğitim, 9 tanesi de test işlemi için kullanılmıştır. Bu işlemde veriler 3-fold (kat) çaprazlama şeklinde değiştirilerek eğitim ve test işlemine tabi tutulmuştur. Eğitim ve test için sırasıyla Levenberg-Marquardt (trainlm), Resilient Backpropagation (trainrp), Gradient Descent Backpropagation (trainingd) algoritmaları ile çalıştırılmış ve sonuçlar alınmıştır. Ayrıca en yakın sonuçların hangi transfer fonksiyonda elde edilebileceğini belirlemek içinde sırasıyla Hyperbolic Tangent Sigmoid (tansig), Logistic Sigmoid (logsig) ve Linear (purelin) transfer function ile Matlab ortamında geliştirilen program çalıştırılmıştır. Eğitim ve test işleminde gizli katmandaki neron sayısı sırasıyla 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15 ve epoch sayısı da 5, 10, 13, 15, 18, 20, 30, 50, 70, 100 olarak belirlenmiş ve sistem tek tek çalıştırılmıştır. En iyi sonucu trainlm algoritmasında, logsig transfer fonksiyonu ve bu fonksiyona ait 18 epoch 3-11-1 modeli ile elde edilmiştir. Bu durumda test hatası MSE (denklem 4) 0.00530 olarak bulunmuştur.

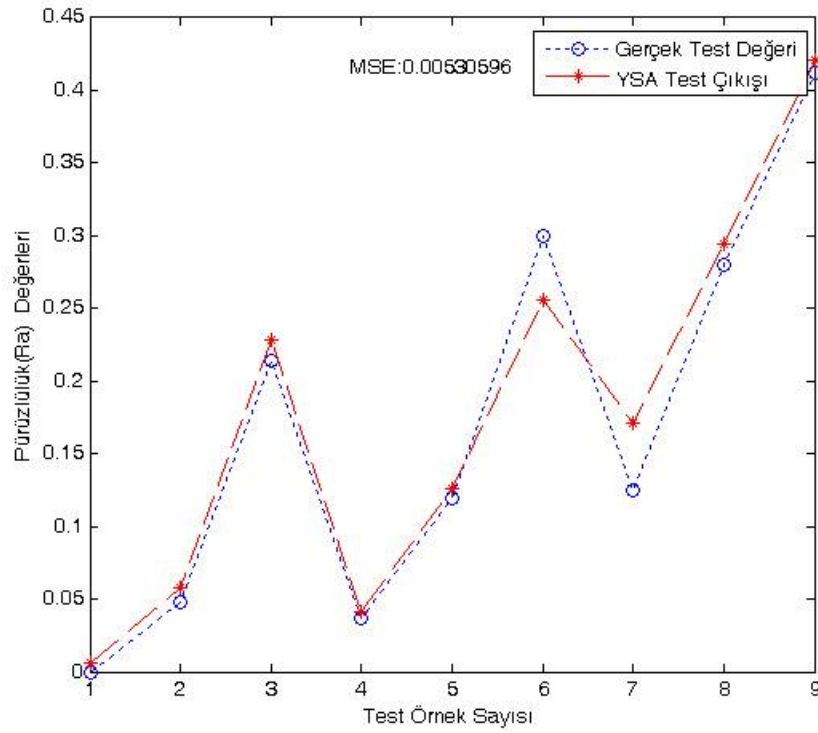
4. Sonuçlar Ve Öneriler

Bu çalışmada, RM ve YSA yaklaşımı ile yüzey pürüzlülüğü tahmin edilmiştir ve etkin sonuçların alınabileceği görülmüştür.

Model 3-11-1'e trainlm ve tansig transfer fonksiyonu ile eğitim için elde edilen MSE (Şekil 2) ve test için MSE (Şekil 3) hataları ve karşılaştırmalı sonuç grafikleri görülmektedir. Şekil 2 ve Şekil 3'deki karşılaştırmalı grafik incelendiğinde deneylerde elde edilen verilerin YSA daki sonuçlara benzer olduğu görülmektedir.

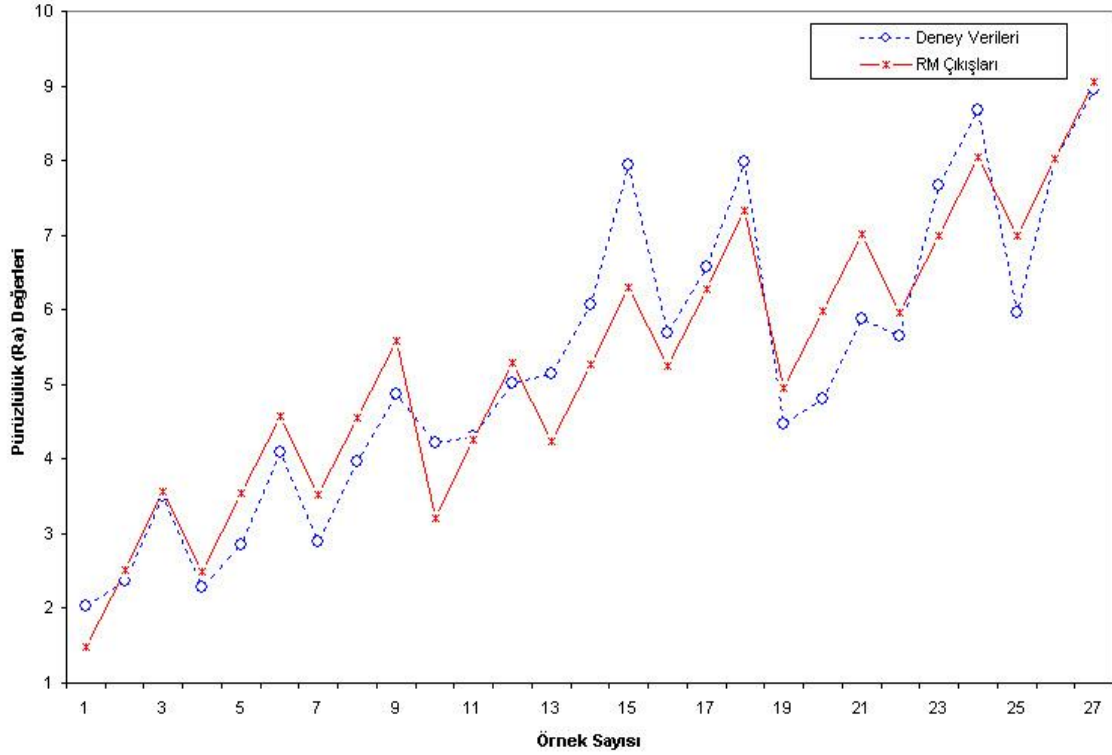


Şekil 2. Deney ve YSA (3-11-1 model) ile eğitim işlemi sonuçları karşılaştırmalı grafiği



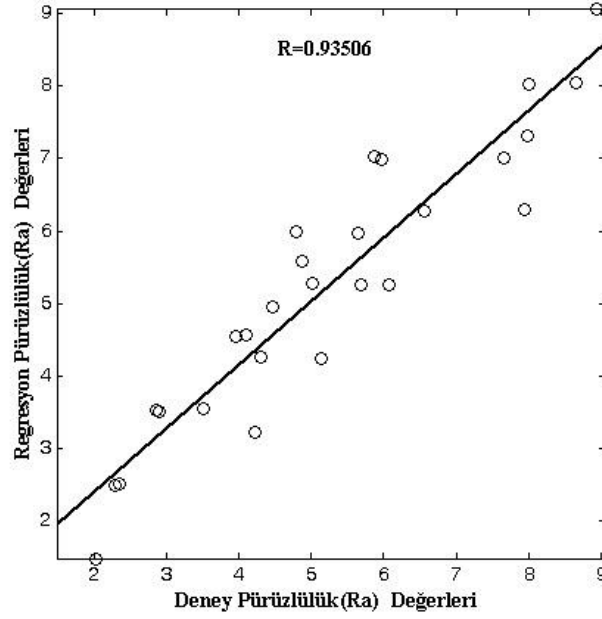
Şekil 3. Deney ve YSA (3-11-1 model) ile test işlemi sonuçları karşılaştırmalı grafiği

RM ile tahmin işleminde doğrusal çoklu regresyon modeli (denklem 2) kullanılarak yapılan çalışma sonunda elde edilen değerler gerçek verilerle karşılaştırıldığında iki grup verinin oldukça birbirine yakın olduğu Şekil 4’de görülmektedir.

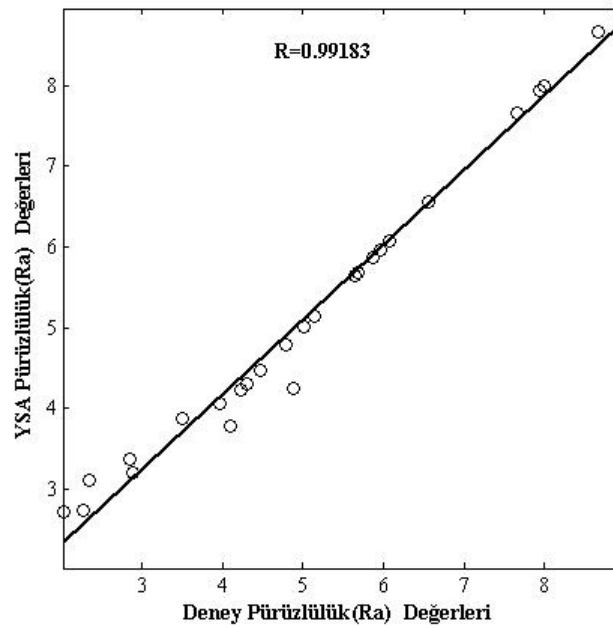


Şekil 4. Deney ve RM sonuçları karşılaştırmalı grafiği

RM-deney verileri arasında yapılan korelasyon analizleri ile $R=0.93506$ olarak hesaplanmıştır (Şekil 5). YSA-deney arasında ise korelasyon değeri $R=0.99183$ bulunmuştur (Şekil 6). RM ve YSA’dan elde edilen Ra değerleri karşılaştırıldığında, YSA modeli gerçek verilerine daha yakın sonuçlar verdiği Şekil 5 ve Şekil 6 incelendiğinde net bir şekilde görülmektedir. Korelasyon sonuçları, deney ile modellerden elde edilen sonuçlar arasındaki yani iki grup veri birbiriyle ilişkilidir sonucuna göstermekte ve veriler arasında anlamca hiçbir fark olmadığı ispatlanmaktadır.



Şekil 5. Deney-RM Yüzey Pürüzlülüğü değerleri arasındaki ilişki grafiği



Şekil 6. Deney-YSA Yüzey Pürüzlülüğü değerleri arasındaki ilişki grafiği

Sonuç olarak, bu çalışma ile RM ve YSA'nın yüzey pürüzlülüğü değerlerinin belirlenmesinde bir model olarak kullanılabilirliği gösterilmiştir. RM ve YSA modelleri, deneysel çalışmalardaki dezavantajları (ekonomik kayıp, zaman kaybı vb.) avantaj haline dönüştürebilmektedir. Ayrıca, deneyde yapılmayan, ara değerlerin alınabilmesi gibi çok önemli avantajlara sahiptir. Sonraki çalışmalarda parametre sayıları artırılıp, örneğin tırlama titreşim değerleri de dikkate alınarak çalışma alanı genişletilebilir.

Kaynaklar

1. Işık Y., Çakır M.C., Hız Çeliği Takımlar İçin Kesme Parametrelerinin Yüzey Pürüzlülüğüne Etkilerinin Deneysel Olarak İncelenmesi, *Teknoloji*, 2001; Sayı 1-2, 111-118.
2. Taşdemir Ş., Neşeli S., Sarıtaş İ., Yıldız S., Prediction of surface roughness using artificial neural network in Lathe. *CompSysTech'08*, Gabrovo, Bulgaristan, 2008.
3. Benardos, P.G., Vosniakos, G.C., Predicting surface roughness in machining: a review. *Int. J. Mach. Tools Manuf.* 2003; 43, 833-844.
4. Petropoulos, G.P., Vaxevanidis, N.M., Pandazaras, C.N., Antoniadis, A.A., Multi-parameter identification and control of turned surface textures. *Int. J. Adv. Manuf. Technol.* 2006; 29, 118-128.
5. Tasdemir Ş., Neşeli S., Yıldız S., Prediction of surface roughness on turning with Artificial Neural Network. *Journal of Engineering and Architecture Faculty of Eskişehir Osmangazi University* 2009; 22(9), 65-75.
6. Diniz, A.E., Micaroni, R., Cutting conditions for finish turning process aiming: the use of dry cutting. *Int. J. Mach. Tools Manuf.* 2002; 432, 899-904.
7. K. Dincer, Ş. Tasdemir, Ş. Baskaya, B. Z. Uysal, Modeling of the effects of length to diameter ratio and nozzle number on the performance of counterflow Ranque-Hilsch vortex tubes using artificial neural networks. *Applied Thermal Engineering*, 2008; 28, 2380-2390.
8. Fındık T., Tasdemir Ş., Sahin İ., The use of artificial neural network for prediction of grain size of 17-4 pH stainless steel powders. *Scientific Research and Essays*, 2010; 5(11), 1274-1283.
9. Tasdemir, S., Sarıtaş, I., Ciniviz, M., Cinar, C. ve Allahverdi, N., Application of artificial neural network for definition of a gasoline engine performance. 4th International Advanced Technologies Symposium, Konya, Turkey, 1030-1034, 28-30 Sept, 2005.
10. Abburi, N.R., Dixit, U.S., A knowledge-based system for the prediction of surface roughness in turning process. *Rob. Comp. Integr. Manuf.* 2006; 22, 363-372..

11. Erzurumlu, T., Oktem, H., Comparison of response surface model with neural network in determining the surface quality of moulded parts. *Mater. Des.* 2007; 28, 459–465.
12. J. Paulo Davim, V.N. Gaitonde, S.R. Karnik, Investigations into the effect of cutting conditions on surface roughness in turning of free machining steel by ANN models, *journal of materials processing technology* 2008; 205, 16–23..
13. Lu C., Study on prediction of surface quality in machining process. *Journal of materials processing technology*, 2008; 205, 439–450.
14. Neşeli S., Yıldız S., Tornalamada Yaklaşma Açısı ve Talaş Açısına Bağlı Tırlama Titreşimlerinin Yüzey Pürüzlülüğüne Etkileri, *Politeknik Dergisi*, 2007; 10 (4), 383-389.
15. Neşeli S., Yıldız S., Türkeş E., Optimization of tool geometry parameters for turning operations based on the response surface methodology, *Measurement*, 2011; 44, 580-587.
16. Neşeli S., Tornalamada takım geometrisi ve tırlama titreşimlerinin yüzey pürüzlülüğüne etkileri, Yüksek Lisans Tezi, S.Ü. Fen Bilimleri Enstitüsü Konya, 2006.
17. Asiltürk İ., Cunkaş M., Modelling and prediction of surface roughness in turning operations using artificial neural network and multiple regression method, *Expert Systems with Applications* 2011; 38, 5826-5832.
18. Huang L., Chen J. C. A multiple regression model to predict in-process surface roughness in turning operation via accelerometer. *Journal of Industrial Technology*, 2001; 17, 1-8.