

YAPAY SINİR AĞI YAKLAŞIMI İLE TORNALAMADA YÜZEY PÜRÜZLÜLÜĞÜNÜN TAHMİN EDİLMESİ

Süleyman NEŞELİ¹, Şakir TAŞDEMİR¹, Süleyman YALDIZ¹

ÖZET: Bu çalışmada, tornada takım geometrisinin yüzey pürüzlülüğüne etkisi incelenmiştir. Bunun için üniversal torna tezgâhında değişik yaklaşma açıları ve talaş açıları ile kuru kesme şartlarında, AISI 1040 çeliği üzerinden 0.5 mm derinliğinde talaş kaldırılarak 27 numune işlenmiş bu işlemde sonra yüzey pürüzlülük değerleri MAHR MI Perthometer ile ölçülmüştür. Yapılan deneylerde elde edilen veriler bir Yapay Sinir Ağının (YSA) eğitiminde kullanılmıştır. YSA modellemesinde giriş parametreleri; uç radyüsü (r) yaklaşma açısı (K), talaş açısı (γ) ve çıkış parametresi; yüzey pürüzlülüğü (R_a) olarak belirlenmiştir. Bu modelleme ile yüzey pürüzlülük değerleri tahmin edilmiştir. YSA, Centrino Duo 1.83 GHz işlemcili Windows XP işletim sistemli bir donanıma sahip bilgisayarda MATLAB 7 programı kullanılarak tasarlanmıştır. Deneysel sonuçlarla YSA sonuçları istatistiksel olarak karşılaştırıldığında, tasarlanan modelin başarılı bir şekilde uygulandığı ve deney sonuçlarına yakın sonuçlar verdiği görülmüştür.

ANAHTAR KELİMELEER: Takım Geometrisi, Yüzey Pürüzlülüğü, Yapay Sinir Ağları.

PREDICTION OF SURFACE ROUGHNESS ON TURNING WITH ARTIFICIAL NEURAL NETWORK

ABSTRACT: In this study, a surface roughness prediction model using artificial neural network (ANN) is developed. For this purpose various machining operations are made on a universal lathe in dry cutting conditions using various insert geometries of 27 samples. At the end of the cutting operations, surface roughness has been measured using MAHR MI Perthometer. After experimental study, to predict the surface roughness, an artificial neural network (ANN) is developed using the data obtained. In modelling of ANN; tool nose radius (r), approach angle (K), rake angle (γ) have been used as input parameters where the output parameter is surface roughness (R_a). The ANN has been designed on a PC, with a Centrino Duo 1.83 GHz processor and Windows XP operation system, by using Matlab 7 software. Statistical comparisons of the experimental data against ANN results show that the result of ANN model is resembled to ANN results very closely.

KEYWORDS: Tool geometry, Surface Roughness, Artificial Neural Network.

¹ Selçuk Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Kampüs 42075 KONYA

I. GİRİŞ

Talaşlı imalat işlemlerinde en önemli husus, işlemin mümkün olan en düşük maliyetle, arzu edilen kalitede gerçekleşmesidir. Endüstride tornalama işlemi en önemli üretim süreçlerinin başında gelir. Tornalama sonucu elde edilmiş parçaların kalitesi, toplam ürün kalitesini etkileyen bir faktördür. Dolayısıyla bu tür parçalarda kalite seviyesini yükseltmek zorunlu hale gelmiştir. İyi işlenebilir bir malzemenin kısa sürede, yüksek talaş hacmiyle işlenmesi ve yeni oluşan yüzeyin kaliteli olması hedeflenir [1]. Tornalama işlemiyle üretilen ürünlerde aranan özellikler içinde yüzey pürüzlülüğü, malzemenin maliyetini, kalitesini, aşınma direncini, yorulma mukavemetini, sürtünme katsayısını, yağlamayı ve korozyon direncini etkileyen başlıca etkidir. Bu yüzden birbirleriyle çalışan yüzeylerin, hatta birbirleriyle hiç ilişkisi olmayan yüzeylerin yüzey kalitelerinin değerlendirilmesine ve yüzey pürüzlülüklerinin ölçülmesine ihtiyaç duyulmaktadır.

Sadece operatörün tecrübesi gözetiminde yapılacak işlemlerde, yetersiz bilgi ve beceri eksikliği düşünülünce ulaşılmak istenen yüzey pürüzlülüğü değeri hayal olacaktır. Bu yüzden istenen yüksek performanslı kesme ve yüzey pürüzlülüğüne ulaşabilmek, tecrübenin yanında uygun kesme koşullarının sağlanmasıyla mümkündür. Bu amaçla günümüzde imalat sanayi yüzey pürüzlülüğü karakteristiği ve değerini tahmin etmek için yoğun çaba sarf etmektedirler.

Literatürde yüzey pürüzlülüğünün tahmin edilmesi için kullanılan en yaygın dört yöntem şunlardır [2].

- Çoklu regresyon analizi,
- Matematiksel modelleme,
- Bulanık küme tabanlı teknikler
- YSA modellemesi.

Yüzey pürüzlülüğü mekanizmasının modellenmesi, esasen talaş kaldırma işlemine bağlı karmaşık bir süreçtir. Bu yüzden analitik olarak pürüzlülük değerinin bulunması oldukça zordur [3, 4]. Ama yine de ortalama yüzey pürüzlülüğünü (R_a) bulabilmek için aşağıda verilen denklem (1) kullanılmaktadır [5];

$$R_a = \frac{1000f^2}{32r} \quad (\mu m) \quad (1)$$

Burada f ilerleme (mm/dev) ve r (mm) takım uç radyüsüdür. Her ne kadar bu formülün pürüzlülüğü teorik olarak hatasız bir şekilde hesaplayacağı düşünülse de gerçekte sürece etki eden titreşim ve takım-talaş ara yüzeyindeki sürtünmeden meydana gelen yapışmalar gibi etkenlerin ihmal edilmiş olduğu, gözden uzak tutulmamalıdır.

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 modellenemeyen veya çözülmesi mümkün olmayan karmaşık, lineer olmayan problemleri çok kolay çözülebilmekte, yukarıda sayılan bu tür kısıtlamaları ve yetersizlikleri gidererek çok başarılı bir şekilde kullanılmaktadır.

YSA insan beyninin sinir ağlarını taklit eden, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan, örneklerden genellemeler yaparak öğrenme yolu ile yeni bilgiler türetebilme, keşfedebilme ve oluşturabilme yeteneğine sahip bilgisayar yazılımlarıdır. 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 işleminde değişken takım geometrisine bağlı olarak yüzey pürüzlülüğü değeri (R_a) tahmini için bir YSA yaklaşımı sunulmuştur. Bunun için üç takım geometrisi değişkeni kullanılarak Çizelge 1'de verilen kesme şartlarında tornalama işlemi gerçekleştirilmiştir. Daha sonra deneyde ölçülen pürüzlülük değerleri ile YSA yaklaşımı ile elde edilen değerler arasındaki tutarlılığa bakılarak, YSA'nın istenilen pürüzlülük değerlerinin oluşturulmasında bir öngörü aracı olabilirliği araştırılmıştır.

Çizelge 1. Kesme koşulları [14]

Takım uç radyüsü (r)	0,4	0,8	1,2
Yaklaşma açısı (κ)	60°	75°	90°
Talaş açısı (γ)	-3°	-6°	-9°
Takım sarkma miktarı (L)	30 mm		
Yardımcı talaş açısı (γ_x)	-6°		
Talaş derinliği (d)	0,5 mm		
Devir sayısı (n)	1200 rpm.		
Kesme hızı (V_c)	150 m/min.		
İlerleme miktarı (f)	0,15 mm/rev.		

II. YÖNTEM

II.1 Deneysel Çalışma

Deneysel çalışmada, dinamik kesme şartları altında takım geometrisine bağlı olarak meydana gelen yüzey pürüzlülüğünün incelenmesinde tam Faktöriyel Tasarım (TFT) yöntemiyle üç seviyeli üç faktörlü deney yapısı kullanılarak 27 farklı ölçüm yapılmıştır. Yapılan deneylerde farklı negatif talaş açılı ($\gamma=-3^\circ, -6^\circ, -9^\circ$) takım tutucular kullanılmış, kullanılan tutucuya uygun farklı uç radyüslü ($r=0,4-0,8-1,2$ mm) takımlarla, belirlenen yaklaşma açılarında ($\kappa=60^\circ, 75^\circ, 90^\circ$) AISI 1040 imalat çelikleri üzerinde kuru kesme işlemi gerçekleştirilmiştir. Malzeme boyutları $\varnothing 40 \times 250$ mm olarak alınmıştır. Kesici uçlar bir sefer kullanılarak iki punta arasına bağlanan her bir numunenin gezer puntaya yakın tarafından 20 mm'lik boy torna edilmiştir. İşlenen numunelerin yüzey pürüzlülük değerlerini ölçmek için Mahr Perthometer M1 pürüzlülük ölçüm cihazı kullanılmıştır. Sinir ağının eğitilmesi deneyler sonucunda elde edilen bu verilerle yapılmıştır.

Deneyde üç farklı uç yarıçapına sahip Böhler LC215B kalitesindeki TIC kaplı CNMG 120404-BF, CNMG 120408-BF, CNMG 120412-BF kesici takımlar ve bu takım formuna uygun Takımsaş firmasının ürettiği PCLNR/L 2020 K12 AA3, PCLNR/L 2020 K12 AA6, PCLNR/L 2020 K12 AA9 numaralı takım tutucuları kullanılmıştır.

II.2. YSA Modellemesi

YSA'nın eğitilebilmesi ve hedef çıktılara ulaşılması için çok sayıda girdi ve girdilere ilişkin çıktı dizisine gereksinim duyulur. Bu veri dizilerine eğitim ve test seti adı verilir. Öğrenme sürecinden sonra test verileri kullanılarak tasarlanan ağın nasıl sonuçlar verdiğinin görülmesi için test işlemi gerçekleştirilir. Öğrenme sürecinde yapay sinir ağının istenen çıktıları üretecek şekilde ağ içindeki ağırlıkların düzenlenmesini sağlayan mekanizma öğrenme algoritması (learning algorithm) olarak adlandırılır [9].

Literatürde birçok YSA mimarisi bulunmaktadır. Bu çalışmada, bunlardan tahmin amaçlı olarak, mühendislik uygulamalarına uygun olan ileri beslemeli çok katmanlı geri yayılım (MLN) algoritması kullanılmıştır [15, 16].

YSA'nın yapısına bağlı olarak kullanılan, step activation, sigmoid ve hyperbolic tangent adında değişik aktivasyon fonksiyonları mevcuttur. En yaygın olarak kullanılan sigmoid aktivasyon fonksiyonudur ve denklem 2 ve 3'de gösterilmektedir.

$$net_j^k = \sum_i w_{ij}^{k-1,k} o_i^{k-1} \quad (2)$$

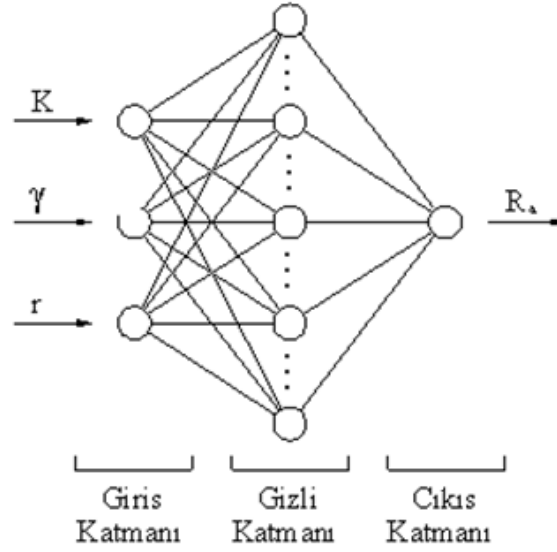
ve

$$o_j^k = f(net_j^k) = \frac{1}{1 + \exp\left(-\frac{net_j^k - \theta_j^k}{\theta_o}\right)} \quad (3)$$

Bu formülde; o_i^{k-1} ($k-1$). katmanın i . neuron'un çıkışıdır. $w_{ij}^{k-1,k}$ ise ($k-1$). katmanın i . neuron'unu k . katmanın j . neuron'una bağlayan ağırlıktır, net_j^k ve θ_j^k sırasıyla k . katmanın j . neuron'un giriş ve eşik değerleridir. Ve θ_o sigmoid fonksiyonunun ateşlemesidir [17-19].

YSA'nın çalıştırılmasında kullanılan bilgisayar, Centrino Duo 1.83 GHz Intel işlemci, 1GB RAM donanım özelliklerine sahiptir. Bu verilerle eğitim ve test için yazılım olarak Matlab 7 programı ve istatistiksel analiz için SPSS 15 paket programı kullanılmıştır.

Tasarlanan YSA için giriş parametreleri; uç radyüsü (r) yaklaşma açısı (K), talaş açısı (γ) ve çıkış parametresi; yüzey pürüzlülüğü (Ra) olarak belirlenmiştir. Geliştirilen bu üç giriş tek çıkışlı ve gizli katmanda 10 nörondan oluşan YSA'nın genel yapısı Şekil 1'de verilmiştir.

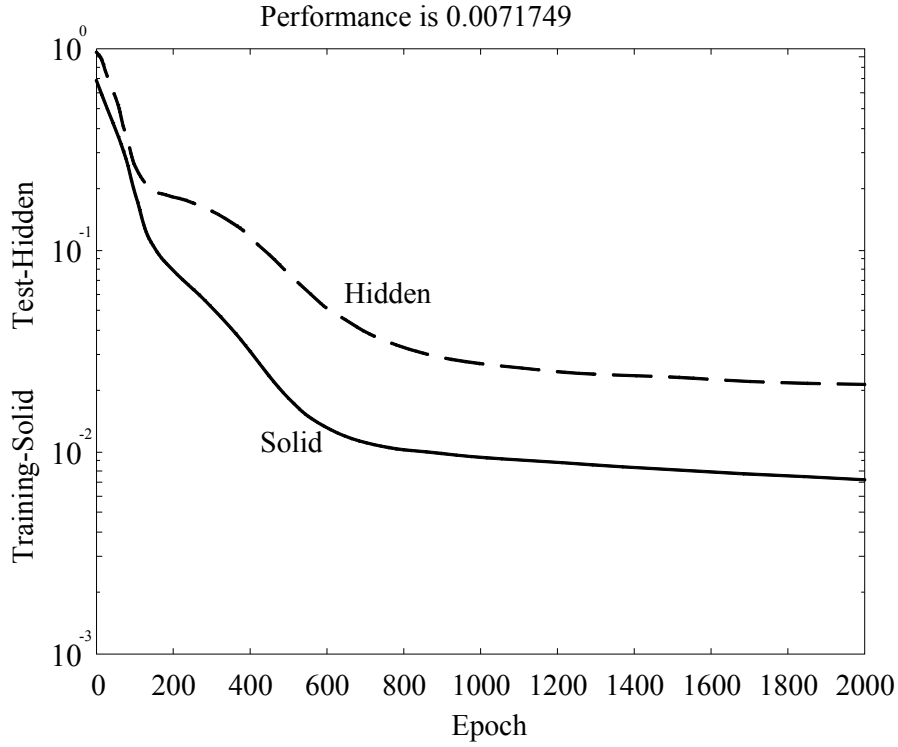


Şekil 1. Tasarlanan YSA ağ yapısı

DeneySEL çalışmalarından elde edilen veriler eğitim ve test verileri olarak ayrılmış ve bunlar denklem (4) kullanılarak 0-1 arasında normalize edilmiştir.

$$V_N = \frac{V - V_{\min}}{V_{\max} - V_{\min}} \quad (4)$$

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. Rasgele seçilen bu 27 veriden 19 tanesi eğitim, 9 tanesi de test işlemi için kullanılmıştır. YSA' da eğitim hızı 0.5, MLN Levenberg-Marquardt (trainlm) algoritması ve sigmoid aktivasyon fonksiyonu seçilmiştir. Gizli katmandaki nöron sayıları için 5, 10, 20, 30, 50 nöron olması durumu, YSA modeli içinde 1000, 2000, 2500, 4000 çevrim boyunca denenmiş, elde edilen sonuçlara göre 10 nöronlu gizli katmanın daha iyi sonuç verdiği görülmüştür. Matlab yazılımında 2000 dönem işleminden sonra elde edilen eğitim ve test performans hata grafiği Şekil 2'de gösterilmiştir. Buna göre oluşturulan ağda 2000 çevrim sayısı sonucunda eğitim hatası olarak 0,0071749 (ortalama karesel hata-MSE) değeri elde edilmiştir.



Şekil 2. 2000 çevrim sayısı için eğitim ve test hata grafiği

III. SONUÇLAR VE ÖNERİLER

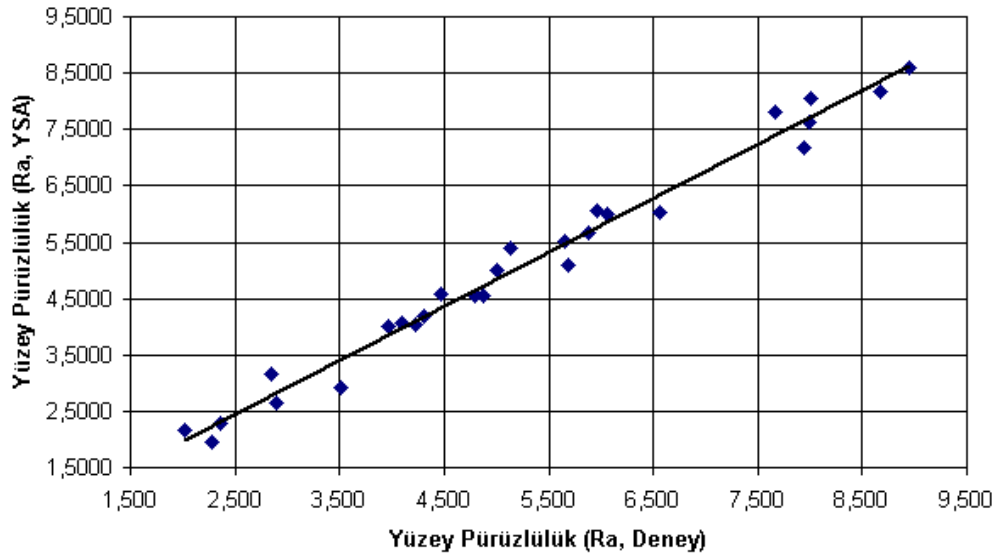
Bu çalışmada, tornalamadan elde edilen deneysel veriler kullanılarak, YSA yaklaşımı ile yüzey pürüzlülüğü tahmin edilmiştir.

YSA, deneysel çalışmalardaki ekonomik kayıp, zaman kaybı, ölçü aletlerinin hassasiyetlerinden kaynaklanan ölçüm hataları, ortamın sıcaklığının aletleri etkilemesi veya zarar görebilmesi gibi hususlardan kaçınabilmeyi sağlamaktadır. Ayrıca ara değerlerin alınabilmesi gibi deneyde elde edilemeyen sonuçlara ulaşılabilmesini de sağlayabilmektedir.


Çizelge 2. Deneysel-YSA verileri Levene testi sonuçları

	Levene Testi	
	F	Anlam Düzeyi
Ra (Deneysel-YSA)	0,000	0,994

SPSS istatistiksel paket programında yapılan Levene testi sonucunda, Deney-YSA güven değerleri %99 seviyesinde elde edilmiştir. Levene testine göre deneyde elde edilen veriler ile YSA kullanılarak elde edilen veriler arasında istatistiksel olarak belirgin bir farkın olmadığı sonucu elde edilip, iki grup verinin uyumlu olduğu görülmüştür (Çizelge 2). Ayrıca YSA' dan tahmin edilen sonuçlar ile yapılan deney çalışması verilerinin karşılaştırmalı kare grafiği Şekil 3'te görülmektedir. Bu diyagram geliştirilen modelin çok iyi olduğu ve güvenle kullanılabileceğini göstermektedir. Korelasyon katsayısı $R=0,9906$ bulunmuştur. Deney verileri ile YSA'dan elde edilen sonuçlar arasında anlamca fark olmadığı ispatlanmaktadır. Buna göre iki grup veri (Deney-YSA) arasında kuvvetli bir ilişki vardır sonucuna varılmıştır. Grafikler incelendiğinde deneylerde elde edilen verilerin YSA daki sonuçlara benzer olduğu görülmektedir (Şekil 4).



Şekil 3. Karşılaştırmalı Deney-YSA sonuçlarının Kare diyagramı



Şekil 4. Deney-YSA verileri karşılaştırmalı sonuç grafiği

Sonuç olarak; bu çalışmayla, yüzey pürüzlülüğü değerlerinin YSA ile modellenmesi ile etkin sonuçlar alınabileceği ve arzu edilen yüzey pürüzlülüğüne ulaşmada en uygun kesme koşullarının tespiti için YSA yaklaşımının kullanılabilirliği gösterilmiştir. Yapılan bu çalışma bu türden diğer çalışmalar için bir temel oluşturabilecektir. İzleyen çalışmalarda, parametre sayıları artırılıp, örneğin tırlama titreşim değerleri de dikkate alınarak, çalışma alanı genişletilebilir. Ayrıca diğer yapay zeka teknikleri de bu çalışmada kullanılarak daha başarılı sonuçlar elde edilebilir.

IV. KAYNAKLAR

- [1] Y. Işık, M.C. Çakır, “Hız Çeliği Takımlar İçin Kesme Parametrelerinin Yüzey Pürüzlülüğüne Etkilerinin Deneysel Olarak İncelenmesi”, *Teknoloji Dergisi*, Sayı 1-2, ss. 111-118, 2001.
- [2] Ş. Taşdemir, S. Neşeli, İ. Sarıtaş, S. Yıldız, “Prediction of surface roughness using artificial neural network in Lathe”, *CompSysTech’08*, Gabrovo, Bulgaristan, 2008.

- [3] P.G. Benardos, G.C. Vosniakos, “Predicting surface roughness in machining: a review”, *Int. J. Mach. Tools Manuf.* 43, pp. 833–844, 2003.
- [4] G.P. Petropoulos, N.M. Vaxevanidis, C.N. Pandazaras, A.A. Antoniadis, “Multi-parameter identification and control of turned surface textures”, *Int. J. Adv. Manuf. Technol*, Vol. 29, pp. 118–128, 2006.
- [5] G. Boothroyd, W.A. Knight, “*Fundamentals of Machining and Machine Tools*”, Marcel Dekker, New York, 1989.
- [6] A.E. Diniz, R. Micaroni, “Cutting conditions for finish turning process aiming: the use of dry cutting”, *Int. J. Mach. Tools Manuf.*, pp. 432, 899–904, 2002.
- [7] N. Allahverdi, “*Uzman Sistemler, Bir Yapay Zeka Uygulaması*”, Atlas Yayın Dağıtım, İstanbul, 2002.
- [8] E. Öztemel, “*Yapay Sinir Ağları*”, Papatya Yayıncılık, İstanbul, 2003.
- [9] S. Tasdemir, I. Saritas, M. Ciniviz, C. Cinar ve N. Allahverdi, “Application of artificial neural network for definition of a gasoline engine performance”, 4th International Advanced Technologies Symposium, Konya, Turkey, pp. 1030-1034, 28-30 Sept, 2005.
- [10] N.R. Abburi, U.S. Dixit, “A knowledge-based system for the prediction of surface roughness in turning process”, *Rob. Comp. Integr. Manuf.*, Vol. 22, pp. 363–372, 2006.
- [11] T. Erzurumlu, H. Oktem, “Comparison of response surface model with neural network in determining the surface quality of moulded parts”, *Mater. Des.*, Vol. 28, pp. 459–465, 2007.
- [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*, Vol. 205, pp. 16–23, 2008.
- [13] C. Lu, “Study on prediction of surface quality in machining process”, *Journal of Materials Processing Technology*, Vol. 205, 439–450, 2008.
- [14] S. Neşeli, S. Yıldız, “Tornalamada Yaklaşma Açısı ve Talaş Açısına Bağlı Tırlama Titreşimlerinin Yüzey Pürüzlülüğüne Etkileri”, *Politeknik Dergisi*, Cilt.10, Sayı. 4, ss.219-227, 2007.

- [15] M.A. Akçayol, C. Çınar, H.İ. Bülbül ve A. Kılıçarslan, “Artificial neural network based modeling of injection pressure in diesel engines”, *World Scientific and Engineering Academy and Society (WSEAS) Transactions on Computers*, ISSN 1109-2750, 3(5), pp. 1538-1544, 2004.
- [16] A. Şencan, “Artificial intelligent methods for thermodynamic evaluation of ammonia–water refrigeration systems”, *Energy Conversion and Management*, Vol. 47, pp. 3319-3332, 2006.
- [17] G. Scalabrin, M. Condosta ve P. Marchi, “Mixtures flow boiling: modeling heat transfer through artificial neural Networks”, *International Journal of Thermal Sciences*, Vol. 45, No. 7, pp. 664-680, 2006.
- [18] Y. Islamoglu ve A. Kurt, “Heat transfer analysis using ANNs with experimental data for air flowing in corrugated channels”, *International Journal of Heat and Mass Transfer*, 47, pp. 1361-1365, 2004.
- [19] C.S. Lee, W. Hwang, H.C. Park ve K.S. Han, “Failure of carbon/epoxy composite tubes under combined axial and torsional loading 1. Experimental results and prediction of biaxial strength by the use of neural networks”, *Composites Science and Technology*, Vol. 59, No. 12, pp. 779-1788, 1999.