



Şehmus Baday

Şırnak University, shmsbdy@hotmail.com, Şırnak-Turkey

<http://dx.doi.org/10.12739/NWSA.2016.11.1.2A0091>

**KÜRESELLEŞTİRME ISIL İŞLEMİ UYGULANMIŞ AISI 1050 ÇELİĞİN TORNALANMASINDA
ESAS KESME KUVVETLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ**

ÖZ

Bu çalışmada, kuru kesme şartlarında tornalanmış ve küreselleştirme ısıl işlemi uygulanmış AISI 1050 çeliğinin esas kesme kuvvetlerini tahmin etmek için yapay sinir ağları (YSA) modeli oluşturulmuştur. Oluşturulan YSA modelinde kesme hızı, ilerleme ve ısıl işlem süreleri bağımsız değişkenler olarak seçilirken esas kesme kuvvetleri bağımlı değişken olarak seçilmiştir. Bu modelin özellikleri; ağ tipi olarak ileri beslemeli geri yayıllımlı ağ tipi, üç adet eğitim algoritması TRAINLM, BFGS ve SCG, adaptasyon öğrenme fonksiyonu LEARNGD ve 1 adet gizli katmanda 10 nörondan 15 nörona kadar seçilip denenerek en iyi R^2 aranmıştır. Ayrıca transfer fonksiyonu olarak SIGMOID ve PURELINE transfer fonksiyonları seçilmiştir. Ortalama hatalar kareleri yöntemi kullanılarak esas kesme kuvveti için elde edilen YSA modelinde R^2 %99,832 elde edilmiştir. Deney sonuçları ve elde edilen YSA modelinin deney verilerini tahmin etmede başarılı olduğu görülmüştür.

Anahtar Kelimeler: Küreselleştirme Isıl İşlemi, Esas Kesme Kuvvetleri, Yapay Sinir Ağları, AISI 1050 Çeliği, Modelleme

**MODELLING OF MAIN CUTTING FORCES WITH ARTIFICIAL NEURAL NETWORK IN TURNING
OF SPHEROIDIZING HEAT TREATED AISI 1050 STEEL**

ABSTRACT

In this study, So as to estimate main cutting forces of AISI 1050 steel turned under dry cutting conditions and spheroidizing heat treated, a model of the artificial neural network (ANN) was made. The cutting speed, feed rate and heat treatment duration as independent variables and the main cutting forces as dependent variable were selected. The ANN model based on a forward feed with back-propagation learning, three training algorithms to be as TRAINLM, BFGS and SCG, adaption learning function being as LEARNGD and one underlayer include between 10 to 15 neurons which were selected to test for researching the best R^2 result. Furthermore, the SIGMOID and PURELINE were selected as transfer functions. The average square method used for main cutting forces of ANN. The R^2 result was 99.832%. The experimental results and ANN predictions were close to previous studies.

Keywords: Spheroidizing Heat Treatment, Main Cutting Forces, Artificial Neural Network, AISI 1050 Steel, Modelling



1. GİRİŞ (INTRODUCTION)

Çeliklerin mekanik özellikleri önemli ölçüde çeliğin mikroyapısındaki farklılıklardan dolayı değişir [1]. Mikroyapı farklılıkları, çeliklere çeşitli ısıl işlemler uygulanarak değiştirilebilir. Çeliklere uygulanan bu ısıl işlemler, çeliği işleyen takım ömrünü artırabilir ve işleme maliyetlerini azaltabilir. Mekanik özellikleri düşürücü nitelikte uygulanan bu ısıl işlemlerdeki amaç, yapıyı yumuşatıp takım ömrünü artırmak, kesme kuvvetlerini azaltmaktır [2]. Talaş kaldırma esnasında oluşan bu kesme kuvvetleri, ilerleme oranı, kesme hızı vb. işlenen malzemenin cinsine göre değişiklik göstermektedir. Kesme kuvvetlerini bilmek ve buna bağlı olarak kesici takımın ömrünün tahmin edilebilmesi takım tezgâh imalatçıları açısından oldukça büyük önem taşır [3 ve 6]. Bu sebeplerden dolayı kesici takıma ait uygun kesme parametrelerin belirlenmesi kesici takımın ömrünün uzamasına, istenilen yüzey kalitesinde iş parçasının üretilmesine olanak vermektedir.

Literatür araştırması sonucunda, kesme kuvvetleri, yüzey pürüzlük, takım aşınması, takım ucu sıcaklığı gibi değerlerin tahmin edilmesinde birçok tahmin tekniğinin kullanıldığı gözlemlenmiştir [7 ve 20]. Bu tahmin teknikleri; yüzey yanıt metodu [7], bulanık mantık [8], taguchi yöntemi [9], yapay sinir ağları [10 ve 20] ve çoklu regresyon modelleri [16 ve 20] şeklinde değerlerin tahmin edilmesinde sıklık ile kullanılmaktadır. Bu tahmin teknikleri kullanılarak başarılı tahminler elde edilmektedir. YSA ile ilgili yapılan çalışmalarda, çok katmanlı feedforward ağ tip ve bir den fazla eğitim algoritmaları karşılaştırılmıştır. Yapılan bu çalışmalar; burun yarıçapı, kesme hızı, ilerleme ve kesme derinliği giriş parametresi olarak seçilmiştir. Bu giriş parametrelerine bağlı olarak yüzey pürüzlülüğü, takım aşınması ve titreşim değerlerini çok katmanlı feedforward ağ yapısı kullanarak deney sonuçlarını tahmin etmişlerdir [11]. Bir diğer çalışmada, frezeleme işleminde kesme parametrelerine bağlı olarak pürüzlülük değerleri YSA ile elde edilmiştir [12]. Eğitim algoritması SCGA ve bir gizli katman, 5 nöronlu oluşan YSA modelinde kesme parametrelerine bağlı olarak yüzey pürüzlülük değerleri tahmin edilmiştir [13]. İki farklı eğitim algoritması kullanarak SCG ve LM yüzey pürüzlülük değerlerinin takım kaplama tipi, kesme hızı ve ilerleme değerlerine YSA ile tahmin etmişlerdir [14]. Çok katmanlı değişik kombinasyonları 3-1-1, 3-3-1, 3-6-1, 3-7-1, 3-1-1-1, 3-3-3-1, 3-6-6-1 ve 3-7-7-1 seçerek ağ modeli oluşturularak yüzey pürüzlü değerlerine en yakın değeri araştırmışlardır [15].

Mümkün olan en az yağlama sonucunda yüzey pürüzlülük değerini tahmin etmek için giriş parametrelerine bağlı olarak YSA modeli geliştirmişlerdir [16]. YSA ve lineer, çoklu lineer regresyon analizi ile karşılaştırılan çalışmalar da mevcuttur. Bu çalışmalar; yüzey pürüzlülüğü tahmini için regresyon ve YSA modeli seçilmiş [17], iş parçası ve takım arasındaki sıcaklık değerini tahmin etmek için YSA ve regresyon modeli selmiş regresyon sonucunun çok az miktarda küçük olduğunu bildirmişlerdir [18]. Yapılan diğer çalışmalarda ise kesme kuvveti tahmini için çoklu lineer regresyon analizi ve YSA modeli gerçekleştirilmiş ve YSA tahminlerinin daha iyi olduğu sonucuna varılmıştır [19]. Kesme kuvvetlerini tahmin etmede yapılan benzer bir çalışmada da SCG ve LM eğitim algoritması ve 3-7-1 ve 3-6-1 gizli katmanlar denenerek YSA modeli ve çoklu lineer regresyon modeli oluşturmuşlardır. Oluşturulan modellerde YSA modelinin daha iyi tahmin sonuçları vermiştir [20]. Yapılan bu çalışmalar ile YSA modelinin kesme kuvveti, yüzey pürüzlülüğü gibi değerleri tahmin etmede başarılı olduğu görülmüştür.



2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Bu çalışmayla, küreselleştirme ısıl işlemi uygulanmış AISI 1050 çeliğinin kesme hızı, ilerleme ve ısıl işlem süresine bağlı olarak kuru kesme şartlarında tornalanması sonucunda elde edilen esas kesme kuvvetleri değerlerinin YSA ile tahmin edilmesi hedeflenmektedir.

3. MATERYAL VE YÖNTEM (MATERIAL AND METHOD)

Esas kesme kuvvetleri ölçümlerinin yapılabilmesi için kimyasal bileşimi Tablo 1'de verilmiş olan AISI 1050 çeliği kullanılmıştır. Bu malzemeden esas kesme kuvvetleri deneylerinde kullanılacak Ø 30x200 mm boyutlarında numuneler hazırlanmıştır.

Tablo 1. AISI 1050 malzemesinin kimyasal bileşimi (ağırlıkça %)
(Table 1. The chemical composition of AISI 1050 material (weight %))


C	Si	Mn	P	S	Cr
0,52	0,28	0,81	0,009	0,022	0,08
Mo	Ni	Al	Cu	Sn	Fe
0,02	0,10	0,020	0,17	0,011	Kalan

Bu numuneler öncelikle 850°C'de 15 dakika östenitlenmiş ardından martensit fazı üretmek için su verilmiş ve daha sonra sırasıyla ayrı ayrı 700°C'de 15, 60 ve 180 dakika izotermal tavlama yapılarak ferritik matriste farklı ebat ve morfolojilere sahip küresel sementitler üretilmiştir. Numunelerin işleme deneylerinde ISO 3685'te belirtilen deney şartlarına uygun olarak SNMG formunda sementit karbür kesici takım ile buna uygun 75° yanaşma açısına sahip PSBNR 2525M12 formunda takım tutucu kullanılmıştır. İşleme malzemesine uygun CVD kaplı GC4215 kalitelisinde çift taraflı kesici takımı seçilmiştir. Kesici takım için üretici takım firmasının SNMG 120408 PM formlu talaş kırıcı geometrisi belirlenmiştir. Deneyler kuru kesme şartlarında CNC torna tezgâhında gerçekleştirilmiştir. Kesme kuvveti ölçümü için üç eksenel yönde ölçüm kapasitesine sahip Kistler 9275B tipi dinamometre kullanılmıştır. İşleme deneylerinde kesme parametreleri, takım üretici firması verileri ve ISO 3685'teki öneriler göz önüne alınarak, 175, 200, 225 ve 250 m/dak dört farklı kesme hızı, 0,16, 0,25 ve 0,40 mm/dev üç farklı ilerleme, 2,5 mm sabit talaş derinliği olarak seçilmiştir. Deneylerin tümünde aynı şartları oluşturmak için, her bir tornalama işlemi uygulanmasından önce yeni bir kesici takım kullanılmıştır. Deneyler sonucunda elde edilen esas kesme kuvvetleri değerlerini tahmin etmek için Matlab programındaki YSA bölümü kullanılarak oluşturulmuştur.

4. YAPAY SİNİR AĞLARI (ARTIFICIAL NETWORK)

YSA insan beynindeki biyolojik sinir sistemlerine gibi bir yöntemden ilham alınarak oluşturulan bir bilgi işleme sistemidir [21]. YSA çeşitli alanlarda, tanıma, tanımlama, sınıflandırma, konuşma, görme ve kontrol sistemleri dahil karmaşık fonksiyonları gerçekleştirmek için eğitilebilir. Bu işlemleri gerçekleştirmek için çeşitli eğitim algoritmalarından faydalanmaktadır. Geriye yayımlı olarak adlandırılan ileri beslemeli yapay sinir ağı yaygın olarak kullanılan eğitim algoritmalarından biridir [22]. Bu eğitim algoritmasında kullanılan tansig, logsig ve purelin olmak üzere üç adet transfer fonksiyonu mevcuttur. Ayrıca bu algoritmada çok katmanlı geri yayımlı model oluşturmak mümkündür. Dahası bu modellerin eğitilmesinde birçok eğitim fonksiyonu kullanılmaktadır; bunlardan bir kaç Levenberg-Marquardt (TRAINLM), Quasi-Newton metodu (BFGS) ve Scaled Conjugate Gradient (SCG) olarak adlandırılan eğitim fonksiyonlarıdır. Bir YSA modelini oluşturulan elemanların şematik gösterimi Şekil 1'deki gibidir. Deneylerden elde edilen parametreler giriş (Input) ile bir YSA

modeline girişi sağlanır ve daha sonra gizli katmanlarda (Hidden Layer) çeşitli eğitim algoritmaları ve transfer fonksiyonları ile sonuçların tahmin edildikten sonra çıkış katmanına (Output Layer) aktarılarak sonuçlar (output) elde edilir.



Şekil 1. Basit bir YSA modeli
(Figure 1. A basic ANN Model)

Bir YSA ağ yapısının en küçük elemanı nöron olarak adlandırılır. Giriş parametreleri ağırlıklar "W" ile çarpılmakta ve dengeleme "b" değerleri eklenerek her bir nöronun değerini oluşturmaktadır. Transfer fonksiyonu ile bir diğer nöronlara aktarılmakta ve ağırlık değeri ile çarpılıp dengeleme değerleri eklenerek hesaplanan en son değer yani çıkış değerlerini oluşturmaktadır (Şekil 1).

Her bir ağın değeri Eşitlik 1 ile ifade edilmektedir:

$$NET_i = \sum_{j=1}^n w_{ij} \cdot x_j + w_{bi} \quad (1)$$

Bu eşitlikte "i" satır numarası, "j" sütun numarasını temsil etmektedir. "w" her bir nöron için ağırlık değeri, "x" giriş değişkenlerini ve "w_b" değeri ise dengelemeyi temsil etmektedir. Her bir ağın değeri bir diğer gizli katmana veya çıkış değerine transfer fonksiyonları ile aktarılmaktadır. Bu transfer fonksiyonları tansig, logsig ve pureline'dır. Bu fonksiyonlar aşağıdaki Eşitlik 2 ve 4 ile ifade edilmektedir [22].

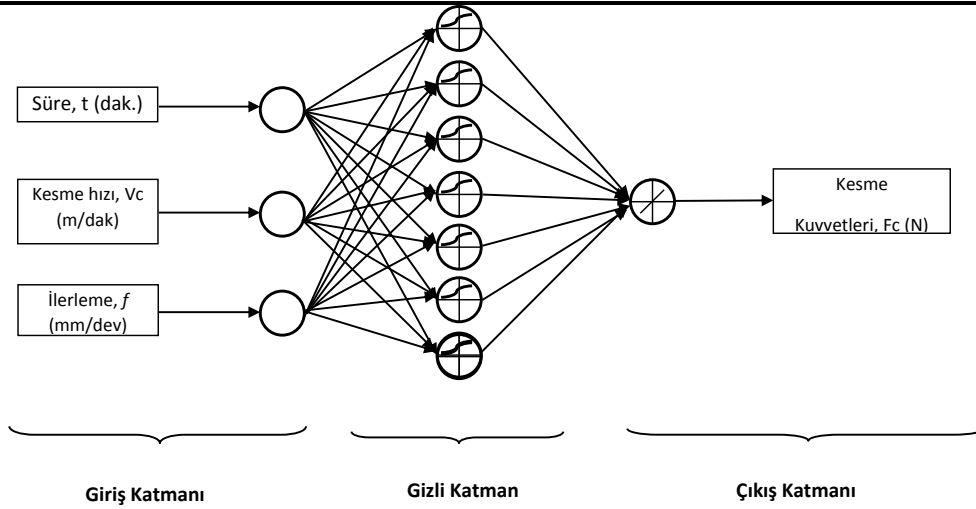
$$\text{logsig}(n) = \frac{1}{(1 + e^{-NET_i})} \quad (2)$$

$$\text{tansig}(n) = \frac{2}{(1 + e^{-2NET_i})} - 1 \quad (3)$$

$$\text{purelin}(n) = NET_i \quad (4)$$

4.1. Oluşturulan YSA Modeli (YSA Model Created)

Esas kesme kuvvetleri tahmini için oluşturulan YSA modeli Matlab programlama dilinde Neural Network Toolbax menüsü altında yapılmıştır. Oluşturulan ağların özellikleri; ağ tipi ileri beslemeli geri yayınlı (Feed-forward backprop), adaptasyon öğrenme fonksiyonu LEARN_GDM, gizli katman sayısı 1, katmandaki nöron sayısı 10'dan 15 nörona kadar, transfer fonksiyonları LOGSIG ve PURELIN ile eğitim fonksiyonları TRAINLM, BFGS ve SCG, performans fonksiyonu ortalama hatalar karesi MSE seçilerek modeller oluşturulmuştur. Giriş ve çıkış parametrelerine bağlı oluşturulan YSA modelinin şematik gösterimi Şekil 2'deki gibidir.



Şekil 2. Oluşturulan YSA modeli
(Figure 2. YSA model created)

Şekil 2’de giriş katmanında kesme hızı, ilerleme ve ısıl işlem süresi girşi parametreleri seçilerek, bir ileri geri yayıllımlı ağ tipinde, bir gizli katmanda, 10 nörondan 15 nörona kadar ve M. Nalbant ve ark. ve F. Kara ve arkadaşları da LM ve SCG eğitim fonksiyonlarını tercih ederken bu çalışmada onlara ek olarak BFGS eğitim fonksiyonu eklenerek kombinasyonlar denenerken deney sonuçlarına en yakın MSE değeri Tablo 2’de verilmiştir. En iyi MSE değeri LM eğitim fonksiyonu, 15 nörona sahip YSA modelinde elde edilmiştir.

Tablo 2. Oluşturulan YSA modelleri için MSE sonuçları
(Table 2 The result of MSE for YSA model created)

No	Nöron Sayısı	Eğitim Performansı	Test Performansı	Geçerlilik	Tümü	Eğitim Fonksiyonu
1	10	0,92732	0,94738	0,38588	0,88709	SCG
2	11	0,97121	0,90235	0,97396	0,94873	SCG
3	12	0,9978	0,96376	0,97401	0,99376	SCG
4	13	0,9877	0,97989	0,97317	0,98445	SCG
5	14	0,99933	0,99397	0,99971	0,99869	SCG
6	15	0,64203	0,68117	0,97871	0,68668	SCG
7	10	0,89132	0,91805	0,97483	0,90939	BFGS
8	11	0,97637	0,97129	0,93594	0,96852	BFGS
9	12	0,98768	0,83756	0,81913	0,96526	BFGS
10	13	0,97933	0,8332	0,99938	0,96798	BFGS
11	14	0,99884	0,97554	0,9089	0,99063	BFGS
12	15	0,94131	0,97281	0,96108	0,93997	BFGS
13	10	0,98879	0,9934	0,99596	0,98735	LM
14	11	0,99927	0,98045	0,99681	0,99456	LM
15	12	0,99941	0,98908	0,9952	0,99244	LM
16	13	0,99991	0,99908	0,99665	0,99532	LM
17	14	0,99915	0,99706	0,92361	0,9971	LM
18	15	0,99996	0,98279	0,99892	0,99832	LM

En iyi MSE değerine göre YSA modelinde gizli katmandaki her bir nörona iletilen ağırlık ve dengeleme oranları aşağıdaki Tablo 3’de verilmiştir.

Tablo 3. Giriş katmanındaki ağırlık oranları ve dengeleme değerleri
(Table 3. The values of weight rates and bias in input layer)

i	$N_i = \frac{2}{(1+e^{-(W_1V+W_2f-W_3t-b_i)})}$			
	W_1	W_2	W_3	b_i
1	-2,6892	-2,6364	0,2668	3,1697
2	2,4218	1,34170	1,7332	-3,0175
3	0,24105	0,83403	3,23	-2,5567
4	2,3958	-2,4042	-0,75149	-2,0116
5	-2,7894	-2,1412	0,17836	1,4043
6	0,59682	-0,15959	3,3972	-0,99223
7	-0,54554	2,6521	-1,8967	0,74673
8	3,3388	0,17304	0,78352	-0,13237
9	-1,585	-2,68	0,36723	-0,65764
10	-0,32759	-3,18	-1,2642	-0,89453
11	-1,0057	2,9194	-1,961	-0,58722
12	2,7449	-0,55588	2,2004	1,745
13	0,98476	-0,66882	3,2338	2,3694
14	-1,7382	1,9633	-1,879	-3,0673
15	-1,7081	-1,3574	2,6376	-3,4694

Giriş parametrelerinin ağırlıklar ile çarpılarak ve dengeleme değerinin eklenmesi ile gizli katmandaki nöronun değerini oluşturmaktadır. Elde edilen bu değer logsig transfer fonksiyonu ile gizli katmana aktarılmaktadır. Buradan da çıkış katmanındaki gizli nöron değerlerini oluşturmak için Tablo 4'deki ağırlık değerleri ile çarpılmakta ve bias değerinin eklenmesi ile buradaki nöron değerleri elde edilmektedir. Buradan çıkış değerine purelin transfer fonksiyonu ile aktarılarak tahmin edilen çıkış değerlerini oluşturmaktadır.

Tablo 4. Çıkış katmanındaki ağırlık oranları ve dengeleme değeri
(Table 4. The values of weight rates and bias in output layer)

W_1	W_2	W_3	W_4	W_5	W_6	W_7	W_8	b_j
-0,525	-0,156	0,445	0,151	0,199	-0,162	0,155	-0,171	
W_9	W_{10}	W_{11}	W_{12}	W_{13}	W_{14}	W_{15}		
-0,329	-0,201	0,223	-0,091	0,218	0,164	0,121		

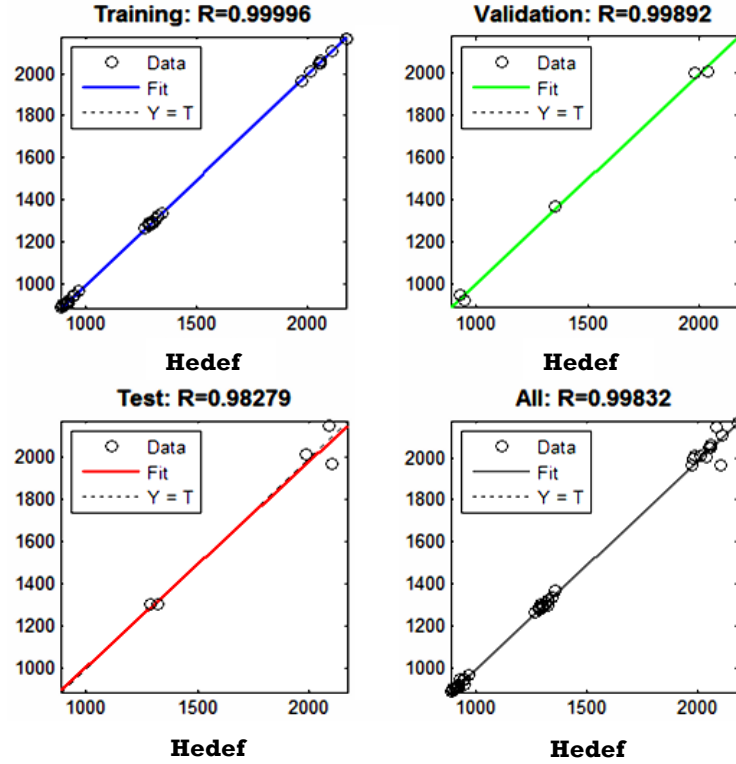
Sonuç olarak elde edilen Eşitlik 5'deki F_c formülleri ile tahmin deney sonuçları değerleri yaklaşık olarak tahmin edilebilmektedir.

$$F_c = \frac{1}{(1+e^{-(W_j \cdot N_i + b_j)})} \quad (5)$$

5. SONUÇ VE ÖNERİLER (CONCLUSION AND RECOMMENDATIONS)

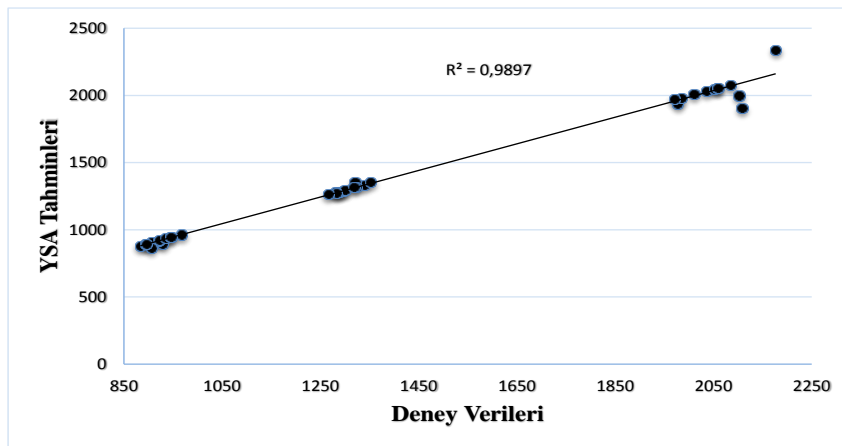
Bu çalışmada, deneyler sonucunda elde edilen esas kesme kuvvetleri kesme hızı, ilerleme hızı ve ısıl işlem süresi parametrelerine bağlı olarak YSA modeli ile tahminler yapılmıştır. Deney sonuçlarını en yakın tahmin eden YSA modeli grafikleri Şekil 3'de verilmiştir. Esas kesme sonuçlarını oluşturulan YSA ile tahmin edilerek MSE sonuçlarına göre en iyi değer Tablo 3'de verilmiştir. Tablo 3'deki en iyi MSE değerine göre; ağ modelinin eğitimi (Training) $R=0,99996$, eğitim verilerine dahil edilmeyen ve rastgele seçilen test (Test) verileri $R=0,98279$ oranında oldukça iyi bir oranda eğildiği görülmektedir (Şekil 3). Eğitilen değerler ve test verilerinin doğrulaması (Validation) $R=0,99892$ oranında örtüşmektedir. Tüm (All) sonuçların R kare değerinin sonucu $0,99832$

oranında ağın tahmin sonuçlarına yaklaşımlı yüksek güvenilirlik düzeyinde sağlanmıştır.



Şekil 3. YSA performans çıktıları
(Figure 3. Output of YSA performans)

Şekil 4'deki grafik incelendiğinde YSA tahmin değerlerinin büyük çoğunluğu eğilim çizgisi etrafında toplandığı görülmektedir. Bu durum deney verilerinin YSA tarafından en küçük kareler yöntemine göre %98,97 değerinde açıklanabildiğini göstermektedir. Sonuç olarak farklı ara değer giriş verileri kullanarak elde etmek istenilen tahmini sonuçlara ulaşma oranı oldukça yüksek olduğu görülmektedir.



Şekil 4. Deney verileri ve YSA sonuçlarının karşılaştırılması
(Figure 4. The compare of experimet datas and YSA outputs)



KAYNAKLAR (REFERENCES)

1. Finn, M.E., (1989). *Metals Handbook*, Ninth edition, Volume:16, Machining, ASM International, Ohio, USA, pp:666-680.
2. Kamyabi-Gol, A. and Sheikh-Amiri, M., (2010). Spheroidizing Kinetics and Optimization of Heat Treatment Parameters in CK60 Steel Using Taguchi Robust Design. *Journal of Iron and Steel Research*, Volume:17, Number:4, pp:45-52.
3. Gunay, M., Aslan, E., Korkut, I., and Ulvi, S., (2004). Investigation of The Effect of Rake Angle on Main Cutting Force. *International Journal of Machine Tools and Manufacture*, Volume:44, Number:9, pp:953-959.
4. FernándeZ-Abia, A.I., Barreiro, J., Lopez de Lacalle, L.N., and Martinez, S., (2011). Effect of Very High Cutting Speeds on Shearing, Cutting Forces and Roughness in Dry Turning of Austenitic Stainless Steels, *The International Journal of Machine Tools and Manufacture*, Volume:57, pp:61-71.
5. Totis, G. and Sortino, M., (2011). Development of A Modular Dynamometer for Triaxial Cutting Force Measurement in Turning. *The International Journal of Machine Tools and Manufacture*, Volume:51, pp:34-42.
6. Kuram, E., Cetin, M.H., Ozcelik, B., and Demirbař, E., (2012). Performance Analysis of Developed Vegetable-Based Cutting Fluids by D-optimal Experimental Design in Turning Process. *Internatinoal Journal of Computer Integred Manufacture*, Volume: 25, Number:12, pp:1165-1181.
7. Camposeco-negrete, C., (2015). Optimization of Cutting Parameters Using Response Surface Method for Minimizing Energy Consumption and Maximizing Cutting Quality in Turning of AISI 6061 T6 Aluminum. *Journal of Cleaner Production*, Volume:91, pp:109-117.
8. Kwon, Y. and Fischer, G.W., (2000). Fuzzy Neuron Adaptive Modeling to Predict Surface Roughness Under Process Variations in CNC Tournring. Number:1, pp:440-450.
9. Philip Selvaraj, D., Chandramohan, P., and Mohanraj, M., (2014). Optimization of Surface Roughness, Cutting Force and Tool Wear of Nitrogen Alloyed Duplex Stainless Steel in A Dry Turning Process Using Taguchi Method. *Measurement*, Volume:49, pp:205-215.
10. Zain, A.M., Haron, H., and Sharif, S., (2010). Prediction of Surface Roughness in The End Milling Machining Using Artificial Neural Network. *Expert Systems with Applications*, Volume:37, pp:1755-1768.
11. Venkata, Rao, K., Murthy, B.S.N., and Mohan Rao, N., (2014). Prediction of Cutting Tool Wear, Surface Roughness and Vibration of work Piece in Boring of AISI 316 Steel with Artificial Neural Network. *Journal of The International Measurement Confederation*, Volume:51, pp:63-70.
12. Sreenivasulu, R., (2013). Optimization of Surface Roughness and Delamination Damage of GFRP Composite Material in End Milling Using Taguchi Design Method and Artificial Neural Network. *Procedia Engineering*, Volume:64, pp:785-794.
13. Karayel, D., (2009). Prediction and Control of Surface Roughness in CNC Lathe Using Artificial Neural Network. *Journal of Materials Processing Technology*, Volue:209, pp:3125-3137.
14. Nalbant, M., Gökaya, H., Toktař, I., and Sur, G., (2009). The Experimental Investigation of the Effects of Uncoated, PVD- and CVD-Coated Cemented Carbide Inserts and Cutting Parameters on Surface Roughness in CNC Turning and Its Prediction Using Artificial neural Networks. *Robotics and Computer-Integrated. Manufacturing*, Volume:25, pp:211-223.



15. Zain, A.M., Haron, H., and Sharif, S., (2010). Prediction of Surface Roughness in the End Milling Machining Using Artificial Neural Network. *Expert Systems with Applications*, Volume:37, pp:1755-1768.
16. Beatrice, B.A., Kirubakaran, E., Thangaiyah, P.R.J., and Wins, K.L.D., (2014). Surface Roughness Prediction Using Artificial Neural Network in Hard Turning of AISI H13 Steel with Minimal Cutting Fluid Application. *Procedia Engineering*, Volume:97, pp:205-211.
17. Zain, A.M., Haron, H., Qasem, S.N., and Sharif, S., (2012). Regression and ANN models for estimating minimum value of machining performance, *Applied Mathematical Modelling*, Volume:36, pp:1477-492.
18. Korkut, I., Acir, A., and Boy, M., (2011). Application of Regression and Artificial Neural Network Analysis in Modelling of Tool-Chip Interface Temperature in Machining. *Expert Systems with Applications*, Volume:38, pp:11651-11656.
19. Asiltürk, İ. and Çunkaş, M., (2011). Modeling and Prediction of Surface Roughness in Turning Operations Using Artificial Neural Network and Multiple Regression Method. *Expert Systems with Applications*, Volume:38, pp:5826-5832.
20. Kara, F., Aslantas, K., and Çiçek, A., (2014). ANN and Multiple Regression Method-Based Modelling of Cutting Forces in Orthogonal Machining of Aisi 316l Stainless Steel. *Neural Computer Application*, Volume:26, Number:1, pp:237-250.
21. Delgrange, V.N., Cabassud, N., Cabassud, M., Durand-Bourlier, L., and Laine, J.M., (1998). Neural Networks for Prediction of Ultrafiltration Transmembrane Pressure: Application To Drinking Water Production. *Journal of Membrane Science*. pp:111-123.
22. Demuth, H., Beale, M., and Hagan, M., (2007). *Neural Network Toolbox 5: Users Guide*. Natick, MA, The MathWorks Inc.