

YAPAY SINİR AĞLARI İLE AI/SiC KOMPOZİT MALZEMENİN YÜZEY PÜRÜZLÜLGÜNÜN TAHMİNİ

İsmail ŞAHİN

Gazi Üniversitesi, Teknoloji Fakültesi, Endüstriyel Tasarım Müh. Bölümü, 06500, Teknikokullar, Ankara.
isahin@gazi.edu.tr

(Geliş/Received: 24.04.2013; Kabul/Accepted: 21.02.2014)

ÖZET

Bu çalışmada Al/SiC kompozit malzemenin yüzey pürüzlülüğü kesme parametrelerine bağlı olarak yapay sinir ağları yaklaşımı kullanılarak yüksek doğrulukta tahmin edilmiştir. Al/SiC kompozit malzemenin TiCN+TiN kaplamalı cementide carbide kesici takımla işlenmesi sonucu deneysel olarak elde edilen yüzey pürüzlülüğü değerleri ileri beslemeli geriye yayılmış 9 farklı YSA modelde eğitilmiştir. YSA modellerinin ağ yapılarındaki nöron sayıları: 3-5-6-1, 3-6-4-1, 3-6-6-1, 3-4-3-5-1, 3-4-5-3-1, 3-6-2-3-1, 3-7-1, 3-8-1 ve 3-9-1'dir. YSA'nın eğitimi ve testi sonrası elde edilen değerler YSA modellerde yaygın olarak kullanılan istatistiksel analizlere tabi tutularak incelenmiştir. Deneysel çalışmaların zorluğu, analitik ifadelerin karmaşıklığı bir çok çalışmada olduğu gibi, YSA kullanımının avantajı kullanılarak kesme parametrelerine bağlı olarak yüzey pürüzlülüğünün tahmini bu çalışmada da YSA'nın kullanılabilirliğini göstermiştir.

Anahtar kelimeler: Yüzey pürüzlülüğü, yapay sinir ağları, kompozit malzeme

PREDICTION OF SURFACE ROUGHNESS OF AI/SiC COMPOSITE MATERIAL WITH ARTIFICIAL NEURAL NETWORKS

ABSTRACT

In this study, surface roughness of Al/SiC composite material depending on the cutting parameters were predicted with high accuracy using approach of artifical neural network. Surface roughness values obtained as experimentally result of machining with TiCN+TiN coated cementide carbide cutting element of Al/SiC composite material are trained in nine different ANN models with feed forward back propogation. The numbers of neuron in network structure of ANN models are 3-5-6-1, 3-6-4-1, 3-6-6-1, 3-4-3-5-1, 3-4-5-3-1, 3-6-2-3-1, 3-7-1, 3-8-1 ve 3-9-1. The values obtained from the ANN training and testing were evaluated by applying the statistical analyses that are widely used in ANN models. In the face of diffuculty of experimental studies and complexity of the analitical expression, as with many studies, this study also showed that ANN is a usable method for predicting the surface roughness value depending on cutting parameters.

Keywords: Surface roughness, artificial neural networks, composite material

1. GİRİŞ (INTRODUCTION)

Talaşlı imalat süreçlerinin amacı sadece makine elemanlarını biçimsel olarak şekillendirmek değil, aynı zamanda geometrik, ölçü ve yüzey gerekliliklerine göre fonksiyonlarını gerçekleştirmektir [1]. Bir makine parçasının fonksiyonelliği çalışma yüzeylerinin kalitesi ile ilişkilidir. Çünkü yüzey kalitesi, makine parçaları için hayatı önem taşıyan oksidasyon, yorulma direnci ve ısıl direnç gibi özelliklerini güçlendirir [2]. Ayrıca, yüzey kalitesi makine takımlarının verimliliğini değerlendirmek için

de önemli bir parametredir [3]. Birbirileyle sürtünerek çalışan parçalarda, boyutsal kararlılık ve çalışma verimliliği yüzey pürüzlülük değerleri ile ilişkilidir. Yüzey pürüzlülüğü, işlenmiş parçaların yüzey fonksiyonlarını ve geometrisini tanımlar [4]. Ayrıca, bir ürünün yüzey kalitesini belirleme ve değerlendirmede de yüzey pürüzlülüğü önemli bir rol oynar. Bunun yanı sıra, malzemenin maliyetini, kalitesini, aşınma direncini, yorulma mukavemetini, sürtünme katsayısını, yağlamayı ve korozyon direncini etkileyen bir parametredir [5]. Ürün kalitesi için bu özelliklerin yüksek seviyede olması gereklidir.

Gereğinden daha düşük yüzey pürüzlülük değeri parçanın fonksiyonelligine zarar vereceği gibi, gereğinden daha yüksek bir yüzey pürüzlülük değeri de üretim maliyetlerini arttırr. Bu yüzden, yüzey pürüzlülük değerinin optimum seviyede tutulması önemlidir [6].

Yüzey pürüzlülüğü oluşum mekanizmaları karmaşıktır ve analitik eşitlikler yardımıyla hesaplanması çok zordur [1]. Çünkü yüzey pürüzlülüğü mekanizmasının şekli çoğulukla işleme süreçlerine bağlıdır [7, 8]. Bu süreçte sadece işleme parametreleri değil, aynı zamanda operatörün tecrübeşi de önemlidir. Bu yüzden yüksek performanslı kesme işlemleri ve ideal yüzey pürüzlülüğüne ulaşılması önemlidir [5]. Yüzey pürüzlülük değerinin belirlenmesinde kullanılan analitik yöntemler ise deneysel çalışmalarla bağlı olarak geliştirildiği için bu eşitlikler büyük miktardaki kesme parametreleri ile sınırlıdır.

Tüm bu zorluklar araştırmacıları, optimum yüzey pürüzlülüğünü tahmin etmek için farklı yöntemler geliştirmeye yönlendirmiştir. Çoklu regresyon analizi, matematiksel modelleme ve bulanık küme teknikleri, genetik algoritmalar ve yapay sinir ağları bu amaçla kullanılan yöntemlerdir. Bu yöntemler içinde YSA, geleneksel yöntemlerle karşılaşıldığında hızı, basılılığı, örneklerden öğrenmedeki başarısı ve çok fazla deneysel veriye ihtiyaç duyulmaması nedeniyle öne çıkmaktadır.

Karayel'in çalışmasında yüzey pürüzlülüğünün tahmininde, deneysel verilere çok yakın değerler elde edilmiştir [1]. Eğitim sırasında, yüzey pürüzlülüğü değerleri geliştirilen bir kontrol sistemi ile kontrol edilmektedir. Davim ve arkadaşlarının geliştirdiği YSA modeli, serbest işleme süresince kesme şartlarının etkilerini araştırarak yüzey pürüzlülüğünü tahmininde kullanılmaktadır [3]. Neşeli ve arkadaşları, tornalamada takım geometrisinin yüzey pürüzlülüğüne etkisini YSA modeli ile tahmininde oldukça yüksek değerlere ulaşmışlardır. [5]. Kohli ve Dixit, yaptıkları bir çalışmada tornalama sürecinde takım tutucuların radyal titreşiminin, geri dönüşümünü alarak yüzey pürüzlülüğü tahmininde YSA modeli uygulamışlardır [6]. Geliştirilen YSA modelde istenilen tamlıkta yüzey pürüzlülüğü değerine ulaşana kadar eğitim ve test verilerinin boyutu artırılmıştır. Minumum yüzey pürüzlülüğüne yol açan optimum kesme parametrelerini belirlemek için, YSA ve genetik algoritmanın bir arada kullanıldığı karma bir modelde deneysel ve test sonuçları arasında yakın bir ilişki olduğu belirtilmiştir [9]. Sharma ve arkadaşları, kesme hızı ve yüzey pürüzlülüğü gibi değerler üzerinde yaklaşma açısı, hız, ilerleme ve kesme derinliği gibi işleme parametrelerinin etkisini araştırmıştır [10]. Birden fazla YSA model deneyerek yüzey pürüzlülüğü tahimininde bulunulan bir çalışmada ise deneysel ve YSA sonuçları arasındaki sapmalar değerlendirilerek en iyi YSA modeli belirlenmiştir [11]. Zain ve arkadaşları yüzey pürüzlülük değerlerini tahmin

etmek için geliştirdikleri modelde yüksek hız ve düşük ilerleme oranında en iyi yüzey pürüzlülük değeri elde edilmiştir [12]. Taşdemir ve arkadaşlarının yaptığı çalışmada universal torna tezgahında işlenen parçalarda tahmin edilen YSA değerleri ile deneysel değerler arasında önemli farklılıklar gözlenmemiştir, bu açıdan YSA model güvenli bulunmuştur [13]. Nalbant ve arkadaşlarının geliştirdiği YSA modelde, kaplama metodu ve malzemesi, kesme hızı ve ilerleme oranının yüzey pürüzlülüğüne etkisinin kabul edilebilir düzeyde olduğu tahmin edilmiştir [14]. Abeesh ve arkadaşlarının geliştirdikleri YSA model ise, en iyi yüzey kalitesini en düşük ilerleme oranı, en küçük partikül çapı ve en büyük uç kavis değerlerinde elde edilmiştir [15]. Yüzey pürüzlülüğü değerlerinin tahmininde regresyon analizi ve YSA modellerin karşılaşılırlarak en iyi tahmin yönteminin belirlendiği bir çalışmada, YSA'nın çoklu regresyon analizine göre daha yüksek doğrulukta sonuçlar verdiği görülmüştür [16]. Benzer şekilde YSA ve çoklu regresyon analizi bir arada kullanılan başka bir çalışmada YSA sonuçlarının regresyon analiz sonuçlarına göre daha iyi olduğu görülmüştür [17].

Bu çalışmanın amacı, uzun deneysel süreçlerle veya karmaşık hesaplamalarla elde edilen yüzey pürüzlülüğü değerlerinin yapay sinir ağları ile tahminini araştırmaktır. Bunun yanında YSA modellerdeki farklı katman sayılarının yüzey pürüzlülüğü değeri tahminine etkisini gözlemlemektir. Bu amaçla deneysel bir çalışma ile [18] elde edilen aritmetik ortalama yüzey pürüzlülüğü değerleri (R_a) bir ileri beslemeli geriye yayılmış Levenbergt Marquert algoritması kullanılan 9 farklı YSA modelde eğitilmiş, bu modeller arasında deneysel sonuçları en iyi tahmin eden ağ araştırılmıştır. Bu çalışmanın bir diğer amacı ise farklı gizli katmana (tek, iki ve üç) sahip ağ yapılarının yüzey pürüzlülüğü değeri tahminine etkisi incelenmiştir.

2. YAPAY SINİR AĞLARI (ARTIFICIAL NEURAL NETWORK)

Yapay sinir ağları (YSA), en genel ifade ile insan beyninin çalışma sistemini modelleyen bir sistem olarak tanımlanabilir. YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar şeklinde düzenlenir [19]. Yapay sinir ağları birbirleri ile bağlı yapay sinirlerden oluşan, bir girdi seti ve tek bir çıktı içeren doğrusal olmayan bir modeldir [20]. YSA, örneklerden genellemeler yaparak öğrenir. Bu öğrenme sonucu yeni bilgiler türetilir ve doğrusal olmayan problemlerin çözümlerini gerçekleştirir [5, 21]. Yapay sinir ağları, aynen insanlar gibi örnekler ile öğrenirler. Bu amaçla deneykümesi, eğitim ve testkümesi olarak iki kısma ayrılır. Eğitim aşaması süresince ağ, eğitimkümesini eğitmek için türmevarım eğitim modelini kullanır [22]. Eğitimin amacı, ağdaki ağırlıkları ayarlayarak hata değerini minimize etmektir [23]. Eğitim süreci hedeflenen çıktı değeri elde edilene kadar devam eder. Ağda beklenen çıktı ve oluşan çıktı değeri arasındaki farktan oluşan hata, ağırlıklar

değiştirilerek minimize edilir [24]. Eğitimin performansı, eğitim sırasında kullanılmayan verilerin ağıda test edilmesiyle gözlemlenir. Bu işleme “test”, bu işlem sonucu elde edilen çıktı verilerine “test verisi” denir. Öğrenme işleminde kullanılan farklı algoritmalar vardır. Bunlardan geri yayılım algoritması en yaygın kullanılanlardandır. Geri yayılım algoritmasında hatalar geriye doğru azaltılmaya çalışılır. Geri yayılmış algoritmanın farklı varyantları vardır. Bunların arasında Conjugate gradient, quasi-Newton ve Levenberg–Marquardt (LM) hızlı olmaları nedeniyle tercih edilen algoritmalarıdır [24]. YSA modelin performansı farklı hata analiz yöntemleri kullanılarak belirlenir. Bir YSA modelin performansı sonuçların mutlak değişim yüzdesi (R^2), istatistiksel hata miktarı (RMS) ve ortalama yüzde hata (MAPE) miktarlarına bakılarak karar verilir. R^2 ’nin yüksek, RMS ve MAPE’nin en düşük değerleri YSA modelin en yüksek performansa sahip olduğu değerlerdir [25]. Bu parametreler aşağıdaki eşitlikler yardımıyla tanımlanır [26, 27]:

$$RMS = \left(\left(\frac{1}{p} \right) \sum_j |t_j - o_j|^2 \right)^{1/2} \quad (1)$$

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

$$MAPE = \frac{o - t}{o} \times 100 \quad (3)$$

Burada t hedef değer, o çıktı değeri ve p numunedir. Girdi ve çıktı katmanları (-1,1) veya (0,1) aralığında normalize edilirler (eş. 4).

$$V_n = \left(\frac{v_R - v_{\min}}{v_{\max} - v_{\min}} \right) \quad (4)$$

Burada, v_R girdinin gerçek değerini, v_{\min} minimum girdi değerini, v_{\max} ise maximum değerini ifade etmektedir.

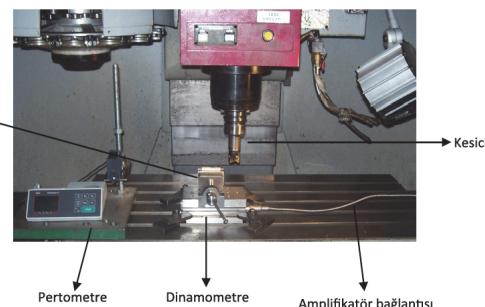
3. DENEYSEL ÇALIŞMA ve YSA MODELİ (EXPERIMENTAL STUDY and ANN MODEL)

Çalışma kapsamında modellenen yüzey pürüzlülük değerleri toz metalurjisi yöntemi ile üretilen SiC takviyeli Al alaşımı kompozit malzemeden elde edilmiştir. Kompozit malzemenin üretimi için karıştırılan Al, %7 Si ve % 5 SiC tozları 600 MPa basınçta sıkıştırılarak 600°C sıcaklıkta 1 saat süre ile argon atmosferinde sinterlenmiştir. Deneysel çalışmalarla kullanılan tozların özellikleri Tablo 1’de verilmiştir.

Tablo 1. Al/SiC Kompozit malzeme üretiminde kullanılan tozlar ve özellikleri (The powders and properties used in the manufacture of Al / SiC composite materials)

Toz Türü	Saflik (%)	Toz Boyutu (μ)
Al	99,99	<150
Si	99,96	<10
SiC		<20

Aluminyum matrisli kompozit malzemenin işlenebilirlik testleri CNC freze tezgahında gerçekleştirilmiştir (Johnford VMC-850 Fanuc Series O-M). Test süresince soğutma sıvısı kullanılmamıştır. Kullanılan kesici takımlar K20 kalitesinde ve TPKN 1603 PPR geometrilidir. İşlenebilirlik testlerinde TiCN+TiN ile kaplamalı cementide carbide kesici takımlar kullanılmıştır. Kesme parametreleri olarak 0,5 ve 1 mm kesme derinliği, 0,1, 0,15 ve 0,20 mm/tooth ilerleme oranı ve 300, 350, 400, ve 450 m/min kesme hızı alınmıştır. Yüzey pürüzlülük değerleri Mahr Perthometer M1 pürüzlülük ölçüm cihazı ile ölçülmüştür (Şekil 1).



Şekil 1. Yüzey pürüzlülüğü deney düzeneği (Surface roughness experimental setup)

Bu çalışmada, Tablo 2’de verilen Al/SiC kompozit malzemenin deneySEL olarak elde edilen yüzey pürüzlülüğü değerleri ile dokuz farklı YSA modelle elde edilen yüzey pürüzlülüğü değerleri karşılaştırılmıştır. Bu amaçla geliştirilen YSA modellerde, geriye yayılmış ileri beslemeli çok katmanlı bir öğrenme mekanizması kullanılmıştır. YSA modellerin eğitiminde bütün veriler kullanılmaz, eğitim için ayrılan verinin oranı %70 ila %90 arasında, test verilerinin ise %30 ila %10 arasında olması tercih edilir. Bu çalışmada deneySEL verilerin %70’i eğitim, %30’u test amaçlı kullanılmıştır. Çalışma kapsamında Kesme derinliği (a), ilerleme oranı (fr) ve kesme hızına (d) bağlı olarak elde edilen 24 yüzey pürüzlülüğü değerinin YSA modelleri oluşturulmuştur (Tablo 2). 3 giriş bir çıkışBu verilerden 17’si eğitim, 7’si test amaçlı kullanılmıştır. Eğitim ve test verileri, her bir girdi kümесini (a, fr ve d) temsil edecek şekilde rastgele belirlenmiştir. Test verileri seçilirken, ilerleme, kesme derinliği ve hız girdilerinin verilerinden seçim grupları oluşturulmuştur. Bu seçimlerin girdi kümelerini (“a” için 0.5 ve 1, “fr” için 0.1, 0.15 ve 0.20 ve “d” için

300, 350, 400 ve 450) homojen bir şekilde temsil etmesine dikkat edilmiştir.

4. SONUÇLAR VE TARTIŞMA (RESULTS AND DISCUSSION)

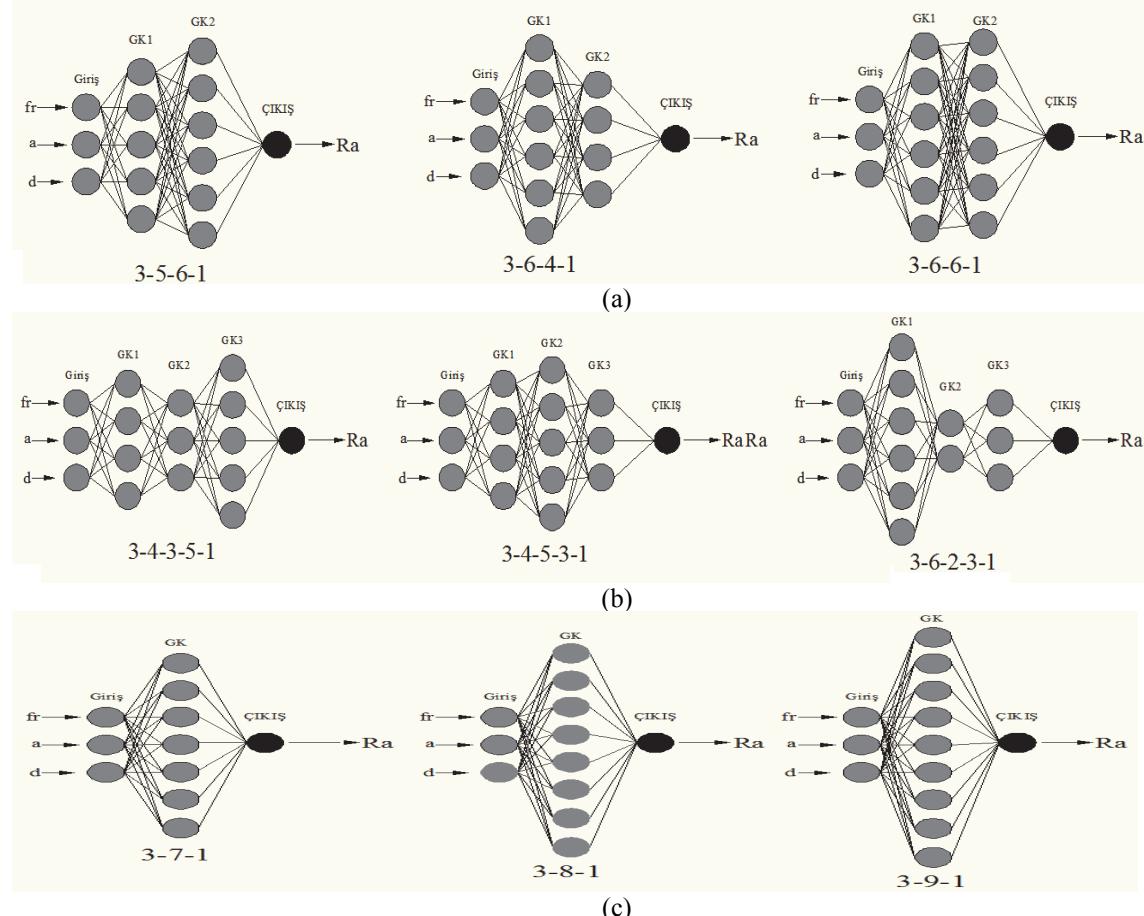
Yüzey pürüzlülüğü tahmininde farklı ağ yapıları denenmiştir. Farklı ağ yapıları ile alternatif çözümler sunularak bunların arasından en uygun ağ modeli seçilmiştir. Çalışmada üç gizli, tek çıkışlı, bir, iki ve üç gizli katmana sahip modeller denenerek, yüzey pürüzlülüğü değerlerini en iyi şekilde tahmin eden ağın bulunması hedeflenmiştir. Yüzey pürüzlülüğünü tahmin için denenen ağlarda aynı eğitim algoritması

ve aynı sayıda eğitim verisi kullanılmıştır. Çalışmada, gizli katman ve nöron sayıları değiştirilerek, farklı yüzey pürüzlülüğü değerleri tahmin edilmiştir. Bu amaçla dokuz farklı ağ geliştirilmiştir. Bunlar 3-5-6-1, 3-6-4-1, 3-6-6-1, 3-4-3-5-1, 3-4-5-3-1, 3-6-2-3-1, 3-7-1, 3-8-1 ve 3-9-1 şeklindedir (Şekil 2). Deneysel verilerin eğitimi, ağ yapısının belirlenmesi ve optimizasyonunda Pythia yazılımı kullanılmıştır.

Ağ yapıları belirlendikten sonra eşitlik 4 kullanılarak girdilerin normalizasyonu gerçekleştirilmiştir. Tablo 3'te girdilerin normalizasyonunda kullanılan, giriş

Tablo 2. Deneysel veriler (Experimental datas)

a	fr	D	Ra	A	Fr	d	Ra
0,5	0,1	300	2,22	1	0,1	300	1,891
0,5	0,15	300	1,236	1	0,15	300	1,692
0,5	0,2	300	0,886	1	0,2	300	1,328
0,5	0,1	350	1,839	1	0,1	350	1,214
0,5	0,15	350	1,228	1	0,15	350	1,252
0,5	0,2	350	1,43	1	0,2	350	0,965
0,5	0,1	400	1,182	1	0,1	400	0,912
0,5	0,15	400	0,886	1	0,15	400	0,78
0,5	0,2	400	0,849	1	0,2	400	0,616
0,5	0,1	450	0,939	1	0,1	450	0,698
0,5	0,15	450	0,711	1	0,15	450	0,659
0,5	0,2	450	0,686	1	0,2	450	0,715



Şekil 2. Çalışmada kullanılan YSA modelleri: (a) Üç gizli katmanlı (b) iki gizli katmalı (c) Tek gizli katmanlı (ANN models used in study: (a)with three hidden layers (b) with two hidden layers (c) with single hidden layer)

parametrelerinin maksimum ve minimum değerleri görülmektedir.

Tabelo 3. Normalizasyon için kullanılan en yüksek ve en düşük giriş değerleri (Maximum and minimum input data values used for normalisation)

Parametreler	V_{max}	V_{min}
İlerleme oranı (fr)mm/tooth	0,20	0,10
Talaş derinliği (a) mm	0,5	0,1
İlerleme hızı (d) m/min	450	300

Model, YSA eğitiminde yaygın olarak kullanılan fermi transfer fonksiyonu kullanılarak formüllize edilmiştir (es. 5).

$$F_i = \frac{1}{1 + e^{-4(\sum v_{nor} \times w_i - 0,5)}} \quad (5)$$

Burada ($i = 1, 2, 3, \dots, n$) olmak üzere v_{nor} girdinin normalize değerini, w_i ise ağırlık değerini ifade etmektedir. Tüm bu hesaplamalar sonunda ağın çıkış değeri eşitlik 6 yardımıyla hesaplanır.

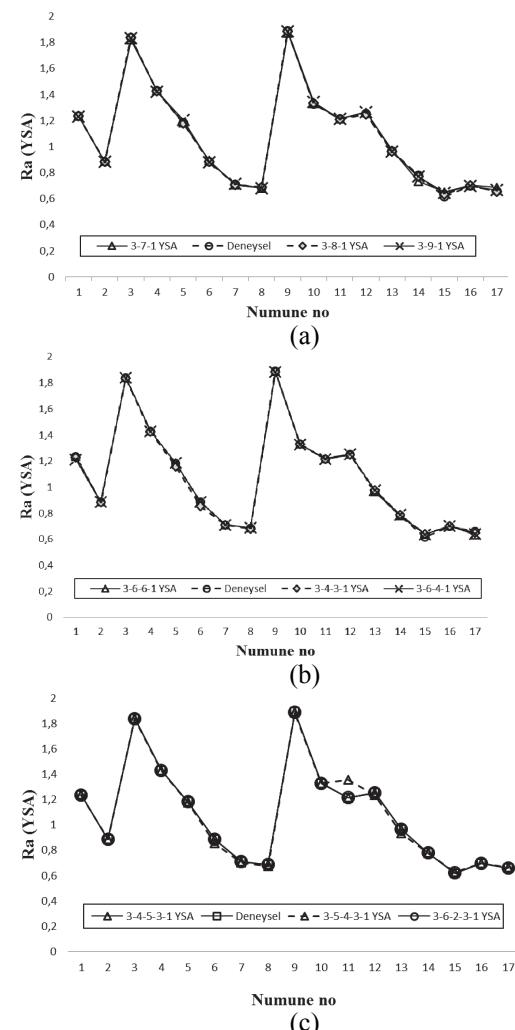
$$S_{ann} = f_i(S_{\max} - S_{\min}) + S_{\min} \quad (6)$$

Burada f_i ($i = 1, 2, 3, \dots, n$) olmak üzere, S_{\max} deneysel verilerin maximum çıkış değerini, S_{\min} ise minimum çıkış değerini ifade etmektedir. Şekil 3'te YSA modellerin eğitim aşamasında yüzey pürüzlülüğü değerlerinin deneysel sonuçlara ne kadar yaklaştığı görülmektedir. Ağların öğrenme kabiliyetlerini gösteren R^2 değerlerinin bütün ağlarda 0,999 gibi yüksek bir öğrenme değerine ulaşığı görülmüştür.

Çalışmada kullanılan dokuz farklı YSA modelin içinde en iyisini seçmek için karşılaştırmalar yapılmıştır. Bu karşılaştırmalar için önce her bir YSA modelin deneysel sonuçlara göre test performansı incelenmiş, daha sonra modellerin performansları birbirleri ile karşılaştırılarak en iyi model seçilmiştir.

Daha önce yapılan çalışmalarda farklı YSA modeller arasında en iyi modeli belirlemek için iki farklı yöntem kullanılmıştır. Bu yöntemler, istatistiksel hata miktarı [12] ve eğitim verilerindeki sapma miktarlarının karşılaştırılmasıdır [11]. Bu çalışmada ise, test sonuçları mutlak değişim yüzdesi (R^2), istatistiksel hata miktarı (RMS) ve ortalama yüzde hata (MAPE) değerleri yönünden karşılaştırılarak bir sonuca varılmıştır. Bu üç istatistikti değeri en iyi durumda olan ağ, yüzey pürüzlülüğü değerini en iyi tahmin eden ağ olarak seçilmiştir. Yapay sinir ağı modeli; hem ham verilerde hem de test verilerinde test edilmiştir. Esas sonuçların test verilerinde uygun sonuç vermesi öğrenmenin yeterli düzeyde gerçekleştigini vurgulamaktadır. Çalışmada farklı YSA modelleri denenmiş, veriler tek tek deney sonuçlarına göre test edilmiştir. R^2 , MAPE ve RMS sonuçları her model için ayrı ayrı hesaplanmıştır. Bu

hesaplamalar sonucunda en optimum ağ yapısı belirlenmiştir. Çalışmada ayrıca YSA modeller katman sayılarına göre gruplandırılarak istatistikti değerlerin ortalamaları yönünden de karşılaştırılmıştır. Böylece gizli katman sayısının ağ performansına etkisi gözlemlenmiştir. Dokuz ağın YSA sonuçları birbirleri ile karşılaştırıldığı zaman üç gizli katmana ve 13 nörona sahip olan 3-4-5-3-1 ağının, eğitim ve test sonuçları yönünden yüzey pürüzlülüğü tahmininde diğer ağlardan daha iyi olduğu görülmüştür (Tablo 4).



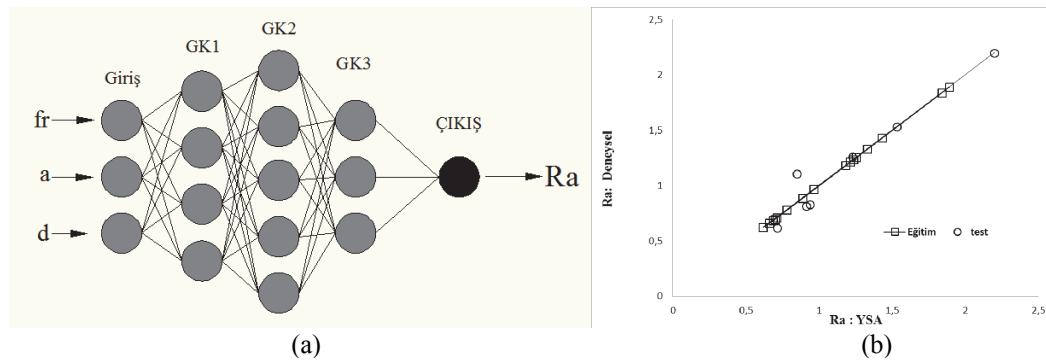
Şekil 3. YSA modellerin eğitimi: (a) Tek gizli katmanlı b) iki gizli katmanlı c) üç gizli katmanlı (Training of ANN models (a)with three hidden layers (b) with two hidden layers (c) with single hidden layer)

Lewis'e göre MAPE değerinin <0.1 olması, ağın yüksek doğrulukta tahminlerde bulunduğu göstermektedir [28]. Bu çalışmada $MAPE_{\text{eğitim}}$ değeri 0,06 çıkararak Lewis'in verdiği doğruluk değerine ulaşmıştır.

Şekil 4'de en iyi yüzey tahmini değerlerini veren modelin ağ yapısı ve deneysel sonuçlarla YSA sonuçların karşılaştırılması verilmiştir.

Tablo 4. Yüzey pürüzlülük değerinin istatistiksel değerleri (Statistical values of the value of surface roughness)

Model	$R^2_{\text{eğitim}}$	R^2_{test}	$RMS_{\text{eğitim}}$	RMS_{test}	$MAPE_{\text{eğitim}}$	$MAPE_{\text{test}}$
3-7-1	0,99976873	0,96902000	0,00017312	0,002313	0,17691688	2,961156
3-8-1	0,9999734	0,97325140	0,0000587	0,002072	0,0344120	3,099069
3-9-1	0,999901	0,96822300	0,000114	0,00241	0,38168	9,498109
3-4-3-1	0,9998737	0,92002200	0,00012775	0,004068	0,25197481	17,31517
3-6-4-1	0,99993	0,80844200	0,0000956	0,005436	0,0156991	9,48
3-6-6-1	0,9999462	0,95563790	0,00008368	0,002451	0,0301954	6,021986
3-5-4-3-1	0,9989954	0,96856700	0,0003624	0,002342	0,0151745	4,4878
3-4-5-3-1	0,9999979	0,99170200	0,00001643	0,00179	0,0604924	0,439134
3-6-2-3-1	0,9999982	0,96843520	0,00001513	0,002374	0,0599167	5,844905

**Şekil 4.** (a) Yüzey pürüzlülüğü tahmini için en iyi YSA model (b) en iyi modelin deneysel ve YSA sonuçlarının karşılaştırılması (a)The best ANN model for the prediction of surface roughness (b) comparison of ANN and experimental results of the best model

Eşitlik 7 – 10'da en iyi YSA model olarak karar verilen 3-4-5-3-1 ağında yüzey pürüzlülüğü değeri tahmini için oluşturulan fermi transfer fonksiyonları görülmektedir. Birinci gizli katman için oluşturulan (F_i) eşitlik 7'de $i=1,2,3,4$; ikinci gizli katman için oluşturulan (G_i) eşitlik 8'de $i=5,6,7,8,9$ olarak; üçüncü gizli katman için oluşturulan (H_i) eşitlik 9'da $i=10,11,12$ ve çıkış katmanı için oluşturulan (K_i) eşitlik 10'da $i=13$ olarak tanımlanmıştır. Denklemlerde v_a , v_{fr} ve v_d girdilerin normalize değerini, w_{ij} ise ağırlık değerlerini ifade etmektedir. Modelin ağırlık değerleri (w_{ij}) Tablo 5'te verilmiştir. Tablo 6'da ise test verilerinin tahmin sonuçları görülmektedir.

$$F_i = \frac{1}{1 + e^{-4(\sum v_a \cdot w_{1i} + v_{fr} \cdot w_{2i} + v_d \cdot w_{3i} - 0,5)}} \quad (7)$$

$$G_i = \frac{1}{1 + e^{-4(\sum F_1 \cdot w_{1i} + F_2 \cdot w_{2i} + F_3 \cdot w_{3i} + F_4 \cdot w_{4i} - 0,5)}} \quad (8)$$

$$H_i = \frac{1}{1 + e^{-4(\sum G_5 \cdot w_{1i} + G_6 \cdot w_{2i} + G_7 \cdot w_{3i} + G_8 \cdot w_{4i} + G_9 \cdot w_{5i} - 0,5)}} \quad (9)$$

$$K_i = \frac{1}{1 + e^{-4(\sum H_{10} \cdot w_{1i} + H_{11} \cdot w_{2i} + H_{12} \cdot w_{3i} - 0,5)}} \quad (10)$$

Tablo 5. Seçilen modelin ağırlıkları (Weights of the selected model)

i	w_{1i}	w_{2i}	w_{3i}	w_{4i}	w_{5i}
1	-0,927300	-0,607665	-0,296835		
2	1,196661	0,279365	-1,803223		
3	-0,231489	1,256283	-0,521348		
4	0,618208	-0,281730	0,662217		
5	1,530926	-2,044788	0,487545	-0,799321	
6	3,072416	0,814915	-0,699119	-0,742861	
7	1,360726	1,351188	-1,055848	0,385165	
8	-0,875915	-0,128056	0,194246	0,820624	
9	-0,142629	0,278025	-0,808125	-0,632134	
10	-1,609956	-0,417809	-1,933163	1,214808	0,345883
11	1,147705	2,915182	-0,161848	-0,630332	1,463031
12	-0,240060	1,058261	0,280823	-0,189085	-0,057545
13	-1,728445	2,484470	1,389877		

Tablo 6. Test aşamasında YSA'nın tahmin değerleri (Predicted values of the ANN in the testing phase.)

a	fr	d	Ra: Deneysel	Ra: YSA	R²
0,5	0,10	300	2,2	2,19875	1
0,5	0,15	350	1,228	1,257304	0,999457
0,5	0,20	400	0,849	1,105599	0,946134
1	0,15	300	1,532	1,534009	0,9999998
1	0,20	450	0,715	0,617695	0,975185
1	0,10	400	0,912	0,815882	0,986121
0,5	0,10	450	0,939	0,829983	0,982748
R² (Ortalama)					0,991703

5. SONUÇLAR (CONCLUSION)

Bu çalışmada, daha önce yapılan bir deneysel çalışmada [18] Al/SiC kompozit malzemenin CNC freze tezgahında işlenmesi ile elde edilen yüzey pürüzlülüğü değerlerini tahmin etmeye yönelik geliştirilen YSA tabanlı bir matematiksel model tanıtılmıştır. YSA modellerin eğitiminde, ileri beslemeli geriye yayılmış Levenbergt Marquert algoritması kullanılmıştır.

Yüzey pürüzlülüğü tahmini için üç farklı gizli katman sayısı ve dokuz farklı ağ yapısı denenmiştir. Bunlar 3-5-6-1, 3-6-4-1, 3-6-6-1, 3-5-4-3-1, 3-4-5-3-1, 3-6-2-3-1, 3-7-1, 3-8-1 ve 3-9-1 ağ yapılarındanadır. YSA'nın eğitimi ve testi sonrası elde edilen değerler istatistiksel olarak incelenmiş, aşağıdaki sonuçlar elde edilmiştir:

- Çalışmada YSA eğitiminde kullanılan 17 ve test aşamasında kullanılan 7 veri ile elde edilen sonuçlar, az sayıda deneysel veri ile yüzey pürüzlülüğü tahmininin mümkün olabileceğiğini göstermektedir.
- Ağlar, gizli katman sayılarına göre grupperlendirildiğinde, test verilerinin R², RMS ve MAPE ortalamalarına göre en iyi yüzey pürüzlülüğü tahminleri üç gizli katmana sahip ağlarla elde edildiği görülmüştür. Eğitim verilerinde ise R² ve RMS ortalamalarına göre iki gizli katmanlı ağların performansı daha iyi iken, MAPE ortalamasına göre üç gizli katmana sahip ağların performansı daha iyi çıkmıştır.
- Dokuz ağın YSA sonuçları birbirleri ile karşılaştırıldığında ise, üç gizli katmana ve 13 nörona sahip olan 3-4-5-3-1 ağının, test sonuçları yönünden yüzey pürüzlülüğü tahmininde diğer ağlardan daha iyi olduğu görülmüştür.
- En iyi ağ olarak belirlenen 3-4-5-3-1 ağının mutlak değişim yüzdesi (R²) eğitim için 0,99999, test için 0,991702; istatistiksel hata değeri (RMS) eğitim için 0,000016, test için 0,00179 ve ortalama yüzde hatası (MAPE) eğitim için 0,0604924, test için 0,439134 olarak gözlenmiştir.

- Test verilerinde uygun sonuçların elde edilmesi öğrenmenin yeterli düzeyde gerçekleştiğini vurgulamaktadır.
- Çalışmada yüzey pürüzlülüğü tahmininde deney sayısını azaltıp YSA ile matematiksel modelin oluşturulabileceği gösterilmektedir.
- Deneysel yöntemler ile karşılaştırıldığında, çalışmada YSA ile daha hızlı bir şekilde tahminlerde bulunmak mümkün olmuştur.

Bu çalışma ile imalat sürecinde zaman ve maliyet kaybına neden olan klasik yöntemlere (deneysel ve analitik) gerek kalmadan YSA ile yüzey pürüzlülüğü değerlerinin tahmin edilebileceği görülmüştür.

KAYNAKLAR (REFERENCES)

1. Karayel, D., "Prediction and control of surface roughness in CNC lathe using artificial neural network", **Journal of Materials Processing Technology**, 209, 7, 3125–3137, 2009.
2. Neşeli, S., Yaldız S. ve Turkes, E., "Optimization of tool geometry parameters for turning operations based on the response surface methodology", **Measurement**, 44, 3 580-587, 2011.
3. Davim, J.P., Gaitonde, V. N. ve Karnik, S. R., "Investigation into the effect of cutting conditions on surface roughness in turning of free machining steel by ANN models", **Journal of Material Processing Technology**, 205, 16-23, 2008.
4. Nalbant, M., Gokkaya, H. ve Sur, G., "Application of Taguchi method in the optimization of cutting parameters for surface roughness in turning", **Materials & Design**, 28, 4, 1379–1385, 2007.
5. Neşeli, S., Taşdemir Ş. ve Yaldız, S., "Prediction of surface roughness on turning with Artificial Neural Network", **Journal of Engineering and Architecture Faculty of Eskisehir Osmangazi University**, XXII, 3, 65-75, 2009.
6. Kohli, A., Dixit, U.S., "A neural-network-based methodology for the prediction of surface roughness in a turning process", **Int. J. Adv. Manuf. Technol**, 25, 118–129, 2005.
7. Bernardos, P.G., Vosniakos, G.C., "Predicting surface roughness in machining: a review",

- International Journal of Machine Tools & Manufacture** 43, 8, 833–844, 2003.
8. Petropoulos, G.P., Vaxevanidis, N. M., Pandazaras, C.N. ve Antoniadis, A.A., "Multiparameter identification and control of turned surface textures", **Int. J. Adv. Manuf. Technol.**, 29, 1-2, 118-128, 2006.
 9. Oktem, H., Erzurumlu T., Erzincanlı F., "Prediction of minimum surface roughness in end milling mold part using neural network and genetic algorithm" **Materials and Design**, 27, 735-744, 2006.
 10. Vishal S. S., Suresh D., Rakesh S. ve Sharma, S. K., "Estimation of cutting forces and surface roughness for hard turning using neural Networks", **J. Intell Manuf**, 19, 473–483, 2008.
 11. Sanjay , C., Jyothi, C. ve Chin, W., "A study of surface roughness in drilling using mathematical analysis and Neural Networks", **Int. Adv. Man. Tec.**, 30, 9, 846-852, 2006.
 12. Zain A.M., Haron. H. ve Sharif, S., "Prediction of surface roughness in the end milling machining using artificial neural network", **Robotics and computer integrated manufacturing**, 19, 189-199, 2006.
 13. Taşdemir, Ş., Neşeli S., Saritaş İ. ve Yaldız S., "Prediction of surface roughness using artificial neural network in Lathe", **CompSysTech'08**, Gabrovo, Bulgaria, 2008.
 14. Nalbant, M., Gökkaya, H., Toktaş, İ., Sur, G., "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**, 25, 1, 211–223, 2009.
 15. Abeesh, B. C., Dabade, U. A., Joshi, S. S., Bhanuprasad, V. V., & Gadre, V. M. "Modeling of surface roughness in precision machining of metal matrix composites using ANN", **Journal of Material Processing Technology**, 197, 439–444, 2008.
 16. Asiltürk İ., Cunkaş, M., "Modelling and Prediction of surface roughness in turning operations using artificial neural network and multiple regression method", **Expert system with Application**, 38, 5826-5832, 2011.
 17. Feng C-X, Wang X-F, "Surface roughness prediction modelling: neural networks versus regression", **IIE Trans.**, 35, 1, 11–27, 2003.
 18. Turgut, Y., Çinici, H., Şahin, İ. ve Fındık, T., "Study of cutting force and surface roughness in milling of Al/Sic metal matrix composites", **Scientific Research and Essays**, 6, 10, 2056-2062, 2011.
 19. Ozdemir, 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.
 20. Eker, A. M., Dikmen, M., Cambazoğlu, S., Düzgün, Ş.H.S.B., "Application of artificial neural network and logistic regression methods to landslide susceptibility mapping and comparison of the results for the Ülus district, Bartın", **Journal of The Faculty of Engineering and Architecture of Gazi University**, 27, 1, 163-173, 2012.
 21. Kalogirou, S. A., "Artificial intelligence for the modeling and control", **Progress in Energy and Combustion Science**, 29, 515–566, 2003.
 22. Fındık, T., Taşdemir, Ş. ve Şahin, İ., "The use of artificial neural network for prediction of grain size of 17-4 pH stainless steel powders", **Scientific Research and Essays**, 5 , 11, 1274-1283, 2010.
 23. Aşkin, D., İskender, İ. ve Mamizadeh, A., "Dry type transformer winding thermal analysis using different neural network methods", **Journal of The Faculty of Engineering and Architecture of Gazi University**, 26, 4, 905-913, 2011.
 24. Karataş, Ç., Sozen, A. ve Dulek, E., "Modelling of residual stresses in the shot peened material C-1020 by artificial neural network", **Expert Systems with Applications**, 36, 2, 3514–3521, 2009.
 25. Menlik, T., Özdemir, M.B. vr Kirmaci, V., "Determination of freeze – drying behaviors of apples by artificial neural network", **Expert system with application**, 37, 7669-7677, 2010.
 26. Sozen, A., Future projection of the energy dependency of Turkey using artificial neural network, **Energy Policy**, 37, 4827-4833, 2009.
 27. Sözen, A., Arcaklıoğlu, E., Menlik, T., Özalp, M., "Determination of thermodynamic properties of an alternative refrigerant (R407c) using artificial neural network", **Expert Systems with Applications**, 36, 3, 4346–4356, 2009.
 28. Lewis, C.D., **Industrial and Business Forecasting Methods**., Butterworths Publishing, London, 1982.