

Makalenin Geliş Tarihi : 02.06.2009
Makalenin Kabul Tarihi : 25.10.2009

AŞINDIRICI SU JETİNİN TEORİK ANALİZİ VE YAPAY SİNİR AĞI YÖNTEMİYLE MODELLENMESİ

Hayriye Sevil ERGÜR¹

ÖZET: Aşındırıcı su jetiyle kesme, diğer kesme teknolojilerine göre belirgin üstünlüklere sahip olduğundan makine imalat sanayi ve madencilikte kullanımları artmaktadır. Aşındırıcı su jetiyle kesme sistemleri; işlenecek olan malzemenin özelliğine göre çok geniş bir dağılıma sahiptirler. Başlıca yararlarından birisi, işlenmiş yüzeylerde ısıdan etkilenmemesidir. Ancak, işleme sonrası kesilen yüzeyde çizik oluşma ihtimali, mahsurlarından sayılabilir. Kapasitesini ve kesme performansını artırabilmek için, söz konusu teknolojinin çok iyi tanınması gerekir. Aşındırıcı su jetinin hidrodinamik karakteristiklerini belirlemedeki eksiklik, işlem kontrolü ve optimizasyonu için gerekli kesme performans modellerinin gelişimini sınırladığından planlama ve kesme işleminin en uygun kesme performansını önceden tayin için, boyutsal analizden yararlanan matematiksel modeller ve yapay sinir ağı uygulamaları mevcuttur. Yapılan çalışmada; aşındırıcı su jeti sistemi teorik olarak analiz edilmiş, ayrıca deneysel veriler yapay sinir ağı yardımıyla modellenerek, aşındırıcı su jeti ile kesmede yapay sinir ağının uygulanabilir olduğu gösterilmiştir.

ANAHTAR KELİMELER: Aşındırıcı su jeti, kesme, yapay sinir ağları, yüzey pürüzlülüğü.

THEORETICAL ANALYSIS OF ABRASIVE WATERJET AND MODELLING WITH ARTIFICIAL NEURAL NETWORK

ABSTRACT: Abrasive water jet cutting is one of the most recently developed non-traditional manufacturing technologies being used increasingly in mining and machine production industry owing to the various distinct advantages over the other cutting Technologies.. Absence of the heat affected zone is the main advantage of this process. In spite of briteness, ductileness and being composites it do have rather wide machining process, but striations are the main disadvantage of this cutting technology. The technology must be known very well in order to increase the capacity and cutting performance. Abrasive water jet cutting applications on specimens with varying thickness and feed rate had been shown that artificial neural network can be used succesfully in this work. The lack of knowledge in describing the hydraulic characteristics of the abrasive water jet cutting will limit the development of the process control and optimization of the modelling. Therefore, in order to determine the optimal cutting performance of the process planning and cutting processs, mathematical models with dimensional analysis and artificial neural network applications are used. In this study, abrasive water jet cutting has been analysed and the experimental data at various conditions had been modelled with the aid of artificial neural network.

KEYWORDS: Abrasive waterjet, cutting, surface roughness, artificial neural network.

¹ Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Makine Müh. Blm., Meşelik Kampüsü, 26480 ESKİŞEHİR
Bu çalışma, Prof. Dr. Yaşar PANCAR danışmanlığında, ESOGÜ Fen Bilimleri Enstitüsünde hazırlanan "Aşındırıcı su jetinin teorik analizi ve yapay sinir ağı yöntemiyle modellenmesi" başlıklı doktora tezinden üretilmiştir.

I. GİRİŞ

Gelişen teknolojinin her kademesinde, değişik imalat yöntemleri günümüze kadar istenilen başarıda gelmişlerdir. İmalat yöntemlerinden birisi de sade veya aşındırıcı su jetleridir. Su jeti kullanımı, aşındırıcı parçacıkların su hüzmesine katılmasıyla, daha sert malzemelerin kesilmelerini kolaylaştırmıştır. Kesme işleminde kullanılan su, sert malzemelerde kesme yerine aşındırıcıyı taşıma görevini de üstlenmektedir [1].

Hidrolik güç ve aşındırıcı su jeti nozulundaki yeni tasarımlarda yüksek güç kullanımıyla, kesme performansı artarken kesme maliyeti düşürülmüştür. Su jetiyle gerçekleştirilen işlemler, basıncı artırılan suyun bir nozuldan geçirilmesiyle ulaşılan yüksek hızlarla, su jeti hüzmesinin veya aşındırıcı-su jeti karışımının, çarpma etkisiyle malzemeyi aşındırması esasına dayanır. Isıl gerilmeler ve radyasyon oluşturmada parlak ve kompozit malzemelerle birlikte, hemen her türlü malzemeyi kesip işleyebilen aşındırıcı su jeti sistemleri, 1982'den sonra metal endüstrisinde kullanılmaya başlanmıştır. Aşındırıcı parçacık katkılı su jeti sistemlerinin, lazer ve plazma ark kesme sistemlerine göre, ilk yatırım maliyetleri ve içerdiği kesme özellikleri yönünden üstünlük sağlamaları, kullanımını yaygınlaştırmıştır [2].

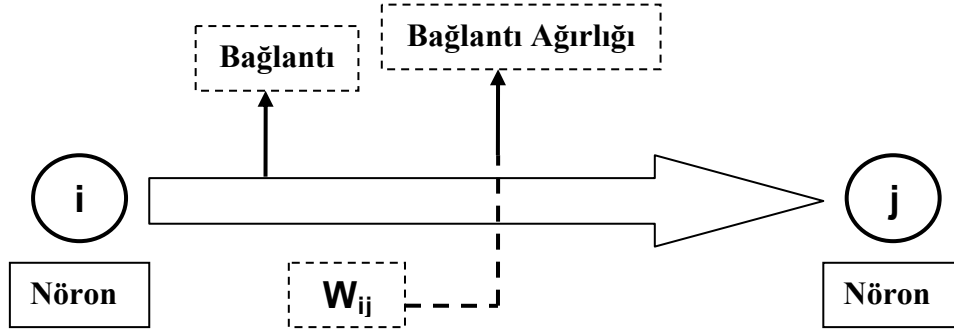
Su jeti sistemleri, kesilen yüzey kalitesi, kesme hızı ve uçucu kesme tozu çıkarmaması açısından, gıda endüstrisi dışında sağlık gruplarında da başarıyla kullanılmaktadır. Ayrıca, kesme kuvvetlerinin çok küçük olması, sert, yumuşak, yapışkan malzemelerin aynı nozulla kesilebilmesi, ince parçaların üst üste konularak aynı anda kesilebilmesi gibi çok sayıda üstünlüğe sahiptir [3,4].

Yapılan çalışmada; Aşındırıcı su jeti (ASJ) sistemi değişik açılardan analiz edilmiştir. Öngörülen mevcut ve deneysel veriler kullanılarak, yapay sinir ağı (YSA) sisteminin ASJ ile kesme işlemlerine başarıyla uygulanabileceği gösterilmiştir. Ayrıca, aşındırıcı su jetiyle kesilen birçok malzemenin kalınlık, su basıncı, aşındırıcı kütleli debisi, nozul çapı, karıştırma tüpü çapı ve ilerleme hızı vb. kesme parametreleri, YSA modeliyle belirlenmiştir. Modelde kullanılan veriler farklı basınç ve kalınlıktaki, cam ve titanyum için hazırlanmış hassas kesme değerleridir. Bu değerler yardımıyla aşındırıcı kütleli debisi, karıştırma tüpü çapı ve nozul çapını değiştirerek, söz konusu malzemelerin hassas kesmeye uygun ilerleme hızlarına ulaşılmıştır.

II. YAPAY SİNİR AĞLARI (YSA)

II.1. Ağ Tanımı

YSA teknolojisi, insan beyninin temel işlem elemanı olan nöronu, şekilsel ve işlevsel olarak basit bir şekilde taklit eden ağlar yardımıyla, biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlar sistemidir. Bu nöronlar, çeşitli şekillerde birbirlerine bağlanarak öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahip ağı oluştururlar [5,6]. Benzer karakteristiğe sahip nöronlar, YSA' da katmanlar halinde yapılandırılırlar. YSA' ya ait matematiksel fonksiyon, veri alan nöronlara ve çıktı üreten nöronlara sahip ağ tarafından şekillendirilir. Şekil 1'de gösterildiği üzere, YSA' da üç ana elemandan söz edilir. Bunlar sırasıyla; işlem elemanı olan nöron, girdi ve çıktı yolunu sağlayan bağlantı ve bu bağlantıların sağlamlığını gösteren bağlantı ağırlığıdır. Örnekler kullanılarak belirlenen bu ağırlıklar, girdi değişkenleri ile tahmin edilen değişkenler arasındaki ilişkiyi ortaya çıkarırlar. Eğitilen YSA, yeni veriler için yeni tahminler üretir. Bir ağın performansı, düşünülen sinyal ve hata kriteri ile ölçülür [7]. Ağın çıktısı, amaçlanan çıktı ile karşılaştırılarak hata payı elde edilir. Geriye yayılma olarak adlandırılan algoritma, hata payını azaltacak şekilde ağırlıkları ayarlamak için kullanılır. İşlem defalarca tekrar edilip, ağ eğitilerek performans ölçümleri bazında optimum çözüme ulaşılabilir.



Şekil 1. Yapay sinir ağlarının (YSA) temel elemanları

Hata karelerinin ortalamasının karekökü,

$$RMSE = \sqrt{1/p \sum_j |t_j - o_j|^2} \quad (1)$$

Korelasyon katsayısı veya sapma kesrindeki % değişim,

$$R^2 = 1 - \left[\sum_j (t_j - o_j)^2 / (o_j)^2 \right] \quad (2)$$


Mutlak ortalama yüzde hata,

$$MAPE = \frac{1}{p} \sum_j \left[|(t_j - o_j) / t_j| \right] \cdot 100 \quad (3)$$

(1), (2) ve (3) nolu denklemler yardımıyla hesaplanabilir. Denklemlerde yer alan “t”, hedef değer, “o”, çıkış değeri, “p” ise, toplam veri sayısını ifade etmektedir [8].

II.2. Ağ Yapısı

Bu modellemede öğrenme algoritması olarak, mühendislikte ve pek çok alanda, işletiminin kolay, yapısının basit ve öğrenme kapasitesinin yüksek olması nedeniyle genelde tercih edilen, geriye yayılma algoritması kullanılmıştır. İleri beslemeli sinir ağının çözümünde kullanılan denetimli öğrenme tipi seçilmiştir. Ağın genel yeteneği, sisteme uygun giriş-çıkış parametrelerinin seçimi, veri tabanının dağıtımı, eğitim ile test verilerinin belirlenmesi ve ağın veri tabanını sunma formatıdır. Modellemenin sonucunda yüksek doğruluk ve performansta değerler elde etmek için; eğitim algoritması, gizli tabaka, nöron sayısı ve gizli tabaka-çıkış tabakası arasındaki transfer fonksiyonunun seçimi çok önemlidir. YSA’ da mevcut olan eğitim algoritmalarının amacı, hataları en aza indirmektir. Burada, malzeme kalınlığı ve basınç değişkeni giriş parametresi olarak, ilerleme hızı ise çıkış parametresi olarak kullanılmıştır.



Şekil 2. Çalışmada kullanılan tek-gizli-tabakalı ağ yapısı

Oluşturulan YSA modeli Şekil 2’de gösterildiği gibi iki girişli, tek gizli tabakalı, tek çıkışlı bir yapıya sahiptir. Ağın eğitiminde kullanılan toplam veri 84 adettir. YSA sistemindeki ağ yapısı oluşturulurken seçilen test değerleri toplam verilerin %20’sini, eğitim değerleri ise %80’ini oluşturmaktadır. Söz konusu test değerleri rasgele seçilmiştir.

III. YSA İLE MODELLEME

Bu modellemede ele alınan malzemeler sırasıyla cam ve titanyumdur. Kesme veriminde etkili parametrelerden karıştırma tüpü çapı, nozul çapı, aşındırıcı kütleli debisinin ve pompa basıncının sabit, su basıncı ve malzeme kalınlıklarının değişken olduğu kabul edilmiştir. Çizelge 1’de detaylı olarak verilen modelleme kabullerinin deneysel sonuçları bilimsel literatürden elde edilmiştir [9]. Modelleme sonucunda belirlenen ilerleme hızları, hassas kesme için geçerlidir.


Yüzey pürüzlülüğünü doğrudan etkileyen en önemli parametrelerden birisi kesme hızıdır. Seçilen ağ yapısında gizli tabakada tansig transfer fonksiyonu, çıkış tabakasında ise pureline transfer fonksiyonları kullanılmıştır. Bu çalışmalarda kullanılan algoritmalar SCG (Scaled conjugate gradient) ve LM (Levenberg –Marquardt) algoritmalarıdır.

Çizelge 1. Modelleme için yapılan kabuller


Malzeme Tipi		Malzeme Kalınlığı (mm)						
Cam	Titanyum	1	2	5	10	15	20	25
		30	35	40	45	50	75	100
Nozul çapı (mm)		0,35						
Aşındırıcı Debisi (kg/dk)		0,30						
Karıştırma Tüpü Çapı (mm)		0,762						
Pompa Basıncı (bar)		3000						
Malzeme Tipi		Su Basıncı (bar)						
Cam	Titanyum	1500	2000	2500	3000	3500	4000	

III.1. Cam Kesmede Elde Edilen YSA Sonuçları


ASJ sisteminde cam kesme için yapılan modellemede 67'si eğitim verileri olmak üzere toplam 84 adet veri kullanılmıştır. LM algoritması kullanılarak yapılan eğitim sonucunda elde edilen YSA değerlerinde, kesme (ilerleme) hızı ile gerçek kesme hızı değerleri arasındaki ilişki Şekil 3'de, SCG algoritması kullanılarak yapılan eğitim sonuçları ise Şekil 4'de gösterilmiştir.



Şekil 3. Gerçek kesme hızının YSA sonuçlarıyla karşılaştırılması (Eğitim-YSA-LM)




Şekil 4. Gerçek kesme hızının YSA sonuçlarıyla karşılaştırılması (Eğitim-YSA-SCG)

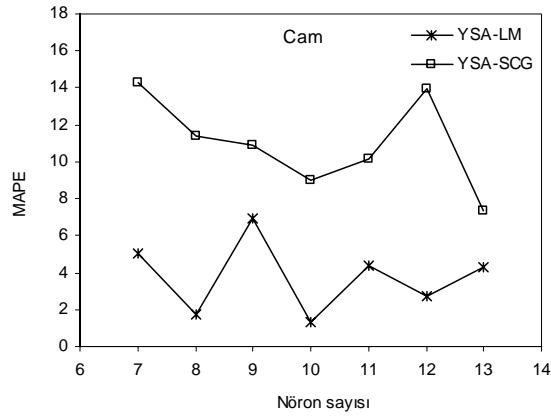


Şekil 5. Gerçek kesme hızının YSA sonuçlarıyla karşılaştırılması (Test-YSA-LM)

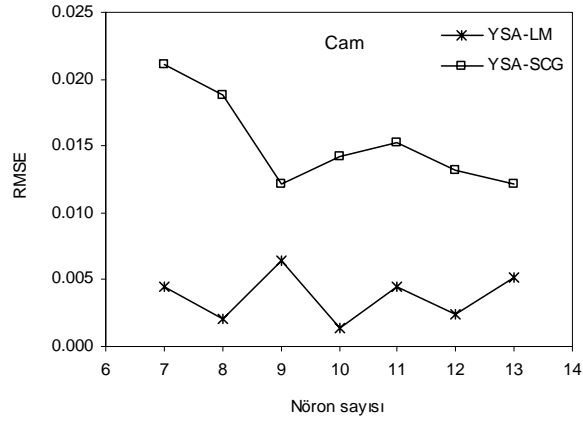
Cam kesmeye ait toplam 84 verinin 17 tanesi test verileri olarak seçilmiştir. YSA değerleriyle gerçek veriler arasında her iki algoritma için elde edilen ilişki, Şekil 5 ve Şekil 6' da gösterilmiştir. Gerçek verilerle YSA değerleri karşılaştırıldığında, LM algoritmasının SCG' ye göre çok daha başarılı olduğu açıkça görülmektedir. Cam kesme için oluşturulan YSA sisteminde test değerleri dikkate alınarak, en iyi ağ yapısında ortalama mutlak yüzde hatanın (MAPE) nöron sayısına göre değişimi Şekil 7' de gösterilmiştir. Oluşturulan en iyi ağ yapısında, LM algoritması için 10 nöronda, SCG algoritması için ise 13 nöronda, MAPE değerinin minimum değerleri elde edilmiştir. Bu modellemede kullanılan test değerleri, toplam veri setinden rastgele seçilmiştir.



Şekil 6. Gerçek kesme hızının YSA sonuçlarıyla karşılaştırılması (Test-YSA-SCG)




Şekil 7. Farklı algoritmalar için MAPE değerinin nöron sayısına göre değişimi (Test)




Şekil 8. Farklı algoritmalar için RMSE değerinin nöron sayısına göre değişimi (Test)

Test değerlerindeki Nöron sayısı–RMSE arasındaki ilişki, Şekil 8’de gösterildiği üzere RMSE, LM için 10 nörona, SCG için 9 nörona optimum değere ulaşmaktadır. Bir başka deyişle, en küçük RMSE değerinde minimum hata elde edilmektedir.




Şekil 9. Korelasyon katsayısının değişimi (R^2 – Eğitim – YSA)

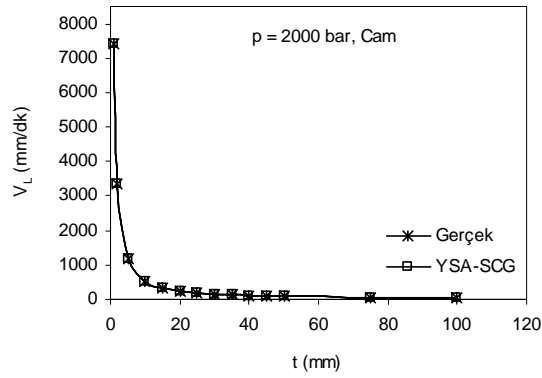


Şekil 10. Korelasyon katsayısının değişimi (R^2 – Test – LM)


Şekil 9 ve Şekil 10’da sırasıyla, eğitim ve test değerleri için korelasyon katsayısının değişimi gösterilmiştir. YSA değerlerindeki ortalama mutlak hatanın minimum değerinde $R^2 = 1$ ’e yaklaşır. Eğitim ve test değerlerindeki hata sırasıyla, LM için % 0,12 – % 1,34 arasında değişirken SCG için % 2,59 – % 7,36 arasında değişmektedir.



Şekil 11. Gerçek kesme hızının kalınlığa göre değişimi ($p = 2000$ bar, YSA-LM)




Şekil 12. Gerçek kesme hızının kalınlığa göre değişimi ($p = 2000$ bar, YSA-SCG)



Şekil 13. Gerçek kesme hızının kalınlığa göre değişimi ($p = 4000$ bar, YSA-LM)

Sabit çalışma basıncında (2000 bar) kesilen cam için elde edilen YSA sonuçları Şekil 11 ve 12’de gösterilmiştir. 4000 bar sabit basınçta; kesme hızının malzeme kalınlığına göre değişimi, LM ve SCG algoritmaları için sırasıyla Şekil 13 ve 14’te verilmiştir.



Şekil 14. Gerçek kesme hızının kalınlığa göre değişimi (p = 4000 bar, YSA-SCG)


Çizelge 2. Aşındırıcı su jetiyle cam kesmede YSA değerleri

Malzeme	Cam					
Eğitim Algoritması	Levenberg-Marquardt Backpropagation (LM) Scaled Conjugate Gradient Backpropagation (SCG)					
Transfer Fonksiyonu	Tansig (Hyperbolic tangent sigmoid)			Gizli tabaka		
Transfer Fonksiyonu	Purelin (Linear transfer fonksiyonu)			Çıkış tabaka		
LM	Eğitim			Test		
Neuron Sayısı	MAPE	RMSE	R ²	MAPE	RMSE	R ²
7	0,71	0,0019	1	5,03	0,00451	0,99910
8	0,77	0,0023	1	1,72	0,00210	0,99980
9	0,53	0,0015	1	6,92	0,00644	0,99820
10	0,24	0,0005	1	1,34	0,00138	0,99992
11	0,57	0,0020	1	4,36	0,00447	0,99912
12	0,12	0,0003	1	2,76	0,00238	0,99975
13	0,25	0,0007	1	4,27	0,00512	0,99885
SCG	Eğitim			Test		
Neuron Sayısı	MAPE	RMSE	R ²	MAPE	RMSE	R ²
7	13,65	0,02953	0,99997	14,32	0,02112	0,98037
8	8,99	0,03107	0,99997	11,39	0,01885	0,98435
9	3,22	0,01377	0,99999	10,89	0,01217	0,99347
10	6,86	0,01644	0,99999	8,97	0,01424	0,99107
11	6,98	0,01688	0,99999	10,14	0,01524	0,98977
12	2,59	0,00775	1,00000	13,93	0,01320	0,99233
13	6,76	0,01643	0,99999	7,36	0,01219	0,99346

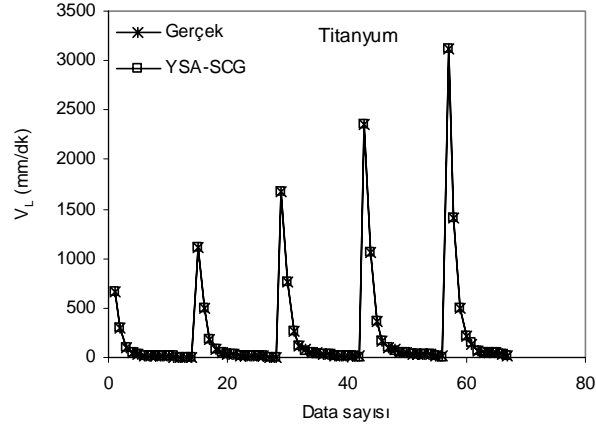
Çizelge 2’de verilen test değerleri incelendiğinde, LM algoritması için 10 nöronda, SCG algoritması için 13 nöronda, en iyi sonuçlar elde edilmiştir. LM ve SCG algoritmasında MAPE değerleri test için sırasıyla %1,34 ve %7,36 olarak hesaplanmıştır.

III.2. Titanyum Kesmede Elde Edilen YSA Sonuçları

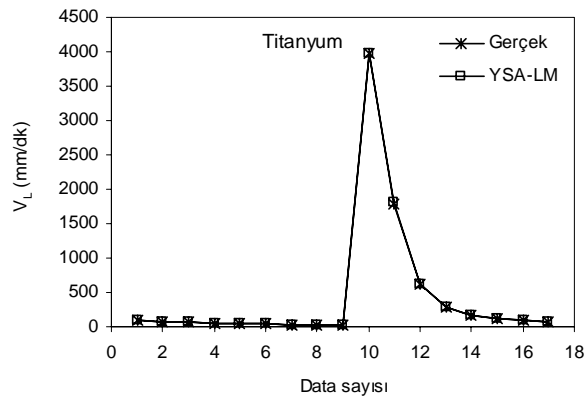
ASJ sisteminde titanyum için yapılan modellemede 67 tanesi eğitim verileri olmak üzere kullanılan 84 adet veri LM algoritmasında eğitilmiştir. Eğitim sonucunda elde edilen YSA değerlerindeki kesme (ilerleme) hızı ile gerçek kesme hızı değerleri arasındaki ilişki Şekil 15’de, SCG algoritması kullanılarak yapılan eğitim sonuçları ise Şekil 16’de gösterilmiştir. Titanyum kesmeye ait toplam 84 verinin 17 tanesi test verileri olarak seçilmiş, sırasıyla LM ve SCG algoritmalarında eğitilmiştir. YSA–gerçek veriler arasında her iki algoritma için elde edilen ilişki, Şekil 17 ve 18’de gösterilmiştir. LM algoritmasının SCG’ye göre çok daha başarılı olduğu açıkça gösterilmiştir.




Şekil 15. Gerçek kesme hızının YSA sonuçlarıyla karşılaştırılması (Eğitim-YSA-LM)




Şekil 16. Gerçek kesme hızının YSA sonuçlarıyla karşılaştırılması (Eğitim-YSA-SCG)



Şekil 17. Gerçek kesme hızının YSA sonuçlarıyla karşılaştırılması (Test-YSA-LM)

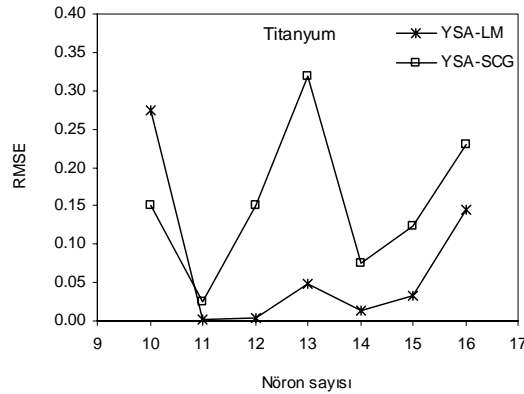


Şekil 18. Gerçek kesme hızının YSA sonuçlarıyla karşılaştırılması (Test-YSA-SCG)




Şekil 19. Farklı algoritmalar için MAPE değerinin nöron sayısına göre değişimi (Test)


Titanyum kesme için oluşturulan YSA sisteminde test değerleri dikkate alınarak, en iyi ağ yapısında ortalama mutlak yüzde hatanın (MAPE) nöron sayısına göre değişimi Şekil 19’da verilmiştir. Oluşturulan en iyi ağ yapısında, LM algoritması için 12 nöronda, SCG algoritması için ise 13 nöronda, MAPE değerinin minimum değerleri elde edilmiştir. Bu modellemede kullanılan test değerleri, toplam veri setinden rastgele seçilmiştir. Test değerleri için Nöron sayısı–RMSE arasındaki ilişki, Şekil 20’de verildiği üzere RMSE, LM için 11 nöronda, SCG için 11 nöronda optimum değere ulaşmaktadır. Bir başka deyişle, en küçük RMSE değerinde minimum hata elde edilmektedir. Şekil 21 ve 22’de sırasıyla, eğitim ve test değerleri için korelasyon katsayısının değişimi gösterilmiştir. Eğitim ve test değerlerindeki hata sırasıyla; LM için %0,03 – %1,05 arasında değişirken, SCG için %5,68 – %5,30 arasında değişmektedir.




Şekil 20. Farklı algoritmalar için RMSE değerinin nöron sayısına göre değişimi (Test)




Şekil 21. Korelasyon katsayısının değişimi (R^2 – Eğitim – YSA)



Şekil 22. Korelasyon katsayısının değişimi (R^2 – Test – LM)




Şekil 23. Gerçek kesme hızının kalınlığa göre değişimi ($p=2000$ bar, YSA-LM)




Şekil 24. Gerçek kesme hızının kalınlığa göre değişimi ($p=2000$ bar, YSA-SCG)

Sabit çalışma basıncında (2000 bar) kesilen titanyum için elde edilen YSA sonuçları Şekil 23 ve 24'de gösterilmiştir. Kesme hızının kalınlığa göre değişimi, LM ve SCG algoritmaları kullanılarak değerlendirilmiştir.



Şekil 25. Gerçek kesme hızının kalınlığa göre değişimi ($p=4000$ bar, YSA-LM)



Şekil 26. Gerçek kesme hızının kalınlığa göre değişimi ($p=4000$ bar, YSA-SCG)

4000 bar sabit basınçta, kesme hızının malzeme kalınlığına göre değişimi, LM ve SCG eğitim algoritmaları için sırasıyla Şekil 25 ve 26'da gösterilmiştir. Çizelge 3'de verilen test değerleri incelendiğinde, LM algoritması için 12 nöron, SCG algoritması için 11 nöron sayısında, en iyi sonuçlar elde edilmiştir. LM ve SCG algoritmalarında MAPE test değerleri sırasıyla, %1,05 ve %5,30 olarak hesaplanmıştır.

Çizelge 3. Aşındırıcı su jetiyle titanyum kesmede YSA değerleri

Malzeme	Titanyum					
Eğitim Algoritması	Levenberg-Marquardt Backpropagation (LM) Scaled Conjugate Gradient Backpropagation (SCG)					
Transfer Fonksiyonu	Tansig (Hyperbolic tangent sigmoid)			Gizli tabaka		
Transfer Fonksiyonu	Purelin (Linear transfer fonksiyonu)			Çıkış tabaka		
LM	Eğitim			Test		
Neuron Sayısı	MAPE	RMSE	R ²	MAPE	RMSE	R ²
10	0,873	0,000222	1	3,143	0,27424	0,9348
11	0,200	0,000084	1	1,261	0,00277	1,0000
12	0,196	0,000083	1	1,050	0,00327	1,0000
13	0,209	0,000052	1	1,526	0,04784	0,9980
14	0,140	0,000039	1	1,458	0,05437	0,9989
15	0,202	0,000049	1	1,371	0,03337	0,9990
16	0,031	0,000009	1	5,369	0,14446	0,9819
SCG	Eğitim			Test		
Neuron Sayısı	MAPE	RMSE	R ²	MAPE	RMSE	R ²
10	10,087	0,00238	0,99998	10,947	0,15042	0,9804
11	5,681	0,00195	0,99999	5,308	0,02443	0,9995
12	14,612	0,00466	0,99994	18,892	0,15084	0,9803
13	11,104	0,00421	0,99995	15,505	0,31892	0,9119
14	8,222	0,00228	0,99999	9,461	0,07605	0,9950
15	16,382	0,00510	0,99993	18,576	0,12405	0,9867
16	13,118	0,00515	0,99993	21,888	0,23086	0,9538

V. SONUÇ ve İRDELEME

Yapılan çalışmada, çok iyi eğitilmiş bir YSA modeliyle elde edilen değerler ile gerçek veriler karşılaştırılmış ve mükemmel sonuçlar bulunmuştur. Yapay sinir ağları yönteminde, en iyi ve hızlı öğrenen algoritma tipinin LM (Levenberg-Marquadt) olduğu bilinmektedir. Bu çalışmada; LM eğitim algoritmasıyla eğitilerek elde edilen en ideal ağ sistemine ait test değerlerinin cam ve titanyum için sırasıyla %1,34; %1,050 ortalama mutlak hatayla yani %98,66; %98,95 doğrulukla elde edilmiştir. Aynı şekilde ortalama karekökteki yüzde hata (RMSE) değeri 0,00138; 0,00277 olarak hesaplanmıştır. SCG (Scaled conjugate gradient backpropagation) algoritmasında eğitilen aynı verilerin test değerleri cam ve titanyum için sırasıyla %7,36; %5,30 ortalama mutlak hatayla yani %92,64 ; %94,7 doğruluk yüzdesiyle elde edilmiştir. Aynı şekilde ortalama karekökteki yüzde hata (RMSE) değeri 0,01217; 0,02443 olarak hesaplanmıştır. Yapılan modellemede her iki algoritma tipi incelendiğinde, en iyi ağ sistemindeki test değerlerine ait ortalama mutlak hatanın %1,05 ile %1,34 arasında bulunması, YSA modelinin doğruluk yüzdesi ile eğitim performansının çok yüksek olduğunu göstermektedir. Ayrıca, özellikle YSA ile test edilen verilerdeki ortalama yüzde hatalar (MAPE-RMSE-R²) arasındaki değişimin, son derece uyumlu olduğu da verilen çizelgelerde görülmektedir. Bir başka deyişle, ortalama mutlak hatanın düşmesiyle, ortalama karekökteki yüzde hata da azalmakta, fakat buna karşılık korelasyon katsayısındaki değişim yüzdesi artmaktadır. Burada kullanılan YSA modeli yardımıyla, bu çalışmada yer alan herhangi bir malzemenin, istenilen basınçta ve kalınlıktaki ilerleme değerlerini sırasıyla SCG ve LM algoritmalarında eğiterek, %92,64÷%98,95 doğruluk yüzdesiyle tahmin etmek mümkün olacaktır. İlerleme değerlerinin tahmin edilmesi demek, kesilecek malzeme yüzeyi kalitesinin de bilinmesi anlamına gelir. Bilindiği üzere, aşındırıcı su jetiyle kesme işleminde ilerleme hızı arttıkça, yüzeyde meydana gelen çizikler ve buna bağlı olarak, yüzey pürüzlülüğü değerleri de artmakta, yani yüzey kalitesi azalmaktadır. Bu modellemede ayrıca nozul çapı, karıştırma tüpü çapı ve aşındırıcı kütleli debisine ait değerler değiştirilerek, bunlara karşılık gelen su basıncı ve malzeme kalınlıkları da, yine çok iyi sonuçlar verecek şekilde tahmin edilebilir.

VI. KAYNAKLAR

- [1] H.S.Ergür, “Aşındırıcı su jetinin teorik analizi ve yapay sinir ağı yöntemiyle modellenmesi”, Eskişehir Osmangazi Üniversitesi, Doktora Tezi, Eskişehir, 2007.
- [2] Machinability data center, “*Machining data handbook*”, 3rd edition, Vol.2, , Techsolve, Inc., Cincinnati, OH, 1980.
- [3] C. Öjmerts, “AWJ machining”, Licentiate Thesis, Chalmers Univ. of Techn., 1994.
- [4] C. Öjmerts, “Analysis of surfaces produced by abrasive waterjet milling techniques”, *Proceedings of 13th International Conference on Jet Cutting Technology*, Sardinia, Italy, pp. 753-768, 1996.
- [5] F.X. Diebold, and Mariano, “Comparing predictive accuracy”, *Journal of Business and Economic Statistics*, vol.13, pp. 253-264, 1995.
- [6] S. Gülseçen, “Yapay sinir ağlarının işletme alanında uygulanması ve bir örnek çalışma”, Doktora tezi, İstanbul Üniversitesi, 1993.
- [7] M.L Minsky, and S.A. Papert, “*Perceptrons*”, Cambridge, MA: MIT Pres., 1969.
- [8] E. Öztemel, “*Yapay sinir ağları*”, Papatya Yayıncılık, İstanbul, 2003.
- [9] www.omax corporation, “Water requirements”, 2005.