

Ray Haddelme Sisteminin BD1 Bölümünde Devir Sayısının Yapay Sinir Ağı ile Tahmin Edilmesi

*¹Hüseyin Altınkaya, ²Dursun Ekmekci ve ³Mustafa Yılmaz

¹Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Karabük Üniversitesi, Karabük, Türkiye

²Mühendislik Fakültesi, Bilgisayar Mühendisliği Karabük Üniversitesi, Karabük, Türkiye

*³Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Karabük Üniversitesi, Karabük, Türkiye

Özet

Bu çalışmada sıcak haddelme işlemlerinin en karmaşık türlerinden biri olan ray haddelme işlemlerinde farklı cinsteki rayların üretim parametrelerinin Yapay Sinir Ağı (YSA) ile modellenerek başka cinsteki bir ray için devir sayısı değerlerinin elde edilmesi amaçlanmıştır. Bunun için Kardemir A.Ş.'de bulunan Ray ve Profil Haddehanesinden alınan veriler kullanılmıştır. 60 kg/m, 54 kg/m, 46 kg/m, 33 kg/m tipindeki rayların BD1 (ön haddelme) bölümüne ait her bir paso için ezme miktarı, blumun kesit alanı, blumun uzunluğu ve haddelme kuvveti parametreleri kullanılarak 49kg/m ray için haddelme devir sayısı değerlerine kabul edilebilir hata oranları ile ulaşılmıştır. YSA modellemesi Matlab programında gerçekleştirilmiştir.

Anahtar kelimeler: Sıcak haddelme, ray, YSA

Abstract

In this study one of the most complicated type of hot rolling process, rail rolling, is considered for modelling by means of ANN in order to estimate the rpm parameters for rolling. For this purposes data is taken from Kardemir Inc. Rail and Profile Hot Rolling Section. The defined parameters, which are draught per pass, cross section of the bloom, length of the bloom and force, for the rail types of 60 kg/m, 54 kg/m, 46 kg/m and 33 kg/m are used for the BD1 section for each pass to estimate the rpm parameter for 49 kg/m. The model shows satisfactory results. Artificial Neural Network modeling is executed in Matlab Programming.

Key words: Hot Rolling, Rail, ANN

1. Giriş

Ağır sanayi içinde demir-çelik sektörü, ürün yelpazesi, üretilen malzemenin miktarı ve toplam ciro ile birlikte dünyadaki en büyük ve önemli sektörlerden biri olarak karşımıza çıkmaktadır. Haddelme bu sektörün içinde çok önemli bir yere sahiptir. Demirin mamul hale getirilmesinde çok önemli bir aşamayı içinde barındıran bu süreçte yapılacak olan iyileştirmeler maliyet ve üretim süresinin optimize edilmesine büyük katkı sağlayacaktır.

Haddelme işlemlerinde standartlara uygun sonuçlar alabilmek için, çalışmayı etkileyen tüm parametrelerin uygun şekilde düzenlenmesi gerekmektedir. Konuyla ilgili çalışmalarda ve sektörde edinilen tecrübelerde, malzemenin cinsi ve elde edilmek istenen geometrik şekle bağlı olarak, merdanelerin hızı, haddelme kuvveti, malzemenin sıcaklığı, sürtünme katsayısı gibi parametreler haddelme prosesinde belirleyici faktörler olarak ön plana çıkmaktadır.

*Sorumlu yazar: Adres: Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Karabük Üniversitesi, 78050, Karabük TÜRKİYE. E-posta adresi: mustafayilmaz@karabuk.edu.tr, Tel: +903704336603 Fax: +903704336604

Haddeleme sistemlerinde yapılan modelleme, simülasyon ve optimizasyon çalışmalarında, genellikle işlenen malzemenin kimyasal yapısı, haddeleme kuvvetinin ürüne etkisi, malzeme üzerindeki sıcaklık dağılımı, üretim sürecinde oluşan deformasyon bölgesinin belirlenmesi gibi sürecin yalnızca bir ya da birkaç parametresi üzerinde çalışılmıştır. Malzemenin hazırlanmasından mamul hale gelinceye kadar olan süreci bir bütün olarak ele alıp, tüm parametreler dikkate alınarak yapılan çalışmaların sayısı yok denecek kadar azdır.

Genel olarak İkonik Model, Analog Model ve Sembolik Model olmak üzere üç yöntem haddeleme sistemlerinin modellenmesinde kullanılmaktadır [1]. Sıcak haddeleme sisteminin analizi, simülasyonu ve optimizasyonu ile ilgili literatür incelemesinde en çok kullanılan yöntemin sonlu elemanlar metodu (SEM) olduğu görülmektedir. Burada genellikle üst sınır (upper bound), en küçük kareler (least squares) ve katlı regresyon (storey regression) metotları kullanılmaktadır. SEM kadar yaygın olmamakla birlikte, modern sezgisel yöntemler olan Yapay Sinir Ağı (YSA) ve Bulanık Mantık gibi yapay zekâ tekniklerinin kullanımı tek başına ya da SEM ile birlikte kullanımı dikkate değer şekilde artış göstermiştir.

Sıcak haddeleme sürecinde durum görüntüleme yeni bir konsept üzerinde yapılan çalışmada, bütün faktörlerin detaylı analizine dayanan bir durum görüntüleme önerilerek, sürecin işleyişinin olması gereken çalışma aralığından ayrılması durumunda mevcut durum değerlendirilerek alarm verilmesi sağlanmıştır. Bu çalışmada Yapay Sinir Ağlarının SOM (Self Organising Maps) algoritması kullanılmıştır. Kullanılan algoritma, çok kompleks sıcak haddeleme analizi için uygun bir yapıda olmakla birlikte, SOM uygulamasının pürüzsüzlük, biçim, yoğunluk gibi kaliteyi etkileyen faktörlerin gizli bağlantılarını ortaya koymaya yardımcı olduğunu da ortaya çıkarmıştır [2].


Yapay Sinir Ağları ile sıcak haddeleme sürecinde malzeme ve enerji tasarrufunun nasıl yapılabileceği üzerinde yapılan bir çalışmada, haddelemede etkili olan parametrelerin optimizasyonda kullanılabileceği gösterilmiştir. Bu çalışmada yüz bin çeşit profilden alınan veriler üzerinde yapılan analizde, haddeleme kuvvetinin RMS hatalarının YSA yaklaşımında konvansiyonel yöntemlere göre % 28'e varan oranlarda iyileşmeler olduğu tablo olarak gösterilmektedir [3].

Yapılan çalışmalardan birinde ise AA5083 alüminyum alaşımının sıcak haddeleme sürecinin hem simülasyonu ve hem de Yapay Sinir Ağı ile modellemesini yapabilmek için işlemde etkili olan parametrelerin tahmini için, simülasyondan elde edilen sonuçlarla YSA' dan elde edilen veriler mukayese edilmiştir. Simülasyon yöntemi olarak sonlu elemanlar metodu kullanılırken, modelin oluşturulması için slabın (kütüğün) geometrik şekli, haddeleme yükü, haddeleme hızı, sürtünme katsayısı, ezilme oranı ve malzemenin ilk kalınlığı gibi veriler tercih edilmiştir. SEM ve YSA ile deformasyon bölgesindeki sıcaklık dağılımı ve gerilme grafikleri ayrı ayrı elde edilmiş ve elde edilen sonuçların birbirleriyle büyük oranda benzeştiği görülmüştür. Bu çalışmada SEM'den elde edilen sonuçlar YSA'nın giriş verileri olarak kullanılmıştır. Giriş olarak sürtünme katsayısı, haddeleme hızı, ezme oranı ve ilk sıcaklık bilgileri kullanılırken ağın öğrenmesinde geri yayılım (back propagation) kuralını tercih etmişlerdir. Ağın eğitimi için 25 adet örnek kullanılırken, test için 12 adet örneğin kullanıldığı görülmektedir [4].

Sıcak haddeleme sürecinde deneysel olarak alınan verilerle yapay sinir ağı ile modellemesinden alınan sonuçların karşılaştırıldığı bir çalışmada, deneysel modeldeki haddeleme kuvveti, tork ve kütük sıcaklığı parametrelerine ait gerçek değerler alınmış ve aynı parametrelere ait değerlerin YSA kullanılarak da tahmin edilebileceği gösterilmiştir [5].

2. Haddeleme

İşlenmemiş malzemelere, bir kalıp yardımıyla kalıcı şekil verilmesine genel bir tanımlamayla haddeleme denilmektedir. Metalik özelliklere sahip işlenmemiş malzemelerin uzatılarak ürün haline getirilmesi işlemi, merdane adı verilen kalıplarla haddelenmesi sonucu gerçekleşir. Metallerden başka plastik şekil verme işleminin büyük bir kısmı da haddeleme yöntemiyle yapılmaktadır. Mamül hale getirilecek olan malzeme, birbirlerine zıt yönde döndürülen iki veya daha çok silindirin arasından belli tekrar sayılarında geçirilerek yeniden şekillendirilir. Haddeleme işleminde öncelikli amaç, işlem görece malzemeyi sıkıştırarak daha yoğun bir hale getirmektir. Diğer bir amaç ise malzemenin kesitini azaltarak istenen forma sokulmasıdır [6,7].




Şekil 1. Haddeleme prensip şeması

Malzemenin istenilen şekli alması için, haddeleme işlemini gerçekleştiren merdaneler hızları aynı olacak şekilde birbirlerine zıt yönde dönerek hareket ederler. Merdaneler arasından geçerken basınç altında kalan ve ezilen malzeme istenilen şekli alır. Şekil 1’de de görüldüğü gibi bu silindiler arasındaki mesafe malzemenin sisteme giriş kalınlığından daha küçük olduğu için, haddelenen malzemenin çıkıştaki kalınlığı daha az olur. Şekil verme sırasında tek seferde işlemin tamamlanması genellikle mümkün olmaz. Bu nedenle işlem belli sayılarda tekrarlanmasına yani malzemenin merdaneler arasından her bir geçişine paso denir. Merdanelerle sağlanan radyal basınç kuvveti ile dolaylı bir mekanik basma işlemi uygulanarak haddeleme prosesi gerçekleştirilmiş olur.

Sıcaklık değeri yeniden kristalleşme (recrystallization) sıcaklığının altında iken yapılan haddelemeye soğuk haddeleme, malzemenin kristalleşme sıcaklığının üzerinde bir değerde ısıtılmasıyla yapılan haddelemeye de sıcak haddeleme denir [8,9,]. Metallerin şekillendirilmesinde hızlı ve daha az paso ile haddelme yapabilmek için sıcak haddeleme tercih edilmektedir. Bu yöntemle tavlama ihtiyacı duymayan malzemeler, yüksek sıcaklık sayesinde artık gerilim toplanması gibi bir sorunla da karşılaşmazlar. Soğuk haddelenen malzemeyle kıyaslandığında, sıcak haddelenen malzemenin kararlılığı daha iyi olduğu görülür. Haddelemek üzere kullanılan, sistemin girişindeki yarı mamul malzeme slab, blum, beam blank ve kütük olarak isimlendirilmektedir. Sıcak haddeleme yöntemiyle kare, yuvarlak, şerit, köşebent, yassı, çokgen, kesit, halka, I, T, U, H profil ve de ray gibi mamullerin üretimi yapılır [10].


Ray üretimi ülke ekonomisi için pek çok açıdan stratejik bir öneme sahiptir. KARDEMİR bünyesinde faaliyet gösteren Ray ve Profil Haddehanesinde 260x360 mm blum, 280x360x90 mm beam blank ve 150x150 mm kütükler ürün çeşidine göre fırına şarj edilerek tavlınır. Tufal temizleme ünitesinden geçirilen malzeme 1 ve 2. kaba hadde tezgâhları olan BD1 ve BD2 bölümünde ilk haddeleme işlemine tabi tutulur. Son bölümde, en üst düzeyde hassasiyetin sağlandığı hassas haddeleme için, bilgisayar kontrolü ile çok sıkı toleranslar arasında çalışan ve kompakt sistem prensibine göre dizayn edilmiş olan tandem hadde grubuna transfer edilir. Malzeme burada universal haddeleme ile 3 tezgâhta, yatay ve dikey 4 yönde haddelenerek istenilen şekil ve ebatla mamule hale getirilir [11].



Şekil 2. 49 kg/m ray geometrik ölçüleri


3. Yapay Sinir Ağları (YSA)

Yapay sinir ağları, sinir hücrelerini matematiksel olarak modelleyerek beynin, özellikle karar vermedeki temel işlevlerini yazılımla sağlamaya çalışan programlama tekniğidir [12]. Biyolojik bir sinir hücresi; temel olarak akson, dendrit ve sinapslardan oluşur. Bu bütünde dendrit olarak adlandırılan yapı, kendisine gelen uyarıları alan girişler, aksonlar ise diğer sinir hücrelerine bilgi taşıyan elemanlardır. Aksonla dendrit arasındaki bağlantı sinapslar aracılığıyla sağlanır. Elektrokimyasal süreçle işlemlerini gerçekleştiren beyin, milyonlarca sinir hücresine sahiptir [13]. Şekil 3.'de biyolojik bir sinir hücresi ve bölümleri gösterilmektedir [14].




Şekil 3. Biyolojik sinir hücresi ve kısımları

Yapay sinir ağları da beynin bu karmaşık modelini temel olarak tasarlanmıştır. Bir sinir hücresi Şekil 4'de gösterildiği gibi, N adet xi girişinin ağırlıklı wij toplamını alarak bu toplamı doğrusal olmayan bir f(.) fonksiyondan geçirir ve bir yj çıktısı üretir [13].



Şekil 4. Yapay sinir hücresi

Yapay sinir ağları, kullanılan yapay sinir hücresi modeli, ağ topolojisi olarak adlandırılan hücrelerin ağ yapısındaki bağlanma biçimi, ağırlıkların ayarlanması için öğrenme kuralının belirlenmesi ve hatırlama ile karakterize edilir [13]. Girdiler ve çıktılar arasında gizli katman ya da katmanlar bulunur. Her katmanın girdisi, bir aktivasyon fonksiyonundan geçerek çıktıyı oluşturur. Katmanlar arasındaki ağırlıklı toplamlar ile çıktılar bulunur. YSA'nın giriş-gizli-çıkış katmanları Şekil 5'te görülmektedir. Her sinir hücresinin bir ağırlık ve yanlılık değeri vardır ve bu ağırlıkları bulmak için değişik algoritmalar kullanılır [14].



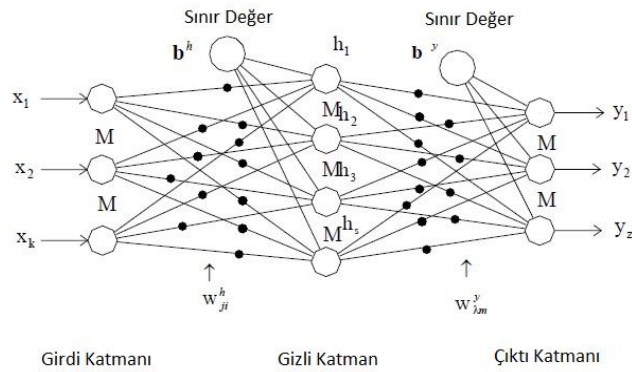
Şekil 5. Yapay sinir ağı modeli

YSA, girdi ve çıktı değişkenleri arasında herhangi bir ön bilgiye ihtiyaç duymadan, herhangi bir varsayımda bulunmadan, doğrusal olmayan (nonlinear) modellemeyi sağlayabilmektedir [15,16]. Bunu sağlayabilmek için de oluşturulan ağ'ın eğitilmesi başka bir deyişle ağırlıkların güncellenmesi gerekmektedir.

3.1. Yapay Sinir Ağlarının Eğitilmesi ve Öğrenme

Yapay sinir ağları belirli bir algoritma çerçevesinde programlanmazlar [17]. Dolayısıyla oluşturulan bir YSA'nın, hücreler arasında doğru bağlantılar yapılarak, bağlantıların uygun ağırlıklara sahip biçimde amaca uygun olarak tasarlanması gerekir. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar en baştan ideal değerlerle tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde, ilgilendiği problemten aldığı eğitim örneklerini kullanarak problemi öğrenmelidir [18]. Bir başka deyişle, ağ'a, girdi bilgileri ve bu girdilere karşılık gelen hedef değerleri verilerek ağın girdi/çıkış arasındaki ilişkiyi öğrenmesi sağlanmakta, böylece ağın uygun ağırlık değerlerini kazanarak eğitimi gerçekleştirilmektedir. Denetimli (öğreticili) öğrenme olarak adlandırılan bu yöntem, daha çok tercih yöntemidir [19]. Basitliği ve uygulamadaki görüş açısı gibi başarılarından dolayı [20] ağ eğitimi için en yaygın kullanılan modeli, ileri beslemeli – geri yayılım algoritmasıdır [15].

Geri yayılım algoritması, birbirinden bağımsız olarak ilk defa Werbos [21] ve daha sonra Rumelhart [22] tarafından önerilmiştir. 1986 yılında Rumelhart ve arkadaşlarının geri yayılım algoritmasını yeniden keşfetmeleri, algoritmanın tanınması ve kullanım yaygınlığı açısından önemlidir [23]. Algoritma prensibinde; hatalar, geriye doğru (çıkıştan girişe) azaltıldığından “geri yayılım” ismini almıştır. Geri yayımlı öğrenme kuralı, ağ çıkışındaki mevcut hata düzeyine göre her bir tabakadaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Geri yayımlı bir ağ modelinde giriş, gizli ve çıkış olmak üzere 3 katman bulunmakla birlikte, problemin özelliklerine göre gizli katman sayısı artırabilmektedir [24]. Gizli katmandaki hücre sayısını belirlemede farklı yaklaşımlar ileri sürülse de genel olarak hücre sayısı, deneme-yanılma yoluyla belirlenmektedir. Şekil 6’da örneklenen ileri beslemeli denetimli bir sinir ağında, tek ara katman ve bu katmanda s adet sinir hücresi bulunmaktadır [25].



Şekil 6. İleri beslemeli denetimli bir yapay sinir ağı

Burada, yapay sinir ağının girdi vektörü $x=(x_1, x_2, x_k)$, kullanılarak elde edilen ara katman çıktı vektörü $h=(h_1, h_2, h_3, h_s)$ çıktı katmanında işlendikten sonra çıktı vektörüne $y=(y_1, y_2, y_z)$ dönüştürülür ve göz önüne alınan tüm girdi vektörleri $X=[x(1), \dots, x(N)]$ için çıktı vektörleri $Y=[y(1), \dots, y(N)]$, N: girdi ve çıktı vektörlerinin sayısı olmak üzere aşağıdaki şekilde hesaplanır:

$$Y = \varphi(Wy[\psi(W_h X + b_h)] + b_y) \quad (1)$$

Denklem (1)'de $\varphi(\cdot)$: çıktı katmanına ait hücreler için aktivasyon fonksiyonu, $\psi(\cdot)$: ara katmana ait hücreler için aktivasyon fonksiyonu, b_h : ara katmandaki hücrelere ait sınır değer vektörü, b_y : çıktı katmanındaki hücrelere ait sınır değer vektörü, W_y : ara katman ile çıktı katmanı arasındaki bağlantılar için ağırlık faktörleri, W_h : ara katman ile girdi katmanı arasındaki bağlantılar için ağırlık faktörleri olarak alınmış olup söz konusu ağırlık faktörleri aşağıdaki şekillerde tanımlanmıştır:

$$W_h = [W_{h11K} \ W_{h1iK} \ W_{hji}] \quad j = 1..s; \quad i = 1..k \quad (2)$$

$$W_y = [W_{y11K} \ W_{y1mK} \ W_{y\lambda m}] \quad \lambda = 1..z; \quad m = 1..s \quad (3)$$

YSA uygulamaları genellikle eğitim ve test olmak üzere iki aşamada oluşturulur. Eğitim aşaması,

katmanlar arasındaki ağırlık faktörlerinin ve sınır değerlerin bir öğrenme algoritması yardımıyla hata seviyesi kabul edilebilir bir düzeye gelinceye kadar iteratif olarak düzeltilmesinden meydana gelir. Ağırlık faktörlerindeki değişim, öğrenme olarak da tanımlanabilir. Test aşamasında ise eğitim aşamasında kullanılmayan girdi ve çıktı verileri kullanılarak ağırlık performansı ölçülür. Değişik öğrenme algoritmaları olmakla birlikte momentum katsayılı gradyan azalma ve konjuge gradyan öğrenme algoritmaları yaygın kullanılan öğrenme algoritmalarına örnek verilebilir [25].

Momentum katsayılı gradyan azalma algoritması, performans indeksinin (hata fonksiyonunun) minimizasyonuna dayanır ve ağırlık faktörleri, performans indeksi gradyanının negatif doğrultusunda hareket edilmesiyle iteratif olarak düzeltilir:

$$w(k+1) = w(k) - \eta \nabla J(w) + \alpha \Delta w(k-1) \quad (4)$$

Burada, w : vektörel olarak ağırlık faktörü, k : iterasyon sayısı, η : öğrenme oranı, α : momentum katsayısı ve $\nabla J(w)$: performans indeksinin gradyanıdır. Performans indeksinin gradyanı ise ∇E : karesel hata fonksiyonunun gradyanı, N : girdi ve çıktı vektörlerinin sayısı ve z : çıktı katmanındaki hücre sayısı olmak üzere vektörel olarak Şekil 4'te verilen yapay sinir ağı için aşağıdaki şekillerde ifade edilir:


$$\nabla J(w) = \frac{1}{zN} \sum_{n=1}^N \nabla E(w, n) \quad (5)$$

$$\nabla E(w, n) = \left[\frac{\partial E}{\partial w_{h11}} \wedge \frac{\partial E}{\partial w_{hji}} \wedge \frac{\partial E}{\partial w_{y11}} \wedge \frac{\partial E}{\partial w_{y\lambda m}} \right] \quad (6)$$

Öğrenme oranı ve momentum katsayısının seçilmesinde değişik yaklaşımlar olsada bu katsayılar, genellikle 0-1 arasında değerler alacak şekilde deneme-yanılma yoluyla seçilmektedir [25].


4. Uygulama

Kardemir AŞ'de Ray ve Profil Haddehanesinin üretim tesislerinde yer alan beş çeşit rayın üretim parametrelerinden dört tanesi giriş parametresi, bir tanesi de tahmin edilmeye çalışılan çıkış parametresi olarak belirlenmiştir. Her bir paso için ezme miktarı, blumun kesit alan, blumun uzunluğu ve kuvvet giriş parametreleri olarak seçilmiş; devir sayısı (RPM) ise çıkış değeri olarak belirlenmiştir. Tasarlanan ağı, 60 kg/m, 54 kg/m, 46 kg/m, 33 kg/m tipindeki raylara ait verilerle eğitilirken, 49 kg/m tipindeki raya ait verilerle test edilmiştir. Farklı katman ve nöron sayılarıyla oluşturularak denenen ağı optimal tasarımında, 8 nöronun yer aldığı 1 adet gizli katman ve 1 adet çıkış katmanı bulunmaktadır. Tasarlanan ağı, Şekil 7'de gösterilmektedir.

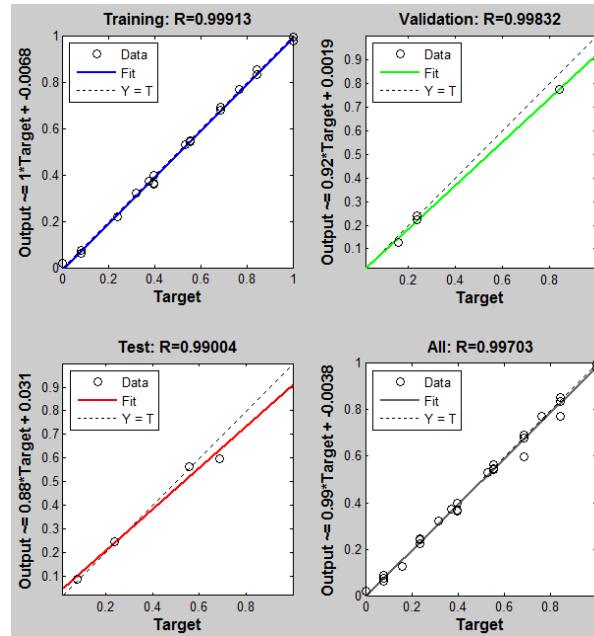


Şekil 7. Çözüm için tasarlanan YSA modeli

Tahmine dayalı akıllı sistem tasarımlarındaki kullanım yaygınlığı ve performansı göz önünde bulundurularak öğrenme kuralı için 3. Bölümde anlatılan ileri beslemeli geri yayılım metodu seçilmiş, sonlanma kriteri için iterasyon sayısı 100 olarak belirlenmiştir. Farklı geri yayılım öğrenme algoritmalarıyla denenen modelden alınan en iyi sonuçların, Levenberg-Marquardt (LM) algoritmasıyla bulunduğu gözlemlenmiştir. Algoritma, 19 iterasyonda sonlanmış, en iyi doğruluk performansına 13. İterasyonda 0,001556 değeriyle ulaşmıştır. Bu iterasyonların sonuçları, gradient değerleri ve algoritma regresyon oranları aşağıdaki şekillerde verilmiştir.



Şekil 8. İterasyonlarla elde edilen sonuçlar

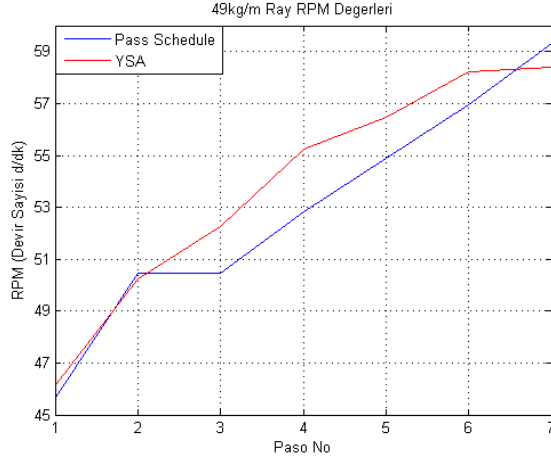


Şekil 9. İterasyonlardan elde edilen regresyon değerleri

Her bir paso için elde edilen sonuçlar ve hata oranları Çizelge 1’de, çizelge verileriyle elde edilen grafik ise Şekil 10’da gösterilmektedir.

Çizelge 1. Levenberg-Marquardt algoritmasıyla elde edilen sonuçlar ve hata oranları

RPM	Pass Schedule	YSA	Hata Oranı(%)
Paso 1	45.64	46.12	1.0
Paso 2	50.45	50.25	0.4
Paso 3	50.45	52.27	3.6
Paso 4	52.85	55.24	4.5
Paso 5	54.87	56.48	2.9
Paso 6	56.94	58.21	2.2
Paso 7	59.31	58.42	1.5

**Şekil 10.** Her bir paso için ölçülen değerler ve YSA sonuçları

5. Sonuç

Bu çalışmada 60 kg/m, 54 kg/m, 49kg/m, 46 kg/m, 33 kg/m olmak üzere beş farklı tip raydan dördüne ait üretim parametreleri kullanılarak 49 kg/m ray türüne ait üretim değerleri için doğru sonuçların elde edilebilmesinin mümkün olduğu gösterilmiştir. 49 kg/m rayın devir sayısının (RPM) bulunabilmesi için YSA modeli tasarlanmış, modelden elde edilen sonuçlar, üretim değerleri ile karşılaştırıldığında makul hata değerleriyle sonuçlar alındığı görülmüştür. Hata oranlarının küçük olması modelin güvenilirliğini ortaya koymaktadır. Çıkış parametresi olarak alınan devir sayısının doğru olarak bulunabilmesi için giriş parametrelerinin belirlenmesindeki tercihlerin sonuçlar üzerinde önemli ölçüde belirleyici etken olduğu sonucuna ulaşılmıştır.

Kaynaklar

- [1] E. Turban, J.E. Aranson, T.P. Liang, "Decision Support Systems and Intelligent Systems", Pearson Education Inc., New Jersey, Seventh Edition, (2005).
- [2] L. Cser, A.S. Korhonen, J. Gulyas, P. Mantyla, O. Simula, Gy. Reiss, P. Ruha, "Data Mining and State Monitoring in Hot Rolling", Bay Zoltan Institute for Logistics and Production Systems, H3519, Miskolc- Tapolca, Hungary, (1999).
- [3] Martinecz T., Protzel P., Gramckow O., Sörgel G., "Neural Network Control for Rolling Mills", Siemens AG Corporate R&D, München, Germany (1994).

- [4] A.R. Shahani, S. Setayeshi, S.A. Nodamaie, M.A. Asadi, S. Rezaie, "Prediction of Influence Parameters on the Hot Rolling Process Using Finite Element Method and Neural Network", *Journal of Materials Processing Technology* (2009) 1920-1935.
- [5] E. Öznergiz, C. Özsoy, A. Kural, "Comparison of Emprical and Neural Network Hot-Rolling Process Models", DOI: 10.1243/09544054JEM1290, 2008.
- [6] Zygmunt Wusatowski, "Fundamentals of Rolling", PergamonPress.
- [7] Aydoğan İ. K., "Haddeme Prosesinde Malzeme Karakteristiklerindeki Değişimlerin İncelenmesi ve Modellenmesi", Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2007.
- [8] [http://en.wikipedia.org/wiki/Recrystallization_\(metallurgy\)](http://en.wikipedia.org/wiki/Recrystallization_(metallurgy)).
- [9] [http://en.wikipedia.org/wiki/Rolling_\(metalworking\)](http://en.wikipedia.org/wiki/Rolling_(metalworking)).
- [10] <http://www.kardemir.com/frmTesis.aspx?id=4&SectionID=tesis>
- [11] Orak, İ.M., Altinkaya, H. ve Tozlu, İ., "Ray Haddeme Sisteminde Ön Haddeme (BD1) İşleminin Yapay Sinir Ağı ile Modellenmesi", 6th International Advanced Technologies Symposium (IATS'11), s. 223-226, 16-18 May 2011, Elazığ, 2011.
- [12] Civalek, Ö., "Nöro-Fuzzy Tekniği ile Dikdörtgen Plakların Analizi", III. Ulusal Hesaplamalı Mekanik Konferansı, 16-18 Kasım, İstanbul, 518-524, 1998.
- [13] Ülker, M., Civalek, Ö., "Yapay Sinir Ağları ile Eksenel Yüklü Kolonların Burkulma Analizi", *Turkish J. Eng. Env. Sci.* 26 (2002), 117-125. Tubitak
- [14] Keleşoğlu, Ö., Ekinci, C. E., Fırat, A., "The Using of Artificila Neural Networks in Insulation Computations", *Journal of Engineering and Natural Sciences Mühendislik ve Fen Bilimleri Dergisi*, 2005/3
- [15] Barış, İ., Erdamar, M., Sümer, E., Erdem, H., "Ses İşaretlerinin Yapay Sinir Ağları ile Tanınması ve Kontrol İşlemleri İçin Kullanılması",
- [16] Kaastra, I., Boyd, M., "Designing a Neural Network for Forecasting Financial and Economic Time Series", *Neurocomputing*, Cilt 10, 215-236, 1996.
- [17] Rojas, R., "Neural Networks, A Systematic Introduction", Springer, Germany, 1996.
- [18] Ergezer, H., Dikmen, M. ve Özdemir, E. (2003). "Yapay Sinir Ağları ve Tanıma Sistemleri" *PİVOLKA*, 2(6), 14-17.
- [19] Haykin, S., "Neural Networks: A Comprehensive Foundation", Perenctice Hall, New Jersey, 1999.
- [20] Aktaş, M., Okumuş, H. İ. (2003). "Doğrudan Moment Kontrollü Asenkron Motorun Stator Direncinin Yapay Sinir Ağı ile Kestirimi", *International XII. Turkish Symposium on Artificial Intelligence and Neural Networks*.
- [21] Werbos, P.J., *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*, PhD thesis, Harvard University, 1974.
- [22] Rumelhart, D.E., Hinton, G.E., Williams, R.J., "Learning Internal Repesantation by Back-Propagating Errors", In: Rumelhart D.E., McClelland J.L., *Paralel Distributed Processing: Explorations in the Microstructure of Cognition*, MIT Press, MA, 1986.
- [23] Hamzaçebi, C., Kutay, F., "Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini", *Gazi Üniv. Müh. Mim. Fak. Der. Cilt 19, No 3*, 227-233, 2004
- [24] Keleşoğlu, Ö., Fırat, A., "Tuğla Duvardaki ve Tesisattaki Isı Kaybının Yapay Sinir Ağları İle Belirlenmesi", *Fırat Üniv. Fen ve Müh. Bil. Der.* 18 (1), 133-141, 2006
- [25] Koç, M. L., Balas, C. E., Arslan, A., "Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı", *İMO Teknik Dergi*, 2004 3351-3375, Yazı 225