

## Soğuk Haddeme Sürecinde Alüminyum Folyonun Çıkış Kalınlığının Yapay Sinir Ağı Yardımıyla Tahmin Edilmesi

### Output Thickness Prediction of Aluminium Foil Using Artifical Neural Network in Cold Rolling Process

*Ali ÖZTÜRK<sup>1</sup>, Kadir ÇINAR<sup>2</sup>*

<sup>1</sup> Bilgisayar Mühendisliği Bölümü  
KTO Karatay Üniversitesi  
ali.ozturk@karatay.edu.tr

<sup>2</sup> Metalürji ve Malzeme Mühendisliği Bölümü  
Selçuk Üniversitesi  
kcinar73@hotmail.com

#### Özetçe

Bu çalışmada, soğuk hadde makinesini kontrol eden PLC devresinin sürdüğü Mill motoru, Açıcı-1 Ön, Açıcı-1 Arka, Açıcı-2, Sarıcı Ön ve Sarıcı Arka motorlarına uygulanan armatür ve alan akımları değerlerini kullanarak alüminyum folyonun çıkış kalınlığını çok katmanlı algılayıcı yapay sinir ağı yardımı ile tahmin eden bir yöntem önerilmiştir. Hadde makinesindeki DC motorların dönüş hızı armatür akımıyla doğru, alan akımıyla test orantılıdır. Tüm motorlar için armatür akım ve alan akımı değerleri ile alüminyum folyo çıkış kalınlığı 1 saniyelik periyotlarla PLC yazılımının bulunduğu bilgisayarda kaydedilmiştir. Çıkış kalınlığı, alüminyum folyonun haddeme merdanelerinden geçişi esnasında x-ışını cihazı yardımıyla ölçülmektedir. Yaklaşık 124 dakika boyunca kaydedilen verilerle toplam 7426 örneklemden oluşan veri kümesi elde edilmiştir. Bu verilerin 4901 adeti eğitim, geri kalan 2525 adeti de test amacıyla kullanılmıştır. Eğitim kümesi verileri kullanılarak eğitilen yapay sinir ağı, test kümesi verileri ile test edilmiştir. Tahmin sonuçları PLC'nin kaydettiği kalınlık verileriyle karşılaştırılmış ve tatmin edici sonuçlar elde edilmiştir.

**Anahtar Kelimeler:** Yapay Sinir Ağları; Kalınlık Tahmini; Soğuk Haddeme; Alüminyum Folyo

#### Abstract

In this study, a method for output thickness prediction of aluminium foil via multilayer perceptron neural network in cold rolling process is proposed. The DC motors, namely mill motor, front motor of first coiling, back motor of first coiling, second coiling motor, front motor of uncoiling and back motor of uncoiling, of the cold rolling machine are driven by ADC drivers which are controlled by PLC. The rotation of the DC motors are directly proportional to armature current and inversely proportional to field current. The armature and field current values for all motors and the output thickness of the aluminium foil are recorded on the PC where PLC software resides. The output thickness of the aluminium foil is measured via x-ray device while the foil is passing through the rolling mill. The data was recorded approximately for 124 minutes giving 7426 instances in total. The whole data set was divided into the training subset including 4901 instances and the test subset including 2525 instances. The thickness prediction

data was compared with the PLC recorded data and satisfactory results were found.

**Keywords:** Artificial Neural Networks; Thickness Prediction; Cold Rolling; Aluminium Foil

#### 1. Giriş

Alüminyum folyo, havacılık ve uzay bilimlerinde, taşımacılıkta, paketleme ve basımda, endüstriyel robotlarda, enerji mühendisliğinde, okyanus bilimlerinde, vs [1] su, hava ve ışık geçirmeme özelliğinden dolayı yaygın olarak kullanılmaktadır. Folyo ne kadar inceyse, o kadar pahalı olmakta ve daha özelleşmiş alanlarda kullanılmaktadır. Ayrıca, örneğin 6.35 mikron kalınlığında alüminyum folyonun sigara paketleri ve sıvı ürün paketlerinde kullanımı standartlarla zorunlu hale gelmiştir. İstenen alüminyum folyo kalınlığını yakalamak için, dökümden başlayarak haddeme ve dilmeye kadar, tüm sürecin kalitesi çok önemlidir [2]. Bu çalışmada kullanılan soğuk hadde makinesi değişik erişim düzenekleri, PLC kontrollü aygıtlar gibi pek çok cihaz yanında, hidrolik ve yağlama ünitelerinden oluşmaktadır. Bir soğuk haddeleme makinesi temel olarak, PLC-kontrollü DC motorlar tarafından sürülen değişik çap ve boyutta merdaneler içermektedir [3].

Bu çalışmada kullanılan haddeme makinesinde 6 DC motor tipi mevcuttur. Bunlar mill motoru, sarıcı ön motor, sarıcı arka motor, açıcı-1 ön motor, açıcı-1 arka

motor ve açıcı-2 motordur. Bu motorların dönme hızları PLC tarafından kontrol edilen ADC sürücülerin sağladığı armatür ve alan akımları ile değişmektedir. Bu dönme hızlarının kontrolü sayesinde, folyonun bant üzerindeki gerilmesi de kontrol edilmiş olmaktadır [4].

## 2. Soğuk Haddede Motor Hızlarının Kontrolü

Germe, levha kalınlığının stabil kalmasına olanak sağlamaktadır. Bu faktör, germeye bağlı olan metalin hareket hızı ile sıkı sıkıya bağlantılıdır. Germe, metalin merdanelere yaptığı baskıyı düşürür. Dolayısıyla merdanelerin elastik deformasyon miktarı azalır. Germe, levhanın sarma makinası üzerinde düzgün ve sıkı bir şekilde sarılmasına da yardımcı olmaktadır.

Haddemele hızının değişmemesi halinde, levhanın çıkış hızı ile sarıcı motorun lineer hızlarını uzlaştırmak için; sarma makinası tamburunun dönüş hızını sürekli olarak azaltmak gereklidir. Levhanın açıcı motorla açılması sırasında ise makinenin açılma hızı sürekli olarak artmalıdır. Şayet açılma hızları, gerek açma gerekse sarma sırasında değişmez ise, levhadaki germe, levhayı koparıncaya kadar, hızla artar. Kopmanın olmaması ve haddemeleminin devam etmesi için hızın azaltılması gerekir [4].

Bir DC motordaki armatür devresi için voltaj denklemi

$$V = E + I_A R_A \quad (1)$$

$I_A$  armatür akımı ve  $R_A$  armatür direncidir. Voltaj cinsinden E,

$$E = K\Phi\Omega \quad (2)$$

Burada K denklem sabiti,  $\Phi$  alan akısı (alan akımı ile orantılıdır) ve  $\Omega$  radyan/saniye cinsinden motor hızıdır.

Newton-metre cinsinden, üretilen tork (T) değeri

$$T = K\Phi I_A \quad (3)$$

Denklem (1) ve (2)'yi birleştirerek, motor hızı radyan/saniye cinsinden aşağıdaki gibi elde edilir.

$$\Omega = \frac{V - I_A R_A}{K\Phi} \quad (4)$$

Denklem (4)'e göre, motor hızı armatür akım ile doğru orantılı ve alan akımı ile ters orantılı olarak değişmektedir [5].

## 3. Veri Toplama ve Normalizasyon

Haddemele makinesindeki tüm motorlar için, armatür ve alan akım değerleri ile alüminyum folyonun çıkış kalınlığı, PLC yazılımının bulunduğu PC'ye otomatik olarak kaydedilmektedir. Alüminyum folyonun kalınlık bilgisi, hadde makinesinden geçişi esnasında mill motoruna bağlı bir x-ışını cihazı yardımıyla ölçülmektedir. Makinede 6 motor olduğundan, veri kümesinde toplam 12 adet giriş verisi bulunmaktadır. Alüminyum folyonun kalınlık bilgisi ise veri kümesindeki tek çıkış özelliğini oluşturmaktadır. Aksi belirtilmediği sürece, folyo üretimi boyunca veriler PC üzerinde saniyede bir defa olmak üzere sürekli kaydedilmektedir. Bu çalışmada, yaklaşık 124 dakika boyunca kaydedilen 7426 adet örneklem içeren veri kümesi kullanılmıştır. Kalınlık bilgisi dışında yapay sinir ağı için giriş olacak akım verileri,  $\mu$  ortalama ve  $\sigma$  standart sapma olmak üzere, aşağıdaki denkleme göre normalize edilmiştir.

$$X_{Norm} = (X - \mu) / \sigma \quad (5)$$

Veri kümesi, 4901 adet eğitim verisi ve 2525 adet test verisi içerecek şekilde 2 alt kümeye bölünmüştür. Yapay sinir ağı, sırasıyla bu alt kümelerle eğitilmiş ve test edilmiştir.

## 4. Çok Katmanlı Algılayıcı Yapay Sinir Ağı

Geri yayılma ile eğitilen çok katmanlı algılayıcı [6], yapay sinir ağı sınıflandırıcıları içinde en ünlüsü ve en yaygın kullanılanıdır. Tahmin, eşleme,

tanımlama, örüntü tanıma, optimizasyon ve sınıflandırma problemlerinde yaygın olarak kullanılmışlardır [7].

Yapay sinir ağlarının tahmin başarısındaki önemli etkenlerden birisi girdilerin özelliği ve türüdür. Çok sayıda girdi, daha çok bellek ve yavaş hesaplama hızı demektir. Az veya yanlış türden girdi kullanmak ise, tahmin doğruluğunu olumsuz olarak etkileyebilir. Bu yüzden, giriş değerlerinin uygun biçimde seçilmesi, ağın genelleştirmesinin sağlanması ve hesaplama karmaşıklığının azaltılması için önemli faktörlerden birisidir [8].

Geri yayılma ile eğitilen çok katmanlı algılayıcı yapay sinir ağları, ağırlıklardaki değişikliğin çıkış düğümlerindeki gerçek ve hesaplanan değerler arasındaki farka göre yapıldığı ileri beslemeli ağlardır. Temel prensip, gerçek ve hesaplanan değerler arasındaki ortalama kare hatasının yinelemeli bir şekilde en aza indirilmesidir [9]. Sonlanma kriteri, toplam ağ hatasının belirli bir değerin altına indirilmesidir. Hata aşağıdaki gibi hesaplanır.

$$E = \frac{1}{2} \sum_j (x_o - x_i)^2 \quad (6)$$

Burada  $x_0$  çıkış değeri ve  $x_i$  gerçek (hedef) değerdir.

$\theta$  aktivasyon fonksiyonu ve  $w_{ij}$ ,  $x_i$  giriş hücreleri ve  $x_j$  çıkış hücresi arasındaki ağırlık değeri olmak üzere, bir  $x_j$  sinir hücresi için çıkış değeri

$$X_j = \theta\left(\sum_i x_i w_{ij}\right) \quad (7)$$

Bu çalışmada tüm nöronlar için aktivasyon fonksiyonu olarak sigmoid kullanılmıştır.

$$\theta(x) = \frac{1}{1 + e^{-\frac{x}{Q_0}}} \quad (8)$$

$Q_0$  terimi, sinir hücresinin sıcaklık değeridir. Sıcaklık ne kadar büyükse, sigmoid fonksiyonu o kadar yavaş değişir. Çok düşük sıcaklıklarda ise bir adım fonksiyonuna dönüşür.

Geri yayılma algoritmasında, ağırlıkların güncellenmesi aşağıdaki formüle göre yapılmaktadır.

$$\Delta w_{ji} = \eta \delta_{pj} O_{pi} \quad (9)$$

Burada  $\eta$  öğrenme oranı ve  $\delta_{pj}$ , L. katmandaki sinir hücresi için hata değeridir.

$\delta_{pj}$ , değeri çıkış katmanı ve gizli katman hücreleri için farklı hesaplanır. Çıkış katmanı hücreleri için

$$\delta_{pj} = (O_{t_{pj}} - O_{pj}) O_{pj} (1 - O_{pj}) \quad (10)$$

ve gizli katman hücreleri için

$$\delta_{pj} = O_{pj} (1 - O_{pj}) \sum_k \delta_{pk} w_{kj} \quad (11)$$


Geri yayılma algoritmasında, ağırlıklara bağlı olarak hata fonksiyonunun negatif gradienti, hata fonksiyonunu en hızlı azaltacak yönde ilerler. Gradientin sıfır olduğu minimum noktasının yerel minimum olmasını engellemek için ağırlık güncellemede aşağıdaki gibi  $\alpha$  momentum sabiti kullanılmaktadır.

$$\Delta W_{ji}(n+1) = \eta \delta_{pj} O_{pi} + \alpha \Delta W_{ji}(n) \quad (12)$$

Bu çalışmada, en doğru tahmin sonuçlarını veren öğrenme katsayısı ve momentum değerleri, sırasıyla 0.3 ve 0.2 olarak bulunmuştur.

## 5. Deneysel Sonuçlar ve Tartışma

Bu çalışmada kullanılan çok katmanlı algılayıcı yapay sinir ağının genel görünümü Şekil 1’de verilmiştir.



Şekil 1. Çalışmada kullanılan yapay sinir ağının görünümü

Toplam 12 adet akım değerinden oluşan giriş verisi için 12 giriş sinir hücresi ve tahmin edilecek kalınlık bilgisine karşılık bir adet çıkış hücresi bulunmaktadır. Ara katmanda toplam 6 sinir hücresi bulunmaktadır.


Performans değerlendirmesi için kullanılan, ortalama mutlak hata ve kök ortalama kare hata değerleri sırasıyla Denklem (13) ve Denklem (14)'e göre aşağıdaki gibi hesaplanmıştır.

$$E = \frac{1}{n} \sum_{j=1}^n |O_j - T_j| \quad (13)$$

$$E = \sqrt{\frac{1}{n} \sum_{j=1}^n (O_j - T_j)^2} \quad (14)$$

Eğitim aşaması sonucunda ortalama mutlak hata 0.0079 ve kök ortalama kare hata 0.0124 olarak bulunmuştur.

Test kümesi verileri için elde edilen hata değerleri ise, ortalama mutlak hata için 0.0085 ve kök ortalama kare hata 0.0116 olarak bulunmuştur.




Şekil 2. Eğitim kümesindeki veriler için ölçülen ve tahmin edilen kalınlık değerleri

Şekil 2’de eğitim kümesindeki veriler için gerçek ve yapay sinir ağının tahmin ettiği kalınlık değerlerinin grafiği görülmektedir. Gerçek kalınlık değerleri mavi ile, tahmin edilen kalınlık değerleri yeşil ile gösterilmiştir.

Test kümesindeki veriler için gerçek ve yapay sinir ağının tahmin ettiği kalınlık değerlerinin grafiği Şekil 3’te verilmiştir.

Elde edilen sonuçlara göre, yapay sinir ağının kullanıldığı önerilen sistem

alüminyum folyonun anlık kalınlık bilgisini, kalınlık ölçme cihazı herhangi bir nedenden dolayı devre dışı kalsa bile hadde makinesindeki motorların dönme hızını belirleyen armatür ve alan akımı değerlerini kullanarak yeterli doğrulukta tahmin edebilmektedir. Bu kalınlık bilgisi, hadde makinesi operatörleri tarafından üretimin denetlenmesinde kullanılabilir.



Şekil 3. Test kümesindeki veriler için ölçülen ve tahmin edilen kalınlık değerleri

### Kaynakça

- [1] Sun Menghui, Wang Yiqun, Zhang Wei, “Research on cascade predictive control in hydraulic AGC of cold rollingmill”, Proc of the Second IEEE Conf on Industrial Electronics and Applications, 2007:pp.2775-2780.
- [2] L.E. Zarate, “A Predictive Thickness Control Structure and Decision about the better Control Parameter for the Cold Rolling Process through Sensitivity Factors via Neural Networks”, IEEE Mid-Summer Workshop on Soft Computing in Industrial Applications, 2005.
- [3] Huang Qinxue, Liang Aisheng, High-precision Rolling Technologies, Beijing: Metallurgy Industry Press, 2004.
- [4] A.S. Filatov, “İki Yönlü Soğuk Hadde Tezgâhlarının Elektro Tahrik Sistemleri Tezgâhların Otomatikleştirilmesi”, Çeviri: Musa Özalp Etibank Alüminyum A.Ş. Eğitim Müdürlüğü Tercüme Yayınları, 1986.
- [5] Gungor Bal, “Doğru Akım Makineleri ve Sürücüler”, Seçkin Yayıncılık, 2008.
- [6] D.E. Rumelhart, J.L. McClelland, “Parallel Distributed Processing: Explorations in the Microstructure of Cognition, I & II”. MIT Press, Cambridge MA, 1986.
- [7] N.S. Marcellos, J.F. Denti, G.C. Saousa, “Strip Thickness Estimation in Rolling Mills From Electrical Variables in AC Drives”, Latin American Applied Research, 39:353-359, 2009.
- [8] B.B. Chaudhuri, U. Bhattacharya, “Efficient training and improved performance of multilayer perceptron in pattern classification. Neurocomputing”, 34: 11-27, 2000.
- [9] I.A., Basheer, M. Hajmeer, “Artificial Neural Networks: Fundamentals, computing, design and application”, Journal of Microbiology Methods. 43:3-31, 2000.