



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Doğu Kayını Ahşabının Yüzey Pürüzlülüğünün Bir Yapay Sinir Ağı ile Modellenmesi

 Abdullah Cemil İLÇE^{a,*},  Hilal SİNGER^a

^a Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi, Bolu Abant İzzet Baysal Üniversitesi, Bolu, TÜRKİYE

* Sorumlu yazarın e-posta adresi: cemil.ilce@gmail.com

DOI : 10.29130/dubited.564000

ÖZET

Bu çalışmanın amacı yapay sinir ağı (YSA) yaklaşımı ile doğu kayını (*Fagus orientalis* Lipsky) ahşabının yüzey pürüzlülüğünü modellemektir. İlk olarak, yatay bant zımpara makinesinin çalışma parametreleri (60-80-100 zımpara numarası, 4-7-10 m/dk besleme hızı ve 0,1-0,2-0,3 mm kesme derinliği) belirlenmiştir. Numunelerin yüzey pürüzlülüğü deneysel olarak kaydedildikten sonra veriler eğitim ve test veri setlerine ayrılmıştır. Daha sonra, mevcut veriler Ra, Rq ve Rz'nin tahmin değerlerini doğru bir şekilde elde etmek için YSA yaklaşımı ile modellenmiştir. Deneysel sonuçlar ile teorik bulgular arasındaki karşılaştırma ($R_{Ra} = 0,99869$, $R_{Rq} = 0,9982$ ve $R_{Rz} = 0,99882$) birbirleriyle iyi bir uyum içinde olduğunu göstermektedir. Bu bağlamda, bu çalışma, kayın yüzey pürüzlülüğünün yapay sinir ağları yaklaşımı kullanılarak çok daha yüksek doğrulukta ve daha düşük hatalarda mükemmel bir şekilde tahmin edildiğini göstermiştir.

Anahtar Kelimeler: Yüzey pürüzlülüğü, Yapay sinir ağı, Zımpara numarası, Besleme hızı, Kesme derinliği

Modeling of Surface Roughness Belonging to Oriental Beech Wood with an Artificial Neural Networks

ABSTRACT

The aim of this study was to model the surface roughness of Oriental beech (*Fagus orientalis* Lipsky) wood with the aid of artificial neural network (ANN) approach. Firstly, the working parameters of a wide belt sanding machine were adjusted to be the sanding belt grit size of 60-100, feeding speed from 4 m/min to 10 m/min, and sanding cutting depth from 0.1 mm until 0.3 mm, respectively. Secondly, after the surface roughness of the samples was experimentally recorded, the data were divided into two basic categories: namely, (I) the training sets and (II) test data sets. Thirdly, they were modeled by the approach of artificial neural networks so that the fundamental surface roughness parameters (Ra, Rq and Rz) can be anticipated thoroughly. The comparisons between the experimental results and theoretical findings ($R_{Ra} = 0.99869$, $R_{Rq} = 0.9982$ and $R_{Rz} = 0.99882$) show well-agreement with each other's. In this respect, this study declares that the surface roughness of the solid beech was perfectly predicted within far higher accuracy and relatively lower error by using the artificial neural networks approach.

Keywords: Surface roughness, Artificial neural network, Sandpaper grit size, Feed speed, Cutting depth

1867

I. GİRİŞ

Ağaç malzemede yüzey pürüzlülüğü üst yüzey işlemlerini etkileyen en önemli faktörlerden biridir. Üst yüzey işlemleri başlamadan önce malzeme yüzeyinin olabildiğince pürüzsüz olması arzu edilir. Uygun tekniklerle işlenmiş olan ağaç malzemede bile, hücre boşlukları nedeniyle, tam olarak pürüzsüz yüzey elde etmek mümkün değildir. Bu sebeple ağaç malzeme hangi yöntemle kesilmiş olursa olsun üst yüzey işlemleri öncesinde zımparalanarak pürüzlülük azaltılmaya çalışılır.

Ağaç malzemenin yüzey pürüzlülüğünün belirlenmesi, ahşabın anatomik yapısı, kesim işlemleri ve işleme koşulları nedeniyle karmaşık bir işlemdir [1]. Taylor ve ark. [2] ile Fujiwara ve ark. [3] zımparalama işleminde doğru besleme hızı ve zımpara numarası belirlendiğinde kaliteli ağaç malzeme yüzeyleri elde edileceğini, Tan ve ark. [4] zımpara numarası ve besleme hızının yüzey pürüzlülüğünü azaltmada çok etkili olduğunu, Budakçı ve ark. [5] kaliteli bir yüzeyin kesme derinliği ve besleme hızı ile beraber kesim açısına bağlı olduğunu, Örs ve Baykan [6] rendeleme işleminde kesici sayısı arttıkça, zımparalama işleminde ise zımpara numarası arttıkça yüzey pürüzlülüğü değerlerinin azaldığını tespit etmişlerdir. Bal [7], CNC makinelerinin çalıştırılması için yapılması zorunlu ayarlardan besleme hızı ve bıçak adımı arttıkça yüzey pürüzlülüğünün arttığını ve işlem süresinin uzadığını, ayrıca yüzey pürüzlülüğü ve işlem süresi üzerine bıçak adımının besleme hızından daha etkili olduğu bildirmiştir. Bal ve Akçakaya [8], CNC makine ile işlenmiş lif levhalarda kesme derinliği, besleme hızı ve bıçak adımı arttıkça yüzey pürüzlülüğünün arttığını belirlemiştir. Bunlara ek olarak çeşitli çalışmalarda teğet yüzeylerde, radyal yüzeylerden daha pürüzsüz sonuçlar elde edildiğini göstermesine rağmen kesme yönü ile kesici türü arasındaki etkileşim önemli bulunmamıştır [6, 9-11].

Bunlar ve benzeri çalışmalar göstermiştir ki, yüzey pürüzlülüğündeki değişimlerin tespit edilmesi için faktörlerin birçok değerinin araştırılması gerekir. Ancak, yüzey pürüzlülüğündeki değişimler veri modelleme yöntemleri kullanılarak kısa sürede tanımlanabilir. Bunlardan biri olan yapay sinir ağı (YSA), son zamanlarda yüksek doğruluk seviyesine sahip bir yöntem olarak öne çıkmaktadır. Bu yaklaşımın popülerliğinin sebebi, ele alınan problem hakkında ön bir bilgi olmadan girdiler ve çıktılar arasındaki karmaşık ve doğrusal olmayan ilişkilerinin tanımlanabilmesi gerçeğinde yatmaktadır. YSA, girdi-çıkı arasındaki ilişkinin tanımını öğrendikten sonra ağa yeni bir girdi sunulması durumunda oluşturulan fonksiyonel ilişkiye dayanarak çıktı sağlayabilmektedir. Bu nedenle, bu yaklaşım tahmin, sınıflandırma, optimizasyon vb. birçok amacı gerçekleştirmek için etkili bir biçimde uygulanabilir. Yöntemin sahip olduğu avantajlardan dolayı, ahşap bilimi alanındaki bazı çalışmalar yüzey pürüzlülüğünü tahmin etme amacıyla YSA yaklaşımına odaklanmıştır.

Tiryaki ve ark. [12], kayın ve ladin ağaç malzeme yüzeylerinin ilkbahar ve yaz odunu bölgelerinde, besleme hızı, kesici sayısı, kesme derinliği ve zımpara tanecik büyüklüğünün yüzey pürüzlülüğü üzerindeki etkilerini YSA yaklaşımı ile modellemiştir. Bir diğer çalışmada, Tiryaki ve ark. [13] YSA yaklaşımını kullanarak ahşap türü, basınç miktarı, işleme hızı, aşındırıcı tipi ve aşındırıcı tane sayısı faktörlerinin yüzey pürüzlülüğü ve güç tüketimi üzerindeki etkilerini modellemiştir. Özşahin ve Singer [14] tarafından yapılan bir YSA modellemesi çalışmasında ise ahşap türü, kesme yönü ve zımpara kağıdı türü faktörlerine bağlı olarak yüzey pürüzlülüğü değerleri tahmin edilmiştir. Bu çalışmalar YSA yaklaşımının ahşabın yüzey pürüzlülüğünü modellemek için kullanışlı, güvenilir ve oldukça etkili bir araç olduğunu göstermiştir. Literatürdeki farklı çalışmalarda da YSA modellemesinin çok fazla zaman, enerji ve maliyet harcamadan, faktörlerin etkilerini belirlemek için kullanılabilmesi ayrıca bir veri modelleme aracı olarak bu yöntemin geleneksel istatistiksel yöntemlere göre daha avantajlı olduğu belirtilmiştir [15, 16].

Bu bilgiler ışığında bu çalışmanın amacı kayın masif malzemede zımpara numarası, besleme hızı ve kesme derinliği parametrelerinin farklılaştırılması ile oluşan yüzey pürüzlülüğü değerlerinin YSA yaklaşımı kullanılarak tahmin edilmesidir. Profil girintileri (vadi) ile çıkıntıları (tepe) arasında bulunan ortalama sapma (Ra), aritmetik ortalama sapmaların karekökü (Rq) ve 5 tane en yüksek 5 tane en alçak noktanın ortalaması (Rz) parametreleri bu çalışmanın konusunu oluşturmuştur. Literatürde belirtilenlerden farklı olarak bu çalışmada ahşap yüzeyinde zımparalama ile oluşan yüzey pürüzlülüğü için kesme derinliği parametresinin de etkisi araştırılmıştır.

II. MATERYAL VE METOT

A. MATERYAL

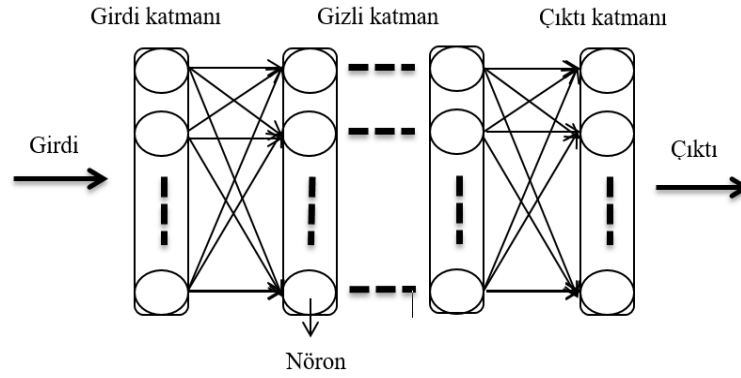
Bu çalışmada, ülkemiz mobilya ve dekorasyon endüstrisinde yaygın olarak kullanılan ağaçlardan Doğu kayını (*Fagus orientalis* L.) odunu deney materyali olarak seçilmiş ve hava kurusu rutubete kadar kurutularak 18 x 110 x 350 mm net ölçülerinde 26 adet deney numunesi hazırlandı. Daha sonra, iklimlendirme dolabına konularak 20 ± 2 °C ve $\%65 \pm 5$ bağıl nemde sabit ağırlığa ulaşana kadar bekletilen deney numuneleri, kalibre zımpara makinesi ile deneme desenine göre zımparalanmış ve yüzey pürüzlülükleri ölçülmüştür. Her parametre grubu için 2 adet deney numunesinden (5+5) 10 tekerrür olmak üzere toplam 130 ölçüm yapılmıştır. Deney numunelerinin rutubet miktarı ve yoğunluk değerleri TS 2470 [17] ve TS 2471 [18] standartlarına göre belirlenmiştir.

Yüzey pürüzlülüğü, ölçümü ISO 4287 [19] esaslarına uyularak belirlenmiştir. Ölçümlerde TIME TR-200 dokunmalı (iğneli) yüzey pürüzlülüğü test cihazı kullanılarak liflere dik yönde ölçüm yapılmıştır. Cihaz, 2,5 mm ölçme adımı ve 5 ölçme sayısına ayarlandıktan sonra ölçme kolu aralığı 20 mm olan iki çizgi arasına yerleştirilmiş, deney örneğinin ve cihazın yer düzlemine paralellik durumu kontrol edildikten sonra ölçüm başlatılmıştır. Sonuçlar cihazın LCD ekranından okunarak Ra, Rq ve Rz cinsinden kaydedilmiştir. Ölçüm hassasiyetin korumak için her 100 ölçümde cihaz yeniden kalibre edilmiştir. Cihaz, tarama iğnesinin örnek yüzeyinde aşağı-yukarı hareketi ile oluşan girinti ve çıkıntıların profilinden ölçüm değeri üretmektedir.

B. METOT

B.1. Yapay Sinir Ağları

YSA, insan beyninin çalışma sistemini modellemek için yapılan çalışmalardan ortaya çıkmış ve çeşitli mühendislik uygulamalarında yaygın olarak kullanılmıştır [20, 21]. Karmaşık problemlerin çözümünde, özellikle de tahmin problemlerinde çok katmanlı algılayıcı (ÇKA) yaygın olarak kullanılmaktadır. ÇKA'nın yapısında girdi katmanı, gizli katman(lar) ve çıktı katmanı olmak üzere üç katman vardır [22]. Girdi katmanı gelen verileri alır ve bunları gizli katman(lar)a iletir. Burada, veriler işlenir ve elde edilen sonuç çıktı katmanına iletilir. Çıktı katmanında çıktı verileri üretilir ve bilgilerin dışarıya iletilmesi sağlanır. ÇKA'nın şematik bir gösterimi Şekil 1'de verilmiştir [23].



Şekil 1. ÇKA'nın şematik gösterimi

İşlemci elemanlar (nöronlar), ÇKA katmanlarındaki temel öğedir. Bir nöronun ana bileşenini girdiler, ağırlıklar, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıktılar oluşturur. Nöronlar, bir sonraki katmanın nöronlarına ağırlıklı bağlantılar ile bağlanır. Burada ağırlık (w_{ij}), i . nöron ile j . nöron arasındaki bağlantının gücünü ifade eder. ÇKA'daki herhangi bir nöron (j), ağırlıklı girdiler (x_i) ile eşikleri (θ_j) toplar ve toplamı matematiksel bir fonksiyon ile ($f(\cdot)$) işler. Net girdi (net_j) ve çıktı değeri (y_j) hesaplama süreci, Eş. 1 ve Eş. 2'de gösterilmiştir [14, 24].

$$net_j = \sum_{i=1}^n x_i w_{ij} + \theta_j \quad (1)$$

$$y_j = f(net_j) \quad (2)$$

En uygun gizli katman sayısı ile her katmandaki nöron sayısı problemlere bağlı olarak değişir. Gizli katmanlarda çok az nöron olursa karmaşık bir veri seti modellenemeyebilir ve nöron sayısı çok fazla olursa aşırı uyum sorunu meydana gelebilir [25, 26].

YSA'nın eğitimi ve eğitilen YSA'nın test edilmesi iki önemli safhadır. Hata oranı en düşük ya da kabul edilebilir bir seviyeye gelinceye kadar ağırlık ve eşik değerleri eğitim sürecinde güncellenir. Eğitim sürecinin ardından, eğitilmiş ağın performansı ilk kez ağa sunulan bir veri seti ile test edilir ve modelin performansı değerlendirilir. Sonuçlar ne kadar iyiye modelin performansının da o kadar iyi olduğu sonucuna varılır [27, 28].

B.2. Yapay Sinir Ağı Analizi

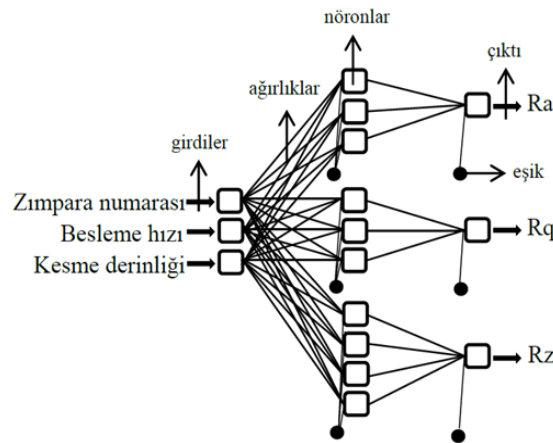
Bu çalışmada, zımpara numarası, besleme hızı ve kesme derinliği faktörlerinin odunun yüzey pürüzlülüğü (R_a , R_q ve R_z) üzerine etkileri YSA yaklaşımı ile modellenmiştir. YSA modelleri için gerekli veriler deneyler vasıtasıyla elde edilmiştir. YSA'ların oluşturulması, eğitimi ve optimizasyonu için MATLAB programı kullanılmıştır. Deneysel sürecin tamamlanmasının ardından, elde edilen veriler eğitim ve test olmak üzere iki farklı gruba ayrılmıştır R_a , R_q ve R_z 'nin modellenmesi için deney verileri (13 veri) arasından rastgele 9 veri (%70) eğitim süreci için seçilmiş ve geri kalan 4 veri (%30) test süreci için kullanılmıştır. Çalışmada kullanılan parametreler hakkında bilgi aşağıda verilmiştir:

Zımparalar üzerindeki aşındırıcı taneciklerin boyutuna göre numaralandırılır. Aşındırıcı boyutu küçüldükçe, zımpara üzerindeki tanecik sayısı artar ve zımpara incelik. Bu çalışmada kaba perdah işlemi 60 numaralı kalın, ince perdah işlemi ise 80 ve 100 numaralı orta zımparaları ifade etmektedir. Besleme hızı kesicinin beslendiği, diğer bir deyişle kalibre zımpara makinesinde ahşap iş parçasının ilerletildiği hızdır. Bu çalışmada yavaş zımparalama işlemi 4 mm/dk, orta zımparalama işlemi için 7 mm/dk ve hızlı zımparalama işlemi 10 mm/dk olarak ifade edilmiştir. Kesme derinliği ahşap yüzeylerin zımparalanması esnasında yüzeyden kaldırılan talaş kalınlığını ifade eder. Bu çalışmada tek seferde az talaş kaldırmak 0,1 mm, orta kalınlıkta talaş kaldırmak 0,2 mm ve çok talaş kaldırmak 0,3 mm olarak ifade edilmiştir. Bu çalışmada kullanılan veri seti Tablo 1’de gösterilmiştir.

Tablo 1. Çalışmada kullanılan veri seti

| Zımpara numarası | Besleme hızı (m/dk) | Kesme derinliği (mm) | Ra | Rq | Rz |
|------------------|---------------------|----------------------|--------|--------|--------|
| 60 | 4 | 0,2 | 10,760 | 13,648 | 74,113 |
| 60 | 7 | 0,3 | 11,338 | 14,113 | 69,708 |
| 60 | 10 | 0,2 | 12,360 | 15,335 | 78,303 |
| 80 | 4 | 0,1 | 9,080 | 11,405 | 55,755 |
| 80 | 7 | 0,3 | 8,808 | 11,028 | 59,373 |
| 80 | 10 | 0,1 | 11,193 | 13,990 | 71,395 |
| 100 | 7 | 0,1 | 7,755 | 9,628 | 47,820 |
| 100 | 7 | 0,3 | 8,233 | 10,420 | 58,565 |
| 100 | 10 | 0,2 | 8,260 | 10,200 | 56,205 |
| 60 | 7 | 0,1 | 11,205 | 13,885 | 70,795 |
| 80 | 7 | 0,2 | 10,730 | 13,580 | 71,118 |
| 80 | 10 | 0,3 | 11,583 | 14,363 | 75,405 |
| 100 | 4 | 0,2 | 7,838 | 9,363 | 47,170 |

Bu çalışmada gizli nöron sayıları sürekli değiştirilerek birçok YSA modeli geliştirilmiş ve ardından Ra, Rq ve Rz için en uygun ağ mimarileri ve tahmin modelleri belirlenmiştir. Seçilen YSA mimarileri aşağıdaki şekilde gösterilmiştir.



Şekil 2. YSA modellerinin mimarileri

Literatürde, mühendislik problemlerini çözmek için bir gizli katmanın yeterli olduğu bildirilmiştir [29, 30]. Bu bilginin ışığında, Ra, Rq ve Rz için bir gizli katmana sahip üç katmanlı YSA’lar inşa edilmiştir. Ağın birinci (girdi) ve üçüncü (çıkı) katmanları, sırasıyla girdi değişkenlerini (zımpara numarası, besleme hızı ve kesme derinliği) ve çıkı değişkenlerini (Ra, Rq ve Rz) göstermektedir.

Gizli katman nöronlarının sayısına karar vermek için kesin bir kural olmadığından, çeşitli kombinasyonlar denenmiştir. Sonuç olarak; Ra için 3-3-1, Rq için 3-3-1 ve Rz için 3-4-1 ağ mimarileri tahminler yapmak için tercih edilmiştir.

Ra, Rq ve Rz modellerinin belirlenmesinde ileri-beslemeli ve geri-yayımlı çok katmanlı YSA'lar tercih edilmiştir. Hiperbolik tanjant sigmoid fonksiyonu gizli katmanda aktivasyon fonksiyonu olarak kullanılırken, doğrusal transfer fonksiyonu çıktı katmanında dikkate alınmıştır. Levenberg-Marquardt algoritması eğitim algoritması olarak kullanılmıştır. Momentumlu gradyan azaltım geri-yayımlı algoritması öğrenme kuralı olarak seçilmiştir. Performans fonksiyonu olarak ortalama karesel hata (MSE) tercih edilmiştir. MSE değerleri Eş. 3 kullanılarak hesaplanmıştır. Bu eşitlikte; t_i gerçek değer, td_i tahmini değer ve N ölçüm sayısıdır.

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2 \quad (3)$$

Girdilerin ve çıktıkların ölçeklendirilmesi, YSA'ların performansını önemli ölçüde etkilemektedir [31]. Yukarıda bahsedildiği üzere, hiperbolik tanjant sigmoid fonksiyonu modellerde aktivasyon fonksiyonu olarak kullanılmıştır. Bu nedenle, orijinal veri seti ağın eğitiminden önce $[-1, 1]$ aralığına ölçeklendirilmiştir. YSA'nın $[-1, 1]$ aralığındaki çıktı değerleri, ters normalleştirme işlemi uygulanarak tekrar gerçek değerlere dönüştürülmüştür. Normalizasyon işlemleri Eş. 4 kullanılarak gerçekleştirilmiştir. Bu eşitlikte; X_{norm} normalize edilmiş veri, X gerçek değer, X_{min} veri grubunun minimum değeri ve X_{max} veri grubunun maksimum değeridir.

$$X_{norm} = 2 \times \frac{X - X_{min}}{X_{max} - X_{min}} - 1 \quad (4)$$

Geliştirilen Ra, Rq ve Rz modellerin tahmin performanslarını karşılaştırmak için ortalama mutlak yüzde hata (MAPE), ortalama karesel hatanın karekökü (RMSE) ve determinasyon katsayısı (R^2) kullanılmıştır. Bu performans göstergelerinin değerleri sırasıyla Eş. 5, Eş. 6 ve Eş. 7 kullanılarak elde edilmiştir.

$$MAPE = \frac{1}{N} \left(\sum_{i=1}^N \left[\left| \frac{t_i - td_i}{t_i} \right| \right] \right) \times 100 \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2} \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (t_i - td_i)^2}{\sum_{i=1}^N (t_i - \bar{t})^2} \quad (7)$$

Burada; \bar{t} tahmini değerlerin ortalamasıdır.

III. BULGULAR VE TARTIŞMA

Kayın masif malzemedeki yüzey pürüzlülüğü, zımpara numarası, besleme hızı ve kesme derinliğinin farklı değerlerinde incelenmiş ve YSA yaklaşımı ile tahmin edilmiştir.

Deney sonuçlarına göre en yüksek yüzey pürüzlülüğü ($R_a = 12,360 \mu\text{m}$, $R_q = 15,335 \mu\text{m}$, $R_z = 78,303 \mu\text{m}$) 60 kum zımpara, 10 m/dk besleme hızı ve 0,20 mm talaş miktarı ile elde edilmiştir. En düşük yüzey pürüzlülüğü ($R_a = 7,755 \mu\text{m}$, $R_q = 9,628$, $R_z = 47,820$) ise 100 kum zımpara, 7 m/dk besleme hızı ve 0,10 mm talaş miktarı ile elde edilmiştir (Tablo 2).

Tablo 2. Gerçek değerler, model çıktıları ve yüzde hata değerleri

| Zımpara numarası | Besleme hızı (m/dk) | Kesme derinliği (mm) | R_a | | | R_q | | | R_z | | |
|------------------|---------------------|----------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | | | Gerçek | Tahmin | %Hata | Gerçek | Tahmin | %Hata | Gerçek | Tahmin | %Hata |
| 60 | 4 | 0,2 | 10,760 | 10,795 | -0,328 | 13,648 | 13,555 | 0,679 | 74,113 | 74,198 | -0,116 |
| 60 | 7 | 0,3 | 11,338 | 11,344 | -0,058 | 14,113 | 13,980 | 0,942 | 69,708 | 69,726 | -0,026 |
| 60 | 10 | 0,2 | 12,360 | 12,359 | 0,005 | 15,335 | 15,332 | 0,019 | 78,303 | 78,380 | -0,099 |
| 80 | 4 | 0,1 | 9,080 | 9,046 | 0,376 | 11,405 | 11,402 | 0,024 | 55,755 | 55,754 | 0,001 |
| 80 | 7 | 0,3 | 8,808 | 8,819 | -0,125 | 11,028 | 11,024 | 0,029 | 59,373 | 59,443 | -0,118 |
| 80 | 10 | 0,1 | 11,193 | 11,165 | 0,249 | 13,990 | 13,977 | 0,094 | 71,395 | 71,400 | -0,007 |
| 100 | 7 | 0,1 | 7,755 | 7,700 | 0,704 | 9,628 | 9,708 | -0,832 | 47,820 | 47,820 | 0,000 |
| 100 | 7 | 0,3 | 8,233 | 8,163 | 0,842 | 10,420 | 10,422 | -0,018 | 58,565 | 58,507 | 0,098 |
| 100 | 10 | 0,2 | 8,260 | 8,336 | -0,922 | 10,200 | 10,210 | -0,101 | 56,205 | 56,209 | -0,007 |
| 60* | 7 | 0,1 | 11,205 | 11,026 | 1,596 | 13,885 | 14,091 | -1,484 | 70,795 | 72,444 | -2,330 |
| 80* | 7 | 0,2 | 10,730 | 10,702 | 0,262 | 13,580 | 13,303 | 2,043 | 71,118 | 70,673 | 0,625 |
| 80* | 10 | 0,3 | 11,583 | 11,545 | 0,327 | 14,363 | 14,493 | -0,908 | 75,405 | 75,811 | -0,539 |
| 100* | 4 | 0,2 | 7,838 | 8,042 | -2,612 | 9,363 | 9,214 | 1,583 | 47,170 | 47,941 | -1,635 |

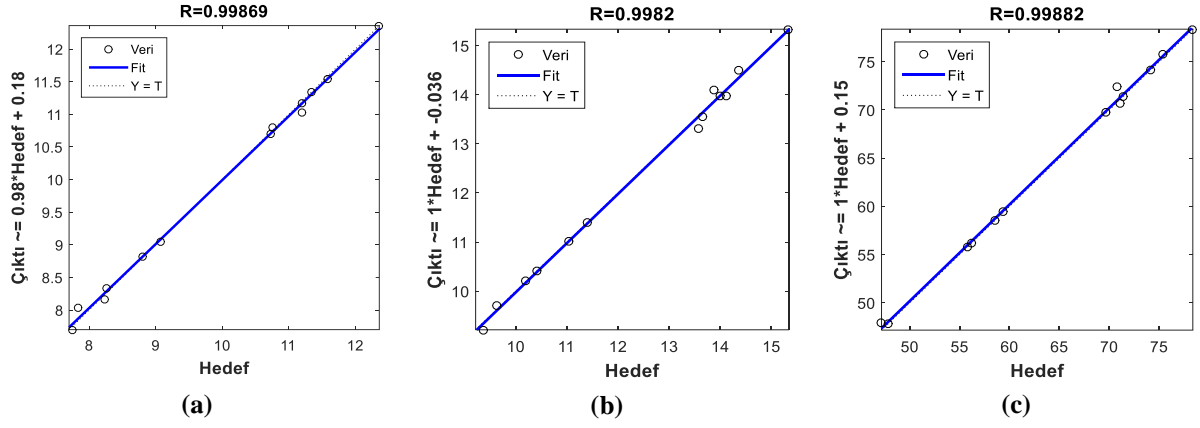
*Test verileri

Tahmin modellerinin performanslarının değerlendirilmesi için MAPE ve RMSE değerleri hesaplanmıştır (bkz. Tablo 3). R_a , R_q ve R_z için eğitim sürecindeki MAPE sırasıyla %0,401 %0,304 ve %0,052 olur iken, test sürecindeki MAPE sırasıyla %1,199 %1,505 ve %1,282 olarak gerçekleşmiştir. RMSE, eğitim sürecinde R_a için 0,043, R_q için 0,060 ve R_z için 0,049 olarak hesaplanmıştır; test sürecinde R_a için 0,138, R_q için 0,199 ve R_z için 0,959 olmuştur. Düşük RMSE ve MAPE değerleri, daha doğru tahmin sonuçlarını temsil eder [32]. Bu açıdan, bu çalışmada hesaplanan MAPE ve RMSE değerleri, odunun yüzey pürüzlülüğünü modellemek için oluşturulan modellerin yeterince doğru ve güvenilir olduğunu göstermiştir.

Tablo 3. Yüzey pürüzlülüğü değerlerinin MAPE ve RMSE değerleri

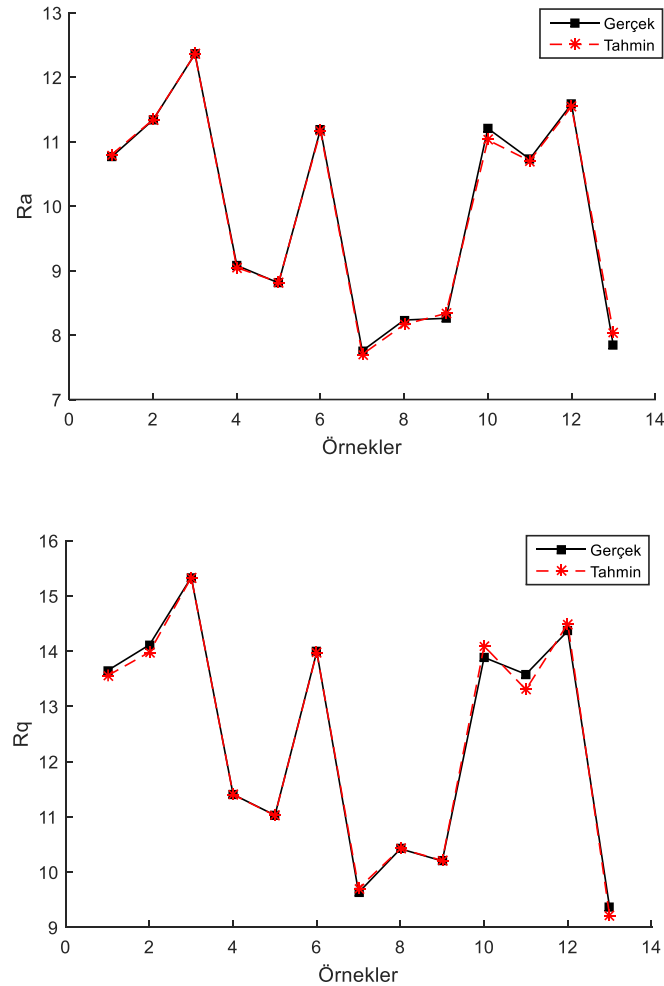
| Pürüzlülük değerleri | MAPE eğitim | MAPE test | RMSE eğitim | RMSE test |
|----------------------|-------------|-----------|-------------|-----------|
| R_a | 0,401 | 1,199 | 0,043 | 0,138 |
| R_q | 0,304 | 1,505 | 0,060 | 0,199 |
| R_z | 0,052 | 1,282 | 0,049 | 0,959 |

Regresyon analizi, genellikle ağların geçerliliğini ve doğruluğunu değerlendirmek için kullanılmakta olup katsayının 1'e yaklaşması mükemmel uyumun gerçekleştiğini göstermektedir. Şekil 3, R_a , R_q ve R_z tahmin modelleri için regresyon analizini göstermektedir ($R_{R_a} = 0,99869$, $R_{R_q} = 0,9982$, $R_{R_z} = 0,99882$). Sonuçlar, deney sonuçları ile model tahminleri arasında iyi bir uyum olduğunu göstermektedir.

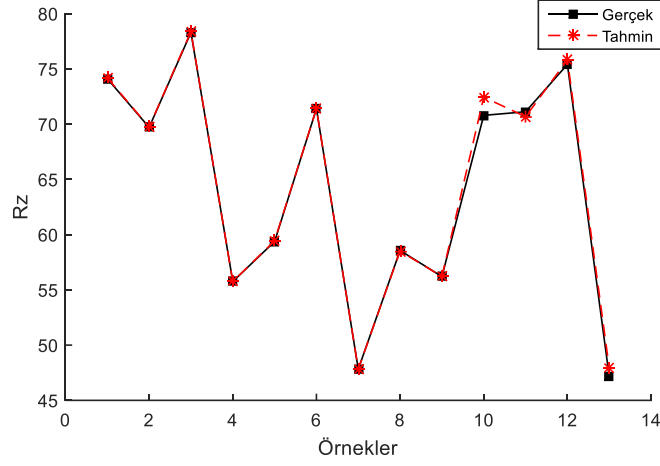


Şekil 3. Ölçülen sonuçlar ile tahmini değerler arasındaki ilişki: (a) Ra, (b) Rq ve (c) Rz

Şekil 4'te ölçülen ortalama pürüzlülük değerleri ile tahmin edilen pürüzlülük değerleri karşılaştırılmıştır. YSA modelleri tarafından tahmin edilen Ra, Rq ve Rz değerlerinin, ilgili gerçek değerleri yakından takip etme eğiliminde olduğu Şekil 4'te görülmektedir. Bu durum, tahmin modellerinin güvenilir olduğuna işaret etmektedir.



Şekil 4. Ölçülen ve tahmin edilen değerlerin karşılaştırılması



Şekil 4. (devam). Ölçülen ve tahmin edilen değerlerin karşılaştırılması)

Ra, Rq ve Rz tahmin modelleri, parametrelerinin değerlerine karşılık gelen pürüzlülük değerlerini kabul edilebilir bir doğrulukla tahmin etmiştir.

Literatürde, ahşabın yüzey pürüzlülüğünün YSA ile modellendiği sınırlı sayıda çalışma bulunmaktadır. Bu çalışmaların MAPE değerleri 1,41 ile 3,93 arasında yer alırken, R^2 sonuçları 0,952 ile 0,998 arasında değişmiştir [12, 14]. Sonuç olarak, bu çalışmanın bulgularının ahşap malzemelerin yüzey pürüzlülüğünün YSA ile modellenmesine ilişkin mevcut literatür ile uyumlu olduğu söylenebilir. Özetle, faktörlerin yüzey pürüzlülüğü üzerine olan etkileri YSA modellerinin kullanımı ile kısa sürede ve düşük hata oranlarıyla belirlenebilir.

IV. SONUÇ

Bu araştırma çalışmasında, zımpara numarası, besleme hızı ve kesme derinliği faktörlerine bağlı olarak odunun yüzey pürüzlülüğü (Ra, Rq ve Rz) araştırılmış ve YSA yaklaşımı ile tahmin edilmiştir. Amaç ışığında, deneysel çalışmadan elde edilen veriler kullanılarak Ra, Rq ve Rz için çok katmanlı sinir ağları geliştirilmiştir.

Gerçek değerler ile tahmini değerler karşılaştırıldığında görülmektedir ki, YSA yaklaşımı zımpara numarası, besleme hızı ve kesme derinliği değişkenlerinin yüzey pürüzlülüğü üzerindeki etkisini tahmin etmede etkin bir şekilde kullanılabilir.

YSA modellerinin performansı MAPE, RMSE ve R^2 değerleri ile doğrulanmıştır. Tahmin modellerinin MAPE ve RMSE değerleri oldukça düşük, determinasyon katsayıları ise bire yakındır. Bu sonuçlar, zımpara numarası, besleme hızı ve kesme derinliği faktörlerinin odunun yüzey pürüzlülüğü üzerindeki etkilerini düşük hata oranlarıyla oldukça kısa sürede YSA yaklaşımı ile modellenebileceğini ve model çıktıları ile gerçek değerler arasında iyi bir uyum olduğunu göstermektedir.

Sonuç olarak, YSA modelleri çeşitli işleme koşulları altında odunun yüzey pürüzlülüğünü tahmin etmek için kullanılabilir.

V. KAYNAKLAR

- [1] E. Csanády, E. Magoss, and L. Tolvaj, *Quality of Machined Wood Surfaces*, Basel: Springer International Publishing, 2015.
- [2] J. B. Taylor, A. L. Carrano and R. L. Lemaster, “Quantification of process parameters in a wood sanding operation,” *Forest Products Journal*, vol. 49, no. 5, pp. 41–46, 1999.
- [3] Y. Fujiwara, Y. Fujii, Y. Sawada and S. Okumura, “Development of a parameter to reflect the roughness of a wood surface that corresponds to tactile roughness,” *Holz als Roh- und Werkstoff*, vol. 59, no. 5, pp. 351–355, 2001.
- [4] P. L. Tan, S. Sharif and I. Sudin, “Roughness models for sanded wood surfaces,” *Wood Science and Technology*, vol. 46, no. 1–3, pp. 129–142, 2012.
- [5] M. Budakçı, A. C. İlçe, D. S. Korkut and T. Gürleyen, “Evaluating the surface roughness of heat-treated wood cut with different circular saws,” *BioResources*, vol. 6, no. 4, pp. 4247–4258, 2011.
- [6] Y. Örs and I. Baykan, “The effect of planning and sanding on surface roughness of massive wood,” *Turkish Journal of Agriculture and Forestry*, vol. 23, no. 3, pp. 577–582, 1999.
- [7] B. C. Bal, “CNC makinelerinin bazı ayarlarının parça işleme süresi ve lif levhanın yüzey pürüzlülüğü üzerine etkileri,” *Mobilya ve Ahşap Malzeme Araştırmaları Dergisi*, c. 1, s. 1, ss. 21–30, 2018.
- [8] B. C. Bal ve E. Akçakaya, “CNC makineleri ile işlenen lif levhaların yüzey pürüzlülüğü üzerine bıçak adımı, besleme hızı ve kesme derinliğinin etkileri,” *Mobilya ve Ahşap Malzeme Araştırmaları Dergisi*, c. 1, s. 2, ss. 86–93, 2018.
- [9] Y. Örs ve L. Gürleyen, “Ağaç malzemede yüzey düzgünlüğüne, rendelemede kesiş yönü, bıçak sayısı ve çeşidinin etkileri,” *Politeknik Dergisi*, c. 5, s. 4, ss. 335–339, 2002.
- [10] H. Efe ve L. Gürleyen, “Bazı ağaç malzemelerde kesiş yönü, kesici adeti ve devir sayısının yüzey düzgünlüğüne etkileri,” *Gazi Üniversitesi Endüstriyel Sanatlar Eğitim Fakültesi Dergisi*, c. 11, s. 12, ss. 34–44, 2003.
- [11] C. Söğütü, “Bazı yerli ağaç türlerinin kündekâri yapımında kullanım imkânları,” Doktora Tezi, Fen Bilimleri Enstitüsü, Gazi Üniversitesi, Ankara, Türkiye, 2004.
- [12] S. Tiryaki, A. Malkoçoğlu and Ş. Özşahin, “Using artificial neural networks for modeling surface roughness of wood in machining process,” *Construction and Building Materials*, vol. 66, pp. 329–335, 2014.
- [13] S. Tiryaki, Ş. Özşahin and A. Aydın, “Employing artificial neural networks for minimizing surface roughness and power consumption in abrasive machining of wood,” *European Journal of Wood and Wood Products*, vol. 75, no. 3, pp. 347–358, 2017.

- [14] Ş. Özşahin ve H. Singer, “Odunun yüzey pürüzlülüğünün ve adezyon direncinin yapay sinir ağları ile tahmini,” *Politeknik Dergisi*, doi: 10.2339/politeknik.481762.
- [15] U. Atici, “Prediction of the strength of mineral admixture concrete using multivariable regression analysis and an artificial neural network,” *Expert Systems with Applications*, vol. 38, no.8, pp. 9609–9618, 2011.
- [16] S. Mahdevari and S. R. Torabi, “Prediction of tunnel convergence using Artificial Neural Networks,” *Tunnelling and Underground Space Technology*, vol. 28, pp. 218–228, 2012.
- [17] *Method of taking samples for physical and mechanical experiments on wood and general properties*, Türk Standartlar Enstitüsü TS 2470, 1976.
- [18] *Wood-determination of moisture content for physical and mechanical tests*, Türk Standartlar Enstitüsü TS 2471, 1976.
- [19] *Geometrical Product Specifications (GPS) - Surface texture: Profile method - Terms, definitions and surface texture parameters*, Uluslararası Standartlar Teşkilâtı ISO 4287, 1997.
- [20] P. T. Nastos, A. G. Paliatsos, K. V. Koukouletsos, I. K. Larissi and K. P. Moustris, “Artificial neural networks modeling for forecasting the maximum daily total precipitation at Athens, Greece,” *Atmospheric Research*, vol. 144, pp. 141–150, 2014.
- [21] A. K. Yadav and S. S. Chandel, “Solar radiation prediction using artificial neural network techniques: a review,” *Renewable and Sustainable Energy Reviews*, vol. 33, pp. 772–781, 2014.
- [22] T. B. M. J. Ouarda and C. Shu, “Regional low-flow frequency analysis using single and ensemble artificial neural networks,” *Water Resources Research*, vol. 45, no. 11, W11428, 2009.
- [23] T. Varol, A. Canakci and S. Ozsahin, “Prediction of the influence of processing parameters on synthesis of Al2024-B4C composite powders in a planetary mill using an artificial neural network,” *Science and Engineering of Composite Materials*, vol. 21, no. 3, pp. 411–420, 2014.
- [24] S. Tiryaki, S. Bardak and T. Bardak , “Experimental investigation and prediction of bonding strength of Oriental beech (*Fagus orientalis* Lipsky) bonded with polyvinyl acetate adhesive,” *Journal of Adhesion Science and Technology*, vol. 29, no. 23, pp. 2521–2536, 2015.
- [25] A. Akkoyunlu, K. Yetilmezsoy, F. Erturk and E. Oztemel, “A neural network-based approach for the prediction of urban SO2 concentrations in the Istanbul Metropolitan Area,” *International Journal of Environment and Pollution*, vol. 40, no. 4, pp. 301–321, 2010.
- [26] P. Singh and B. Borah, “Indian summer monsoon rainfall prediction using artificial neural network,” *Stochastic Environmental Research and Risk Assessment*, vol. 27, no. 7, pp. 1585–1599, 2013.
- [27] M. Çuhadar, İ. Güngör ve A. Göksu, “Turizm talebinin yapay sinir ağları ile tahmini ve zaman serisi yöntemleri ile karşılaştırmalı analizi: Antalya iline yönelik bir uygulama,” *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, c. 14, s. 1, pp. 99–114, 2009.

- [28] I. Yildirim, S. Ozsahin and K. C. Akyuz, "Prediction of the financial return of the paper sector with artificial neural networks," *BioResources*, vol. 6, no. 4, pp. 4076–4091, 2011.
- [29] C. Hamzaçebi, D. Akay and F. Kutay, "Comparison of direct and iterative artificial neural network forecast approaches in multi-periodic time series forecasting," *Expert Systems with Applications*, vol. 36, no. 2, pp. 3839–3844, 2009.
- [30] G. Cybenko, "Approximation by superposition of a sigmoidal function," *Mathematics of Control, Signals and Systems*, vol. 2, no. 4, pp. 303–314, 1989.
- [31] K. P. Somashekhar, N. Ramachandran and J. Mathew, "Optimization of material removal rate in micro-edm using artificial neural network and genetic algorithms," *Materials and Manufacturing Processes*, vol. 25, no. 6, pp. 467–475, 2010.
- [32] H. Küçükönder, S. Boyacı and A. Akyüz, "A modeling study with an artificial neural network: developing estimation models for the tomato plant leaf area," *Turkish Journal of Agriculture and Forestry*, vol. 40, pp. 203–212, 2016.