



POLİTEKNİK DERGİSİ

*JOURNAL of POLYTECHNIC*

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



# Odunun yüzey pürüzlülüğünün ve adezyon direncinin yapay sinir ağları ile tahmini

## *Prediction of surface roughness and adhesion strength of wood by artificial neural networks*

Yazar(lar) (Author(s)): Şükrü ÖZŞAHİN<sup>1</sup>, Hilal SINGER<sup>2</sup>

ORCID<sup>1</sup>: 0000-0001-8216-0048

ORCID<sup>2</sup>: 0000-0003-0884-2555

**Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article):** Özşahin Ş. ve Singer H., “Odunun yüzey pürüzlülüğünün ve adezyon direncinin yapay sinir ağları ile tahmini”, *Politeknik Dergisi*, 22(4): 889-900, (2019).

**Erişim linki (To link to this article):** <http://dergipark.org.tr/politeknik/archive>

**DOI:** 10.2339/politeknik.481762

# Odunun Yüzey Pürüzlülüğünün ve Adezyon Direncinin Yapay Sinir Ağları ile Tahmini

*Araştırma Makalesi / Research Article*

Şükrü ÖZŞAHİN\*, Hilal SİNGER

Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Türkiye

(Geliş/Received : 12.11.2018 ; Kabul/Accepted : 18.12.2018)

## ÖZ

Mobilya ve dekorasyon elemanlarının üretiminde kullanılan ağaç malzemelerin yüzey pürüzlülüğünün ve adezyon direncinin belirlenmesi, nihai ürünün kalitesinin değerlendirilmesi bakımından çok önemlidir. Bu makalede ilk olarak, odun türü, kesme yönü ve zımpara kağıdı türünün yüzey pürüzlülüğü üzerine etkilerini incelemek için yapay sinir ağı (YSA) ile yüzey pürüzlülüğü tahmin modeli geliştirilmiştir. Daha sonra, vernik türü, odun türü, kesme yönü ve yüzey pürüzlülüğünün adezyon direnci üzerine etkileri YSA ile geliştirilen adezyon direnci tahmin modeliyle araştırılmıştır. En iyi performansa sahip tahmin modelleri istatistiksel ve grafiksel karşılaştırmalar yoluyla belirlenmiştir. YSA modellerinin kabul edilebilir sapmalarla oldukça tatmin edici neticeler elde ettiği görülmüştür. Sonuç olarak bu çalışmanın bulguları, deneysel araştırmalar için zaman, enerji ve maliyeti azaltmak amacıyla mobilya ve dekorasyon endüstrisinde etkili bir şekilde uygulanabilir.

**Anahtar Kelimeler:** Yapay sinir ağları, odun, yüzey pürüzlülüğü, adezyon direnci, tahmin.

## Prediction of Surface Roughness and Adhesion Strength of Wood by Artificial Neural Networks

### ABSTRACT

Determining the surface roughness and adhesion strength of wood materials used in the manufacturing of furniture and decoration elements is very crucial in terms of evaluating the quality of the final product. In this article, firstly, the surface roughness prediction model was developed with the artificial neural network (ANN) to examine the effects of wood species, cutting direction and sandpaper type on surface roughness. Then, the effects of varnish type, wood species, cutting direction and surface roughness on adhesion strength were investigated with the adhesion strength prediction model developed with ANN. The prediction models with the best performance were determined by statistical and graphical comparisons. It has been observed that ANN models yielded very satisfactory results with acceptable deviations. As a result, the findings of this study could be employed effectively into the furniture and decoration industry to reduce time, energy and cost for empirical investigations.

**Keywords:** Artificial neural networks, wood, surface roughness, adhesion strength, prediction.

### 1. GİRİŞ (INTRODUCTION)

Ahşap, hem yapısal hem de yapısal olmayan uygulamalarda kullanılabilen sürdürülebilir ve çevre dostu doğal bir malzemedir [1]. En eski yapı malzemelerinden biri olan ahşap, beton ve çelik ile karşılaştırıldığında hafif olması, kolay bulunabilmesi, estetik görünümü ve bazı üstün mekanik özellikleri nedeniyle birçok uygulama alanında tercih edilmektedir [2, 3]. Ağaç malzemeler, kullanım yerlerinde maruz kaldıkları dış etkenlere karşı uzun süre direnç gösteremediklerinden dolayı bu malzemelerle üretilen mobilya ve dekorasyon elemanlarının korunması gerekir. Bu amaca hizmet eden en önemli maddelerden biri verniktir. Ağaç malzemelerin yüzeylerini dış etkenlere karşı korumak için farklı vernik katmanları ile kaplamak en yaygın kullanılan yöntemdir [4]. Adezyon direnci, katman performansını değerlendirmek amacıyla yaygın olarak kullanılmaktadır. Vernik türü, verniklerin odun

yüzeyine tutunma direncinde görülen farklılığın en önemli sebeplerinden birisidir. Bir verniğin yüzeye yapışma mukavemeti verniğin kullanılabilirliğini gösterir. Adezyon direncinin belirlenmesi için çapraz kesim testi (cross-cut test), bant soyma testi (tape-peel test) ve çekme testi (pull-off test) yöntemlerinden faydalanılabilir [5].

Adezyon direnci üzerinde önemli bir etkiye sahip olduğu için yüzey pürüzlülüğünün tespit edilmesi gerekir [6]. Pürüzlülük, üretim sürecinin veya malzeme özelliklerinin etkisiyle işlenmiş bir yüzeyde meydana gelen küçük düzensizlikleri karakterize eder [7]. Orman ürünleri, odunun testere, planya, zımpara vb. işleme tabi tutulmasından sonra oluşmaktadır [8]. İşleme sonucunda elde edilen yüzeyin kalitesi, odun türü, rutubet miktarı gibi odun özelliklerinden ve kesici sayısı, kesme açısı, kesici körlüğü, besleme hızı, kesme hızı gibi işleme koşullarından önemli ölçüde etkilenir [9]. Odunun yüzey pürüzlülüğü, nihai ürünün kalitesini belirlemede en önemli kriterlerden biridir. Bu nedenle, nihai ürünün yüzey kalitesini iyileştirmek için işleme koşulları ve

\*Sorumlu Yazar (Corresponding Author)  
e-posta : sukru@ktu.edu.tr

odun özellikleri ile ilgili parametrelerin dikkate alınması önemlidir [10]. Yüzey pürüzlülüğünün hem niteliksel hem de niceliksel olarak değerlendirilmesi mümkündür. Geleneksel görsel ve dokunma yöntemleri ile yüzeyin niteliksel bir değerlendirmesi yapılabilir, ancak bu yolla yüzeyin özel bilgileri ölçülememektedir. Yüzey pürüzlülüğünü nicelleştirmek için dokunmalı iğne tarama, optik, ultrasonik, video kamera gibi yöntemler kullanılır [11].

Yüzey pürüzlülüğü ve adezyon direnci özelliklerini etkileyen çok sayıda faktör vardır ve bu faktörler birbirleriyle etkileşim içerisindedir. Bu nedenle, en iyi sonuçlara ulaşmak için faktörlerin etkilerinin saptanıp optimum koşulların belirlenmesi gerekir. Ancak, faktörlerin adezyon direnci ve yüzey pürüzlülüğü üzerindeki etkilerini araştırmak için kapsamlı deneylerin yapılmasına gerek vardır. Bu tarz deneyler, yüksek maliyetler ile zaman ve enerji kaybına neden olabilmektedir. Yapay sinir ağı (YSA) yaklaşımı bu tür sorunlarla başa çıkabilmek için alternatif bir araç olarak kullanılabilir. Son zamanlarda, YSA'nın bir sürecin veya sistemin değişkenleri arasındaki karmaşık, tanımlanmamış ve doğrusal olmayan ilişkileri herhangi bir ön bilgi gerekmeden öğrenebilme yeteneği pek çok araştırmacının dikkatini çekmiş ve YSA yaklaşımı farklı mühendislik alanlarındaki problemleri çözmede önemli bir rol oynamıştır [12, 13].

Literatürdeki birçok çalışmada ahşap biliminin çeşitli alanlarındaki problemleri çözmek için YSA modellerinin geliştirilmesine odaklanılmıştır. Bu çalışmalara ısı işlemleri odunun denge rutubet miktarının ve özgül ağırlığının tahmini [13], odunun ısı iletkenliğinin hesaplanması [14], kırılma dayanımının tahmini [15], ahşap kaplama kusurlarının sınıflandırılması [16], kurutma karakteristiklerinin belirlenmesi [17] ve yönlendirilmiş yonga levha üretiminde proses parametrelerinin optimizasyonu [18, 19] örnek olarak verilebilir. Ahşap biliminin çeşitli alanlarında YSA yaklaşımının birçok uygulaması bulunmasına rağmen, odunun yüzey pürüzlülüğü ile ilgili çalışmalar oldukça sınırlıdır. Tiryaki ve ark. [20] planyalanmış odunların yüzey pürüzlülüğü değerlerini tahmin etmek için YSA yaklaşımını kullanmışlardır. Çalışmalarında, odun türü, besleme oranı, bıçak sayısı, kesme derinliği, ilkbahar-yaz odunu ve zımpara numarası girdi değişkenlerine dayalı olarak yüzey pürüzlülüğü çıktı değişkeni tahmin edilmiştir. Tiryaki ve ark. [21] tarafından yapılan bir diğer çalışmada, odun türü, basınç miktarı, işleme hızı, aşındırıcı tipi ve aşındırıcı tane sayısı değişkenlerinin zımparalama işleminde yüzey pürüzlülüğü ve güç tüketim düzeyleri üzerine etkileri literatürden elde edilen veriler kullanılarak YSA yaklaşımı ile modellenmiştir. Odunun yüzey pürüzlülüğünün tahmini için bazı YSA modelleri geliştirilmiş olsa da, daha fazla araştırmaya ihtiyaç duyulduğu açıktır. Öte yandan, ilgili literatürde yapışma mukavemetinin YSA ile tahmini için yapılan çalışmalarda birbirine tutkal vasıtasıyla yapıştırılan ahşap veya ahşap esaslı malzemelerin yapışma direnci deneylerinden elde edilen sonuçların modellenmesi

gerçekleştirilmiştir [22, 23]. Yürütülen çalışmalar ağaç malzemede vernik katmanı tutunma direncinin YSA ile modellenmesinden farklıdır.

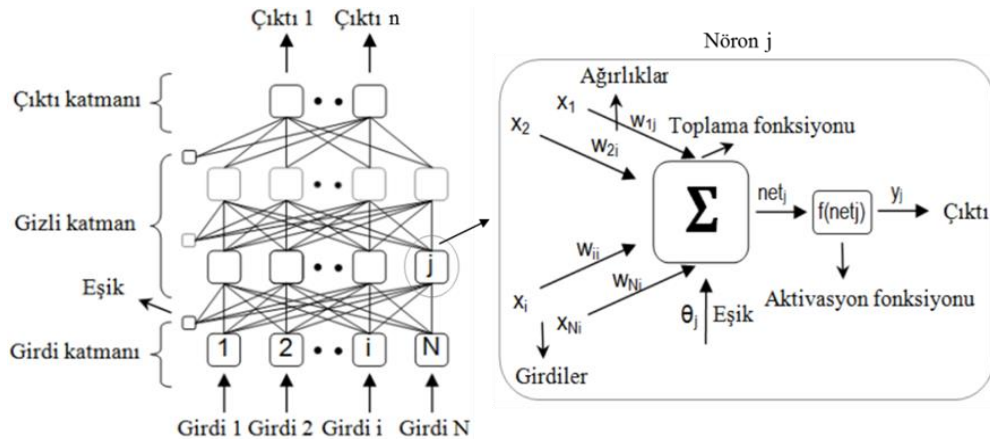
Literatür araştırması, ahşap biliminde sınıflandırma, tahmin ve optimizasyon amaçları için YSA yaklaşımının yaygın olarak kullanıldığını göstermiştir. Ahşap biliminde YSA'nın birçok uygulaması bulunmasına rağmen, yüzey pürüzlülüğünün YSA yaklaşımı ile tahminine ilişkin çalışmaların sayısı azdır. Ayrıca, ilgili literatürde ağaç malzemede vernik katmanı tutunma direncinin YSA ile modellenmesine yönelik herhangi bir çalışma bulunmamaktadır. Bu yüzden bu çalışmada, odunun yüzey pürüzlülüğü ve vernik adezyon direnci değerlerini yüksek bir doğrulukta tahmin etme yeteneğine sahip YSA modellerinin geliştirilmesine odaklanılmıştır. Bu açıdan bu çalışma, odun türü, kesme yönü ve zımpara kağıdı türü değişkenlerinin yüzey pürüzlülüğü üzerine etkileri ile vernik türü, odun türü, kesme yönü ve yüzey pürüzlülüğü değişkenlerinin adezyon direnci üzerine etkilerini aynı çatı altında YSA yaklaşımı ile modelleyen ilk girişim olacaktır. Geliştirilen YSA modellerinin tahmin sonuçları, deneysel araştırmalar için zaman, enerji ve maliyeti azaltmak amacıyla mobilya ve dekorasyon endüstrisinde etkili bir şekilde uygulanabilecektir.

## 2. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORKS)

YSA, biyolojik sinir ağlarının yapısal ve/veya işlevsel yönlerinden ilham alınarak oluşturulmuş matematiksel veya hesaplamalı bir modeldir [24]. Güçlü bir modelleme aracı olan YSA, herhangi bir varsayıma gerek duymadan parametreler arasındaki karmaşık ve doğrusal olmayan ilişkileri tanımlayabilme yeteneğine sahip olduğu için geleneksel istatistiksel yöntemlere göre birçok avantaj sunar [19, 25]. YSA'nın doğrusal olmayan fonksiyon tahmini, sınıflandırma, örüntü tanıma, optimizasyon, kümeleme ve simülasyon gibi çeşitli uygulamalarda kullanılması mümkündür [26].

YSA'nın çeşitlerinden biri olan çok katmanlı algılayıcı (ÇKA), tahmin amaçlı kullanılan en popüler ağıdır. ÇKA, problemin girdi değişkenlerini temsil eden nöronları içeren bir girdi katmanından, çıktı değişken(ler)ini temsil eden nöron(lar)a sahip bir çıktı katmanından ve sistemdeki doğrusal olmayanlığı yakalamaya yardımcı olmak için nöron(lar) içeren bir veya daha fazla gizli katmandan oluşur [27]. YSA'nın birinci katmanı gelen bilgiyi alan girdi katmanıdır. Girdi katmanı bu bilgiyi ara (gizli) katmana iletir. Gizli katman bu bilgiyi işler ve ardından işlenmiş bilgiyi çıktı katmanına gönderir. Çıktı katmanı bilgiyi alır ve son olarak çıktı verilerini üretir [28].

İşlemci elemanlar (nöronlar), YSA katmanlarındaki temel öğedir. ÇKA'da aynı katmanın nöronları arasında herhangi bir bağlantı yoktur. Girdi ve çıktı nöronlarının sayısı sırasıyla bağımsız (girdi) ve bağımlı (çıktı) değişkenlerin sayısına eşittir [29]. Ancak, gizli katmanın ve nöronlarının sayıları ile ilgili özel bir kural yoktur.



Şekil 1. YSA'nın şematik bir gösterimi (A schematic illustration of the ANN)

Çok az sayıdaki gizli nöron öğrenme sürecini olumsuz yönde etkileyebilir. Öte yandan, çok sayıdaki gizli nöron aşırı uyum sorununa yol açacağından ağır genelleme yeteneğini önlüyor [30]. Optimum gizli katman sayısının ve gizli nöron sayısının belirlenmesinde çoğunlukla deneme yanılma yöntemi kullanılır [31].

Ağdaki herhangi bir nöron önceki katmanın nöronlarından bağlantı ağırlıkları ( $w_{ij}$ ) ile ağırlıklandırılmış giriş sinyallerini ( $x_i$ ) alır. Bir nöronun net girdisi ( $net_j$ ), ağırlıklı sinyallerin ve ilgili eşik ( $\theta_j$ ) toplamı ile elde edilir. Çıktı değerleri ( $y_j$ ),  $net_j$ 'e matematiksel fonksiyon ( $f(.)$ ) uygulanarak hesaplanır ve sonraki katmanın nöronlarına gönderilir. Bu süreç, Eşitlik 1 ve Eşitlik 2 ile formüle edilir. YSA'nın şematik bir çizimi Şekil 1'de verilmiştir [19].

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

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

Eğitim ve test YSA'nın iki ana aşamasıdır. Eğitim aşamasında, gerçek sonuçlar ile model çıktılarının birbirine olabildiğince yaklaşması için ağırlık ve eşik değerleri sürekli olarak değiştirilir [32]. Bu süreç, hata oranı en aza indirilinceye veya kabul edilebilir bir seviyeye ulaşıncaya dek tekrarlanır. Test aşamasında, modelin performansı eğitimin herhangi bir aşamasında kullanılmamış bir veri seti ile kontrol edilir. Ağ performansının yüksek olması durumunda ilgili ağırlık ve eşik değerleri hafızaya alınır. İyi eğilmiş/öğrenmiş bir YSA, daha önceden ağa sunulmayan verilerin sonucunu tahmin etmek için kullanılabilir [33].


### 3. YAPAY SİNİR AĞI MODELLERİNİN GELİŞTİRİLMESİ (DEVELOPMENT OF ARTIFICIAL NEURAL NETWORK MODELS)

#### 3.1. Veri Toplama (Data Collection)

Bu çalışmada kullanılan veriler Söğütlü ve ark. [34] tarafından yapılan bir çalışmadan elde edilmiştir. Yazarlar, Türkiye'nin Doğu Karadeniz Bölgesi'nde yetişen sarıçam (*Pinus sylvestris* L.), kayın (*Fagus*

*orientalis* L.) ve kiraz (*Prunus cerasus*) odunlarını deney materyalleri olarak seçmişlerdir [35]. Sarıçam, kayın ve kiraz odunlarının ortalama hava kurusu yoğunluk değerleri sırasıyla 0,51 g/cm<sup>3</sup>, 0,63 g/cm<sup>3</sup> ve 0,58 g/cm<sup>3</sup>'tür. Numunelerin verniklenmesinde akrilik (AC) vernik, poliüretan (PU) vernik ve su bazlı (WB) vernik tercih edilmiştir. Hava kurusu rutubetteki numuneler, 100 x 100 x 10 mm<sup>3</sup> ölçülerinde radyal veya teğet yönde kesilmiştir. Odun türü, kesme yönü, vernik türü ve zımpara kağıdı türü (80, 120, 180) faktörleri için 10'ar adet olmak üzere 3 x 2 x 3 x 3 deneme desenine göre 540 adet numune hazırlanmıştır. Hazırlanan numuneler, güneş ışığına doğrudan maruz kalmayan iyi havalandırılmış bir ortamda 20 ± 2 °C sıcaklık ve %50 ± 5 bağıl nem şartlarında sabit bir ağırlığa ulaşıncaya kadar bekletilmiştir. Ön kontroldeki 20 adet örneğin ortalama rutubet miktarı %9 ± 0,5 olarak belirlenmiştir [36]. Deney numuneleri ASTM-D 1667-87 [37] esaslarına uyularak hazırlanmıştır. Radyal ve teğet yüzeylerin zımparalama işlemleri bant zımpara makinesinde 9 m/dk besleme hızında gerçekleştirilmiştir. Yüzey pürüzlülüğü ISO 4287 [38] ve TS 2495 EN ISO 3274 [39] standartlarına göre TIME TR-200 test cihazı ile belirlenmiştir. Numunelerin pürüzlülük sonuçlarının değerlendirilmesinde ortalama pürüzlülük ( $R_a$ ) parametresi kullanılmıştır (bkz. Şekil 2). Yüzey pürüzlülüğü deneylerinin ardından adezyon direnci deneyleri için hazırlık yapılmıştır. Örneklerin verniklenmesi ASTM-D 3023 [40] esaslarına uygun olarak yapılmıştır. İki kat vernik uygulaması gerçekleştirilmiş ve her bir kat için yaklaşık olarak 90 g/m<sup>2</sup> vernik kullanılmıştır. Son kat akrilik ve poliüretan verniklerin uygulanmasında püskürtme tabancası kullanılırken, su bazlı verniğin uygulanması için orta kıl sertliğinde fırça kullanılmıştır. Püskürtme tabancası yüzeyden 20 cm uzaklıkta sabit bir hızda hareket ettirilmiştir. Kurutulan numunelerde katlar 400 numaralı zımpara kağıdı ile hafifçe zımparalanmıştır. Deney silindirleri örneklerin ortasına epoksi tutkalı ile yapıştırılmış ve basınç altında 24 saat süreyle bekletilmiştir. Deneylerde 688 kgf kapasitesine sahip TÜBİTAK TOGTAG-1100012 pnömatik adezyon test

cihazı kullanılmıştır. Çekme testi gerçekleştirerek adezyon direnci değerlendirilmiştir [41].



**Şekil 2.** İğne uçlu tarama cihazı ile belirlenen yüzey profili (Surface profile determined with a stylus-type profilometer) [34]

### 3.2. Yapay Sinir Ağı Analizi (Artificial Neural Network Analysis)

Bu çalışmada, odunun yüzey pürüzlülüğü ve adezyon direnci değerleri literatürden elde edilen verileri kullanarak YSA yaklaşımı ile modellenmiştir. YSA'ların oluşturulması, eğitimi ve optimizasyonu MATLAB paket programı kullanılarak gerçekleştirilmiştir. İlk olarak, odun türü, kesme yönü ve zımpara kağıdı türü değerlerine bağlı olarak yüzey pürüzlülüğü düzeyindeki değişim modellenmiştir. Ardından, vernik türü, odun türü, kesme yönü ve yüzey pürüzlülüğü değerlerine dayanarak adezyon direnci düzeyindeki değişimin modellenmesi gerçekleştirilmiştir. İlgili değişkenlerin yüzey pürüzlülüğü ve adezyon direnci düzeyleri üzerine etkilerini incelemek amacıyla; deney verileri eğitim ve test verileri şeklinde rastgele ve homojen bir şekilde gruplandırılıp, farklı veri setleri oluşturularak YSA'ları eğitmek için kullanılmıştır. Yüzey pürüzlülüğünün modellenmesi için deney verileri (18 veri) arasından 12

veri (toplam verinin %66,67'si) eğitim seti için ayrılmış ve geri kalan 6 veri (toplam verinin %33,33'ü) test seti için tahsis edilmiştir. Adezyon direncinin modellenmesi için deney verileri (54 veri) arasından 36 veri (toplam verinin %66,67'si) YSA'ların eğitimi için tercih edilmiş ve geri kalan 18 veri (toplam verinin %33,33'ü) YSA'ların performansını test etmek amacıyla kullanılmıştır. Tahmin modellerinde kullanılan veri setlerini yüzey pürüzlülüğü için Çizelge 1 ve Çizelge 2'de, adezyon direnci için Çizelge 3 ve Çizelge 4'te görmek mümkündür.

Bir ağın tasarımı çıktığı büyük ölçüde etkilediği için önemlidir. En uygun ağ mimarisi girdi ve çıktı verileri arasındaki ilişkinin en iyi şekilde açıklandığının bir göstergesidir. Ancak, en iyi ağın belirlenmesi için kesin bir yöntem yoktur [42]. Bu çalışmada, en uygun ağ mimarisinin ve parametrelerinin belirlenmesinde YSA modellemelerinde en çok kullanılan yöntem olan deneme yanılma metodu kullanılmıştır. Denemelerde gizli katman sayıları ve gizli katman(lar)daki nöron sayıları geniş bir yelpazede değiştirilip, farklı parametreler (aktivasyon fonksiyonu, eğitim algoritması, öğrenme kuralı, performans fonksiyonları vb.) ve veri setleri kullanılarak değişik modeller kurulup sayısız denemeler yapıp eğitimler gerçekleştirilerek yüzey pürüzlülüğü ve adezyon direnci için en uygun ağ mimarisi ve tahmin modeli belirlenmiştir. Diğer bir ifade ile birçok farklı YSA yapıları ve parametreleri gerçek ve tahmin edilen değerler arasındaki fark en aza indirilene kadar denenmiştir. Sonuç olarak, deney sonuçlarına en yakın çıktıları veren modeller tahminler yapmak için seçilmiştir. Seçilen YSA mimarileri Şekil 3'te gösterilmiştir.


**Çizelge 1.** Yüzey pürüzlülüğü için kullanılan eğitim veri seti ve tahmin modeli sonuçları (Training data set used for surface roughness, and prediction model results)

Odun türü	Kesme yönü	Zımpara kağıdı türü	Yüzey pürüzlülüğü ( $R_a$ , $\mu\text{m}$ )		
			Gerçek	Tahmin	Hata (%)
Fagus orientalis L.	Teğet	80	4,50	4,50	-0,08
Fagus orientalis L.	Teğet	120	3,14	3,09	1,63
Fagus orientalis L.	Radyal	120	3,01	3,04	-1,03
Fagus orientalis L.	Radyal	180	2,07	2,08	-0,37
Pinus sylvestris L.	Teğet	80	4,26	4,26	0,09
Pinus sylvestris L.	Teğet	180	2,55	2,68	-5,26
Pinus sylvestris L.	Radyal	80	4,20	4,22	-0,42
Pinus sylvestris L.	Radyal	120	3,68	3,61	1,93
Prunus cerasus	Teğet	120	3,34	3,38	-1,14
Prunus cerasus	Teğet	180	2,65	2,53	4,68
Prunus cerasus	Radyal	80	4,08	4,08	0,09
Prunus cerasus	Radyal	180	1,98	1,99	-0,26
<b>MAPE</b>			<b>1,41</b>		
<b>RMSE</b>			<b>0,06</b>		

**Çizelge 2.** Yüzey pürüzlülüğü için kullanılan test veri seti ve tahmin modeli sonuçları (Testing data set used for surface roughness, and prediction model results)

Odun türü	Kesme yönü	Zımpara kağıdı türü	Yüzey pürüzlülüğü ( $R_a$ , $\mu\text{m}$ )		
			Gerçek	Tahmin	Hata (%)
Fagus orientalis L.	Teğet	180	2,15	2,07	3,72
Fagus orientalis L.	Radyal	80	4,35	4,44	-2,16
Pinus sylvestris L.	Teğet	120	3,67	3,65	0,47
Pinus sylvestris L.	Radyal	180	2,71	2,65	2,31
Prunus cerasus	Teğet	80	4,71	4,49	4,77
Prunus cerasus	Radyal	120	2,91	2,92	-0,51
<b>MAPE</b>			<b>2,32</b>		
<b>RMSE</b>			<b>0,11</b>		

Yüzey pürüzlülüğü için 3 nörona sahip bir gizli katmanlı ağ mimarisi (3:3:1) ve adezyon direnci için ilk katmanında 3, ikinci katmanında 4 nöron bulunan iki gizli katmana sahip ağ mimarisi (4:3:4:1) tahminler yapmak için seçilmiştir. Modellerin en tutarlı sonucu verebilmesi için ağların yapısı genelleme yapabilecek en az nöron sayısı ile tasarlanmıştır.

**Şekil 3.** Tahmin modellerinin YSA mimarileri (ANN architectures of the prediction models)

Yüzey pürüzlülüğü ve adezyon direnci modellerinin belirlenmesinde ileri beslemeli ve geri yayımlı çok katmanlı YSA'lar kullanılmıştır. Önerilen modellerde, hiperbolik tanjant sigmoid fonksiyonu (tansig) gizli katman(lar)da ve doğrusal transfer fonksiyonu (purelin) çıktı katmanında transfer (aktivasyon) fonksiyonu olarak tercih edilmiştir. Eğitim algoritması olarak levenberg marquardt algoritması (trainlm) seçilmiş, öğrenme kuralı olarak momentumlu gradyan azaltım geri yayılım algoritması (traingdm) kullanılmış, performans fonksiyonu olarak da Eşitlik 3 ile hesaplanan ortalama karesel hata (MSE) tercih edilmiştir. Eşitlikte  $t_i$ , gerçek değeri;  $td_i$ , YSA ile tahmin edilen değeri;  $N$ , ise toplam ölçüm sayısını ifade etmektedir.

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

Her bir parametrenin modellere eşit katkı sağlaması amacıyla eğitim ve test setindeki veriler, modellerde hiperbolik tanjant sigmoid fonksiyonu kullanıldığından (-1,1) aralığında normalize edilerek ilgili ağlara sunulmuş, daha sonra sonuçların yorumlanabilmesi için veriler ters normalize işlemine tabi tutulmak suretiyle orijinal değerlerine çevrilmiştir. Normalizasyon (ölçeklendirme) işlemleri Eşitlik 4 yardımıyla gerçekleştirilmiştir. Eşitlikte  $X_{norm}$ , normalize edilmiş veriyi;  $X$ , değişkenin gerçek değerini;  $X_{min}$ , veri grubunun minimum değerini;  $X_{max}$ , ise veri grubunun maksimum değerini ifade etmektedir.

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

YSA'ların girdiler için doğru çıktıları üretecek hale gelmesi yani ağı eğitilmesi, bağlantı ağırlıklarının ve eşik değerlerinin belirlenmesi ile gerçekleşmektedir. Ağı doğru ağırlık değerine ulaşması, ağı genellemeler yapabilme yeteneğine kavuştuğunu diğer bir ifade ile ağı öğrendiğini gösterir. YSA'larda bilgi, ağıdaki bütün bağlantılar üzerine ağırlık değerleri ile dağılmıştır. Yüzey pürüzlülüğü ve adezyon direnci tahmin modellerinin bağlantı ağırlıkları ve eşik değerleri sırasıyla Çizelge 5 ve Çizelge 6'da verilmiştir.

İyi bilinen ve yaygın olarak kullanılan tanı vasıtaları (performans fonksiyonları) olan Eşitlik 5 ile hesaplanan ortalama mutlak yüzde hata (MAPE), Eşitlik 6 ile hesaplanan ortalama karesel hatanın karekökü (RMSE) ve Eşitlik 7 ile hesaplanan determinasyon katsayısı ( $R^2$ ) dikkate alınarak en iyi tahmin değerlerini veren modeller tespit edilmiştir.

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

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

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



**Çizelge 3.** Adezyon direnci için kullanılan eğitim veri seti ve tahmin modeli sonuçları (Training data set used for adhesion strength, and prediction model results)

Vernik türü	Odun türü	Kesme yönü	Yüzey pürüzlülüğü ( $R_a$ , $\mu\text{m}$ )	Adezyon direnci ( $\text{N}/\text{mm}^2$ )		
				Gerçek	Tahmin	Hata (%)
AC	Fagus orientalis L.	Teğet	3,14	2,42	2,38	1,65
AC	Fagus orientalis L.	Teğet	2,15	2,28	2,27	0,30
AC	Fagus orientalis L.	Radyal	4,35	2,12	2,10	0,92
AC	Fagus orientalis L.	Radyal	2,07	1,76	1,83	-4,16
AC	Pinus sylvestris L.	Teğet	4,26	2,48	2,53	-1,91
AC	Pinus sylvestris L.	Teğet	3,67	2,44	2,46	-0,86
AC	Pinus sylvestris L.	Radyal	3,68	2,14	2,06	3,78
AC	Pinus sylvestris L.	Radyal	2,71	1,95	1,95	0,20
AC	Prunus cerasus	Teğet	4,71	2,54	2,56	-0,76
AC	Prunus cerasus	Teğet	2,65	2,07	2,07	0,20
AC	Prunus cerasus	Radyal	4,08	2,42	2,42	0,02
AC	Prunus cerasus	Radyal	2,91	2,25	2,25	0,04
PU	Fagus orientalis L.	Teğet	4,50	3,81	3,84	-0,78
PU	Fagus orientalis L.	Teğet	3,14	3,55	3,50	1,43
PU	Fagus orientalis L.	Radyal	3,01	2,91	3,00	-3,04
PU	Fagus orientalis L.	Radyal	2,07	2,92	2,85	2,49
PU	Pinus sylvestris L.	Teğet	4,26	3,05	3,01	1,27
PU	Pinus sylvestris L.	Teğet	2,55	2,62	2,67	-1,88
PU	Pinus sylvestris L.	Radyal	4,20	2,96	2,92	1,26
PU	Pinus sylvestris L.	Radyal	3,68	2,67	2,69	-0,86
PU	Prunus cerasus	Teğet	3,34	3,35	3,38	-0,84
PU	Prunus cerasus	Teğet	2,65	3,31	3,28	0,96
PU	Prunus cerasus	Radyal	4,08	3,39	3,36	1,00
PU	Prunus cerasus	Radyal	1,98	3,15	3,19	-1,27
WB	Fagus orientalis L.	Teğet	4,50	1,97	1,97	0,17
WB	Fagus orientalis L.	Teğet	2,15	1,65	1,65	-0,11
WB	Fagus orientalis L.	Radyal	4,35	1,98	2,02	-2,23
WB	Fagus orientalis L.	Radyal	3,01	1,77	1,73	2,27
WB	Pinus sylvestris L.	Teğet	3,67	1,85	1,85	-0,04
WB	Pinus sylvestris L.	Teğet	2,55	1,82	1,81	0,31
WB	Pinus sylvestris L.	Radyal	4,20	4,10	4,10	0,04
WB	Pinus sylvestris L.	Radyal	2,71	2,73	2,73	0,03
WB	Prunus cerasus	Teğet	4,71	2,11	2,10	0,43
WB	Prunus cerasus	Teğet	3,34	1,96	1,97	-0,37
WB	Prunus cerasus	Radyal	2,91	1,78	1,78	-0,22
WB	Prunus cerasus	Radyal	1,98	1,64	1,64	0,11
<b>MAPE</b>				<b>1,06</b>		
<b>RMSE</b>				<b>0,04</b>		

Eşitlik 7'deki  $\bar{t}$ , tahmini değerlerin ortalamasını ifade etmektedir.

#### 4. BULGULAR VE TARTIŞMA (RESULTS AND DISCUSSION)

YSA modelleri, Söğütü ve ark. [34]'nın deney sonuçlarından elde edilen verilerle eğitilmiş ve test

edilmiştir. Yüzey pürüzlülüğü ve adezyon direnci YSA tahmin modellerinin tekrara (iterasyona) bağlı MSE değişimleri Şekil 4'te görülmekte olup, en iyi eğitim performansı yüzey pürüzlülüğü için 22. iterasyonda 0,0019588 ve adezyon direnci için 176. iterasyonda 0,00074997 olarak gerçekleşmiştir.

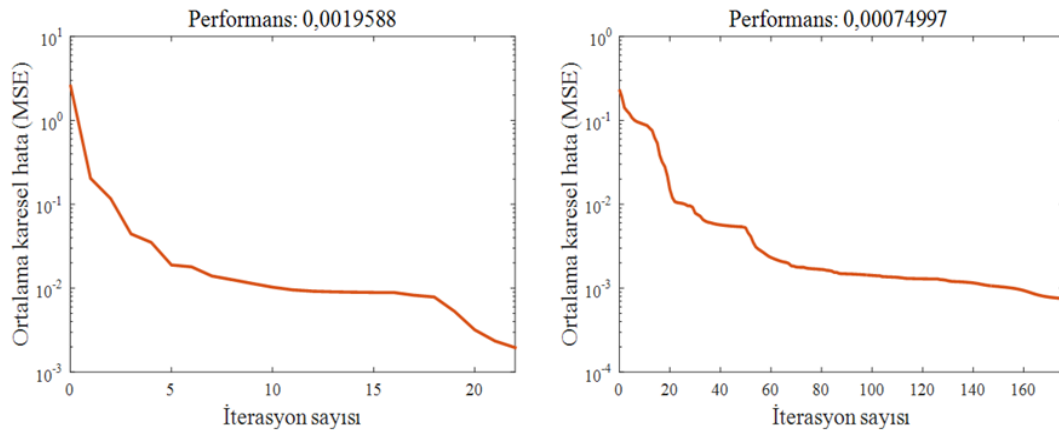
**Çizelge 4.** Adezyon direnci için kullanılan test veri seti ve tahmin modeli sonuçları (Testing data set used for adhesion strength, and prediction model results)

Vernik türü	Odun türü	Kesme yönü	Yüzey pürüzlülüğü (R <sub>a</sub> , µm)	Adezyon direnci (N/mm <sup>2</sup> )		
				Gerçek	Tahmin	Hata (%)
AC	Fagus orientalis L.	Teğet	4,50	2,44	2,53	-3,65
AC	Fagus orientalis L.	Radyal	3,01	1,84	1,95	-5,77
AC	Pinus sylvestris L.	Teğet	2,55	2,41	2,34	2,98
AC	Pinus sylvestris L.	Radyal	4,20	2,30	2,12	7,90
AC	Prunus cerasus	Teğet	3,34	2,32	2,31	0,32
AC	Prunus cerasus	Radyal	1,98	2,02	1,82	9,85
PU	Fagus orientalis L.	Teğet	2,15	3,47	3,27	5,64
PU	Fagus orientalis L.	Radyal	4,35	3,11	3,25	-4,43
PU	Pinus sylvestris L.	Teğet	3,67	2,74	2,89	-5,47
PU	Pinus sylvestris L.	Radyal	2,71	2,50	2,49	0,49
PU	Prunus cerasus	Teğet	4,71	3,79	3,54	6,62
PU	Prunus cerasus	Radyal	2,91	3,32	3,27	1,49
WB	Fagus orientalis L.	Teğet	3,14	1,94	1,80	7,31
WB	Fagus orientalis L.	Radyal	2,07	1,44	1,46	-1,61
WB	Pinus sylvestris L.	Teğet	4,26	2,28	2,18	4,19
WB	Pinus sylvestris L.	Radyal	3,68	3,80	3,67	3,48
WB	Prunus cerasus	Teğet	2,65	1,91	1,90	0,55
WB	Prunus cerasus	Radyal	4,08	2,12	1,96	7,57
<b>MAPE</b>				<b>4,41</b>		
<b>RMSE</b>				<b>0,13</b>		

Önerilen YSA modellerinin performansını değerlendirmek için grafiksel ve istatistiksel karşılaştırmalar kullanılmıştır. Gerçek değerler, tahmin edilen değerler, yüzde hata oranları ile MAPE ve RMSE değerleri yüzey pürüzlülüğü için Çizelge 1 ve Çizelge 2'de, adezyon direnci için Çizelge 3 ve Çizelge 4'te verilmiştir. Grafiksel ve istatistiksel karşılaştırmalar, YSA modellerinin tatmin edici ve istikrarlı sonuçlar ürettiğini teyit etmektedir. Çizelgeler incelendiğinde YSA tahmin modellerinin kullanılması ile tahmin edilen

değerlerin gerçek değerlere çok yakın olduğu görülmektedir.

Tahmin modellerinin performansları hata değerleri (MAPE ve RMSE) dikkate alınarak değerlendirilmiştir. En iyi YSA modelinin seçiminde düşük MAPE ve RMSE değerleri dikkate alınmaktadır [43]. Bu çalışmada, yüzey pürüzlülüğü için MAPE eğitim safhasında %1,41 ve test safhasında %2,32 olmuştur. RMSE değerleri ise eğitim ve test safhaları için sırasıyla 0,06 ve 0,11 olarak hesaplanmıştır. Adezyon direnci tahmin modelinin



**Şekil 4.** Yüzey pürüzlülüğü (sol görüntü) ve adezyon direnci (sağ görüntü) için her bir iterasyonda MSE'nin değişimleri (Variations of the MSE at each iteration for surface roughness (left image) and adhesion strength (right image))



**Çizelge 5.** Yüzey pürüzlülüğü tahmin modelinin bağlantı ağırlıkları ve eşikleri (Connection weights and biases of the surface roughness prediction model)

Gizli katman			Çıktı katmanı		
Nöron 1	Nöron 2	Nöron 3	Eşik 1	Nöron 1	Eşik 2
-1,75754	-0,16638	3,75657	3,60776	0,88197	0,49028
-1,10578	-0,00806	0,03065	-0,73057	2,69293	-
-0,12005	-0,51846	1,86015	1,48438	0,42231	-

**Çizelge 6.** Adezyon direnci tahmin modelinin bağlantı ağırlıkları ve eşikleri (Connection weights and biases of the adhesion strength prediction model)

Gizli katman 1				Gizli katman 2				Çıktı katmanı		
Nöron 1	Nöron 2	Nöron 3	Eşik 1	Nöron 1	Nöron 2	Nöron 3	Nöron 4	Eşik 2	Nöron 1	Eşik 3
1,74575	-4,73558	0,63597	-1,42390	3,14862	-1,78329	-1,31055	-3,87960	-4,63173	-3,58966	1,83177
0,58272	-7,26481	0,02393	2,74052	-0,38388	0,06705	1,25608	-2,46479	2,87257	-4,98043	-
-0,25730	-1,86899	-0,12776	0,83927	0,97589	-2,79390	0,51670	3,82539	-1,74101	4,71426	-
-0,04703	0,90159	0,09122	-	-	-	-	-	-5,33601	4,29824	-

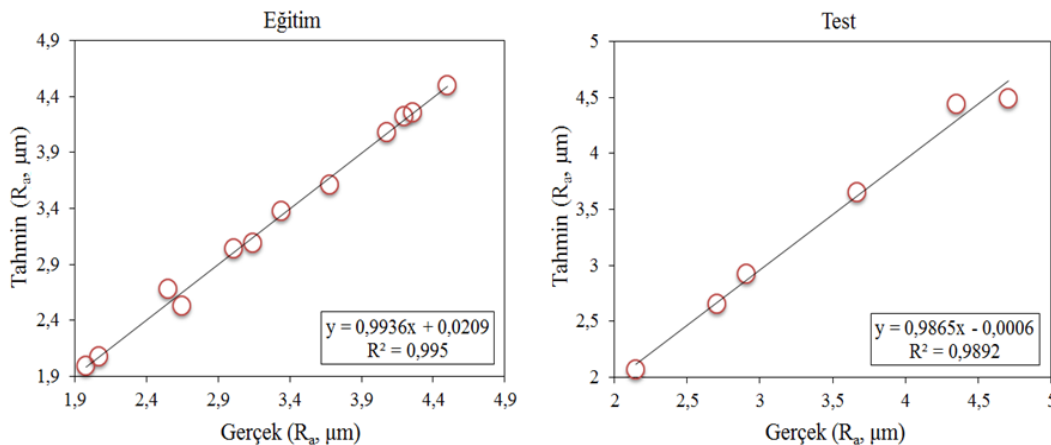
eğitim safhasındaki MAPE ve RMSE değerleri sırasıyla %1,06 ve 0,04 olmuş ve test safhasındaki MAPE ve RMSE değerleri sırasıyla %4,41 ve 0,13 olarak hesaplanmıştır. Bu hata düzeyleri YSA tahmin modellerinin etkili bir şekilde memnun edici sonuçlar ürettiğini ve yeterli doğruluk ve güvenilirliğe sahip olduklarını göstermektedir.

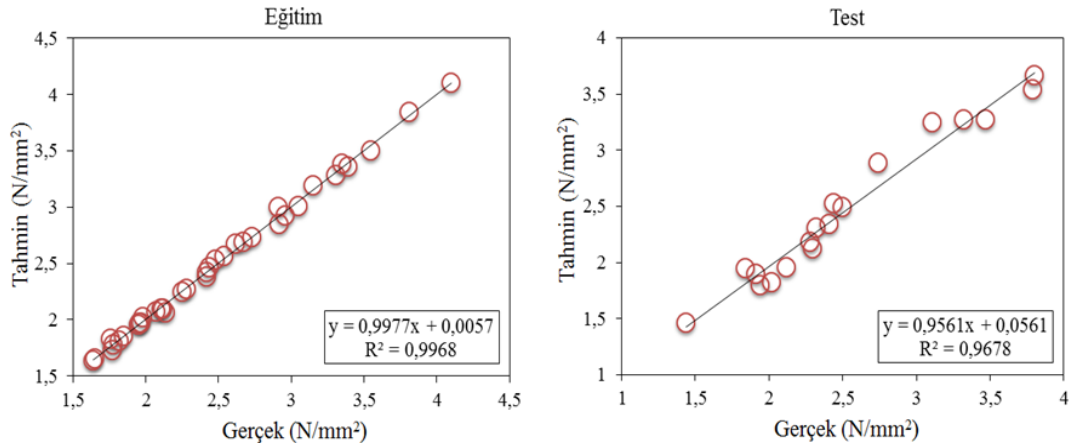
Tahmin edilen değerler ile ölçülen değerler arasındaki regresyon analizi genellikle ağların geçerliliğini ve doğruluğunu değerlendirmek için kullanılır.  $R^2$  değerinin 1'e yaklaşması durumunda tahmin doğruluğu artmaktadır [18]. Bu durum, gerçek değerler ile tahmin edilen değerler arasında mükemmel bir uyum olduğunu ifade eder. Hesaplanan değerler ile gerçek değerler arasındaki ilişkileri gösteren diyagramlar Şekil 5 ve Şekil 6'da sunulmuştur. Şekillerden görüleceği üzere yüzey pürüzlülüğü ve adezyon direnci tahmin modellerinin test safhasındaki  $R^2$  değerleri sırasıyla 0,9892 ve 0,9678 olmuştur. Bu değerler, elde edilen ağların yüzey pürüzlülüğünün gerçek verilerinin en az %98,92'sini ve

adezyon direncinin gerçek verilerinin en az %96,78'ini açıkladığını gösterir. Hesaplanan  $R^2$  değerleri, geliştirilen modellerin iyi bir performansla sahip olduğunu kanıtlamış ve YSA'ların tahmin amaçlı kullanılabilirliğini desteklemiştir.

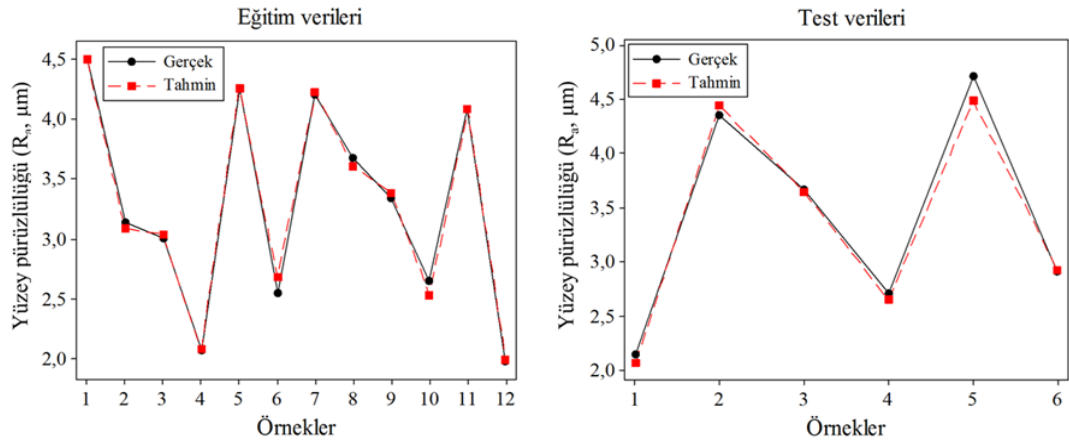
Şekil 7 ve Şekil 8, YSA tahmin modellerinin çıktıları ile deneysel sonuçları karşılaştırmaktadır. Şekillerden görüleceği üzere değerler birbirine çok yakındır. Deneysel sonuçlar ve tahmin edilen değerler arasındaki yüksek benzerlik önerilen YSA modellerinin güvenilirliğini arttırmaktadır.

Eğitilmiş YSA modeli optimizasyon çalışmaları için istenen ara değerleri sağlayabilir. Başka bir deyişle, iyi eğitilmiş model sayesinde daha fazla deneysel çalışma yürütmeden belirtilen girdi değerlerine karşılık gelen çıktıları yüksek doğrulukta tespit etmek mümkündür [44]. Parametrelerin bağımlı değişken üzerine etkilerinin tüm çıktıları çeşitli kombinasyonlar için YSA tarafından tahmin edilebilir. Bu çalışmada, deneylerde kullanılmayan 150 numaralı zımpara kağıdı türü ile farklı

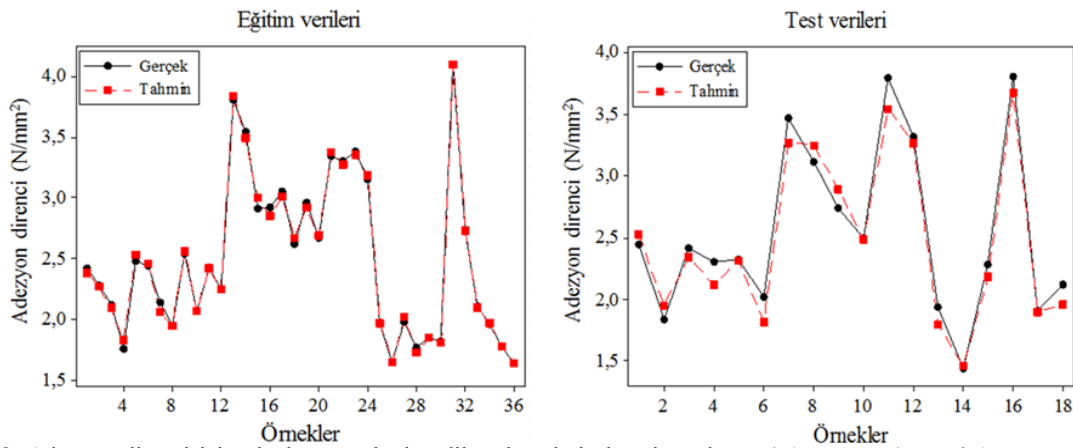
**Şekil 5.** Yüzey pürüzlülüğü için ölçülen sonuçlar ile tahmin edilen değerler arasındaki ilişki (The relationship between the measured results and the predicted values for surface roughness)



Şekil 6. Azezyon direnci için ölçülen sonuçlar ile tahmin edilen değerler arasındaki ilişki (The relationship between the measured results and the predicted values for adhesion strength)



Şekil 7. Yüze pürüzlülüğü için ölçülen ve tahmin edilen değerlerin karşılaştırılması (The comparison of the measured and predicted values for surface roughness)



Şekil 8. Azezyon direnci için ölçülen ve tahmin edilen değerlerin karşılaştırılması (The comparison of the measured and predicted values for adhesion strength)

odun türü (*Fagus orientalis* L., *Pinus sylvestris* L. ve *Prunus cerasus*) ve kesme yönü (teğet ve radyal) değerleri kullanılarak yüze pürüzlülüğü değerleri tahmin edilmiş ve Çizelge 7'de sunulmuştur. Çizelge 7 incelendiğinde 150 numaralı zımpara kağıdı türünde hem teğet hem de radyal yönde en yüksek yüze pürüzlülüğü

değerlerine sarıçam (*Pinus sylvestris* L.) odununun sahip olduğu ve teğet yönde kesilen odunların yüze pürüzlülüğü değerlerinin radyal yönde kesilenlerden daha yüksek olduğu görülmektedir. Benzer sonuçlar bazı araştırmacılar tarafından da bildirilmiştir [45, 46].

**Çizelge 7.** 150 numaralı zımpara kağıdı için yüzey pürüzlülüğü değerleri (Surface roughness values for 150-grit sandpaper)

Odun türü	Kesme yönü	Zımpara kağıdı türü	Yüzey pürüzlülüğü ( $R_a$ , $\mu\text{m}$ )
Fagus orientalis L.	Teğet	150	2,3264
Fagus orientalis L.	Radyal	150	2,2976
Pinus sylvestris L.	Teğet	150	3,0949
Pinus sylvestris L.	Radyal	150	3,0518
Prunus cerasus	Teğet	150	2,8498
Prunus cerasus	Radyal	150	2,3568

**Çizelge 8.** Farklı yüzey pürüzlülüğü değerleri için adezyon direncindeki değişim (The change in adhesion strength for different surface roughness values)

Vernik türü	Odun türü	Kesme yönü	Zımpara kağıdı türü	Yüzey pürüzlülüğü ( $R_a$ , $\mu\text{m}$ )	Adezyon direnci ( $\text{N}/\text{mm}^2$ )
AC	Fagus orientalis L.	Teğet	150	2,3264	2,2924
AC	Fagus orientalis L.	Radyal	150	2,2976	1,8609
AC	Pinus sylvestris L.	Teğet	150	3,0949	2,3977
AC	Pinus sylvestris L.	Radyal	150	3,0518	1,9864
AC	Prunus cerasus	Teğet	150	2,8498	2,1553
AC	Prunus cerasus	Radyal	150	2,3568	2,0224
PU	Fagus orientalis L.	Teğet	150	2,3264	3,3128
PU	Fagus orientalis L.	Radyal	150	2,2976	2,8824
PU	Pinus sylvestris L.	Teğet	150	3,0949	2,7751
PU	Pinus sylvestris L.	Radyal	150	3,0518	2,3951
PU	Prunus cerasus	Teğet	150	2,8498	3,3094
PU	Prunus cerasus	Radyal	150	2,3568	3,2245
WB	Fagus orientalis L.	Teğet	150	2,3264	1,6796
WB	Fagus orientalis L.	Radyal	150	2,2976	1,5360
WB	Pinus sylvestris L.	Teğet	150	3,0949	1,7714
WB	Pinus sylvestris L.	Radyal	150	3,0518	3,0771
WB	Prunus cerasus	Teğet	150	2,8498	1,9191
WB	Prunus cerasus	Radyal	150	2,3568	1,6983

Çizelge 7’de sunulan sonuçların yanında, adezyon direnci üzerindeki diğer parametrelerin etkilerinin tüm çıktıları geliştirilen ikinci model yardımıyla belirlenmiştir. Elde edilen ikinci tahmin modeli ile zımpara kağıdı türüne (150) bağlı olarak vernik türü (AC, PU ve WB), odun türü (*Fagus orientalis* L., *Pinus sylvestris* L. ve *Prunus cerasus*), kesme yönü (teğet ve radyal) ve ilk tahmin modeli ile belirlenen yüzey pürüzlülüğü değerlerinin (2,3264; 2,2976; 3,0949; 3,0518; 2,8498 ve 2,3568) değişmesi ile adezyon direncindeki değişimler tahmin edilmiş ve Çizelge 8’de sunulmuştur. Bu çizelgeden en yüksek adezyon direnci değerlerinin PU vernik kullanılması sonucunda elde edildiği görülmektedir. PU verniğin kullanılması durumunda yüksek adezyon direnci değerlerine ulaşılabileceği daha önce yapılan çalışmalarda da belirtilmiştir [4, 47, 48]. Bu durumun vernik üretiminde kullanılan sentetik reçine ile ağaç malzemenin selüloz bileşeni arasında kurulan güçlü kimyasal bağlardan kaynaklandığını söylemek mümkündür [48].

## 5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, odun türü, kesme yönü ve zımpara kağıdı türü değişkenlerinin yüzey pürüzlülüğü üzerine etkileri ile vernik türü, odun türü, kesme yönü ve yüzey pürüzlülüğü değişkenlerinin adezyon direnci üzerine etkilerini modellemek için YSA modelleri geliştirilmiştir. Girdi ve çıktı parametreleri arasındaki karmaşık ve doğrusal olmayan ilişkiler göz önünde bulundurulduğunda, modeller tarafından oldukça cesaret verici ve tatmin edici sonuçlar elde edilmiştir. Yüzey pürüzlülüğü tahmin modelinin test safhasındaki MAPE değeri %2,32, RMSE değeri 0,11 ve  $R^2$  değeri 0,9892; adezyon direnci tahmin modelinin test aşamasındaki MAPE değeri %4,41, RMSE değeri 0,13 ve  $R^2$  değeri 0,9678 olarak hesaplanmıştır. Çalışma sonuçları, zaman alıcı olan ve yüksek test maliyetleri gerektiren deneysel çalışmalara gerek kalmaksızın girdi değişkenlerinin değer aralığında odunun yüzey pürüzlülüğü ve adezyon direnci değerlerinin tahmin edilmesinde YSA modellemesinin kullanılabilirliğini göstermiştir.

Geliştirilen YSA modellerinin tahmin sonuçları sayesinde deneysel araştırmalar için zaman, enerji ve maliyetin düşürülmesi mümkün olacaktır.

#### TEŞEKKÜR (ACKNOWLEDGEMENT)

Yazarlar, makalede kullanılan verilerin sağlanmasından dolayı Dr. Cevdet Söğütü, Dr. Pascal Nzokou, İsmail Koç, Rahmi Tutgun ve Dr. Nihat Döngel'e teşekkür etmektedir.

#### KAYNAKLAR (REFERENCES)

- [1] Priadi T. and Hiziroglu S., "Characterization of heat treated wood species", *Materials and Design*, 49: 575-582, (2013).
- [2] Akbiyik A., Lamanna A. J. and Hale W. M., "Feasibility investigation of the shear repair of timber stringers with horizontal splits", *Construction and Building Materials*, 21: 991-1000, (2007).
- [3] Hauptmann M., Müller U., Obersriebnig M., Gindl-Altmutter W., Beck A. and Hansmann C., "The optical appearance of wood related to nanoscale surface roughness", *BioResources*, 8: 4038-4045, (2013).
- [4] Kılıç M., "The effects of steaming of beech (*Fagus orientalis* L.) and sapele (*Entandrophragma cylindricum*) woods on the adhesion strength of varnish", *Journal of Applied Polymer Science*, 113: 3492-3497, (2009).
- [5] Vitosytė J., Ukvalbergienė K. and Keturakis G., "The effects of surface roughness on adhesion strength of coated ash (*Fraxinus excelsior* L.) and birch (*Betula* L.) wood", *Materials Science*, 18: 347-351, (2012).
- [6] Ratnasingam J. and Scholz F., "Optimal surface roughness for high-quality finish on rubberwood (*Hevea brasiliensis*)", *Holz als Roh- und Werkstoff*, 64: 343-345, (2006).
- [7] Magoss E., "General regularities of wood surface roughness", *Acta Silvatica & Lignaria Hungarica*, 4: 81-93, (2008).
- [8] Sofuoğlu S. D. and Kurtoğlu A., "Effects of machining conditions on surface roughness in planing and sanding of solid wood", *Drvna Industrija*, 66: 265-272, (2015).
- [9] Burdurlu E., Usta İ., Ulupınar M., Aksu B. and Erarslan T. Ç., "The effect of the number of blades and the grain size of abrasives in planing and sanding on the surface roughness of European black pine and Lombardy poplar", *Turkish Journal of Agriculture and Forestry*, 29: 315-321, (2005).
- [10] Singer H. and Özşahin Ş., "Employing an analytic hierarchy process to prioritize factors influencing surface roughness of wood and wood-based materials in the sawing process", *Turkish Journal of Agriculture and Forestry*, 42: 364-371, (2018).
- [11] Hendarto B., Shayan E., Ozarska B. and Carr R., "Analysis of roughness of a sanded wood surface", *International Journal of Advanced Manufacturing Technology*, 28: 775-780, (2006).
- [12] Haghbakhsh R., Adib H., Keshavarz P., Koolivand M. and Keshtkari S., "Development of an artificial neural network model for the prediction of hydrocarbon density at high-pressure, high-temperature conditions", *Thermochimica Acta*, 551: 124-130, (2013).
- [13] Ozsahin S. and Murat M., "Prediction of equilibrium moisture content and specific gravity of heat treated wood by artificial neural networks", *European Journal of Wood and Wood Products*, 76: 563-572, (2018).
- [14] Avramidis S. and Iliadis L., "Predicting wood thermal conductivity using artificial neural networks", *Wood and Fiber Science*, 37: 682-690, (2005).
- [15] Samarasinghe S., Kularisi D. and Jamieson T., "Neural networks for predicting fracture toughness of individual wood samples", *Silva Fennica*, 41: 105-122, (2007).
- [16] Castellani M. and Rowlands H., "Evolutionary feature selection applied to artificial neural networks for wood-veneer classification", *International Journal of Production Research*, 46: 3085-3105, (2008).
- [17] Ceylan İ., "Determination of drying characteristics of timber by using artificial neural networks and mathematical models", *Drying Technology*, 26: 1469-1476, (2008).
- [18] Özşahin Ş., "The use of an artificial neural network for modeling the moisture absorption and thickness swelling of oriented strand board", *BioResources*, 7: 1053-1067, (2012).
- [19] Ozsahin S., "Optimization of process parameters in oriented strand board manufacturing with artificial neural network analysis", *European Journal of Wood and Wood Products*, 71: 769-777, (2013).
- [20] Tiryaki S., Malkoçoğlu A. and Özşahin Ş., "Using artificial neural networks for modeling surface roughness of wood in machining process", *Construction and Building Materials*, 66: 329-335, (2014).
- [21] Tiryaki S., Özşahin Ş. and Aydın A., "Employing artificial neural networks for minimizing surface roughness and power consumption in abrasive machining of wood", *European Journal of Wood and Wood Products*, 75: 347-358, (2017).
- [22] Tiryaki S., Özşahin Ş. and Yıldırım İ., "Comparison of artificial neural network and multiple linear regression models to predict optimum bonding strength of heat treated woods", *International Journal of Adhesion and Adhesives*, 55: 29-36, (2014).
- [23] Tiryaki S., Bardak S. and Bardak T., "Experimental investigation and prediction of bonding strength of Oriental beech (*Fagus orientalis* Lipsky) bonded with polyvinyl acetate adhesive", *Journal of Adhesion Science and Technology*, 29: 2521-2536, (2015).
- [24] Khanlou H. M., Sadollah A., Ang B. C., Kim J. H., Talebian S. and Ghadimi A., "Prediction and optimization of electrospinning parameters for polymethyl methacrylate nanofiber fabrication using response surface methodology and artificial neural networks", *Neural Computing & Applications*, 25: 767-777, (2014).
- [25] Abbot J. and Marohasy J., "Input selection and optimisation for monthly rainfall forecasting in Queensland, Australia, using artificial neural networks", *Atmospheric Research*, 138: 166-178, (2014).
- [26] Yadav A. K. and Chandel S. S., "Solar radiation prediction using Artificial Neural Network techniques: A review", *Renewable & Sustainable Energy Reviews*, 33: 772-781, (2014).
- [27] Fathi M., Mohebbi M. and Razavi S. M. A., "Application of image analysis and artificial neural network to predict mass transfer kinetics and color changes of osmotically

- dehydrated kiwifruit", *Food and Bioprocess Technology*, 4: 1357-1366, (2011).
- [28] Canakci A., Ozsahin S. and Varol T., "Modeling the influence of a process control agent on the properties of metal matrix composite powders using artificial neural networks", *Powder Technology*, 228: 26-35, (2012).
- [29] Ariana M. A., Vaferi B. and Karimi G., "Prediction of thermal conductivity of alumina water-based nanofluids by artificial neural networks", *Powder Technology*, 278: 1-10, (2015).
- [30] Hamzehie M. E., Fattahi M., Najibi H., Van der Bruggen B. and Mazinani S., "Application of artificial neural networks for estimation of solubility of acid gases (H<sub>2</sub>S and CO<sub>2</sub>) in 32 commonly ionic liquid and amine solutions", *Journal of Natural Gas Science and Engineering*, 24: 106-114, (2015).
- [31] Monjezi M., Hasanipanah M. and Khandelwal M., "Evaluation and prediction of blast-induced ground vibration at Shur River Dam, Iran, by artificial neural network", *Neural Computing & Applications*, 22: 1637-1643, (2013).
- [32] Roy S., Banerjee R. and Bose P. K., "Performance and exhaust emissions prediction of a CRDI assisted single cylinder diesel engine coupled with EGR using artificial neural network", *Applied Energy*, 119: 330-340, (2014).
- [33] Yildirim I., Ozsahin S. and Akyuz K. C., "Prediction of the financial return of the paper sector with artificial neural networks", *BioResources*, 6: 4076-4091, (2011).
- [34] Söğütlü C., Nzokou P., Koc I., Tutgun R. and Döngel N., "The effects of surface roughness on varnish adhesion strength of wood materials", *Journal of Coatings Technology and Research*, 13: 863-870, (2016).
- [35] TS 2470, "Wood–Sampling methods and general requirements for physical and mechanical tests", (1976).
- [36] TS 2471, "Wood, determination of moisture content for physical and mechanical tests", (2005).
- [37] ASTM-D 1667-87, "Standard methods for conducting machining tests of wood and wood-base materials", (1999).
- [38] ISO 4287, "Geometrical product specifications surface texture profile method terms, definitions and surface texture parameters", (1997).
- [39] TS 2495 EN ISO 3274, "Geometrical product specifications (GPS)–Surface texture: Profile method–Nominal characteristics of contact (stylus) instruments", (2005).
- [40] ASTM-D 3023, "Standard practice for determination of resistance of factory applied coatings on wood products to stains and reagents", (1998).
- [41] TS EN ISO 4624, "Paints and varnishes–pull-off test for adhesion", (2006).
- [42] Seyhan M., Akansu Y. E., Murat M., Korkmaz Y. and Akansu S. O., "Performance prediction of PEM fuel cell with wavy serpentine flow channel by using artificial neural network", *International Journal of Hydrogen Energy*, 42: 25619-25629, (2017).
- [43] Küçükönder H., Boyacı S. and Akyüz A., "A modeling study with an artificial neural network: developing estimation models for the tomato plant leaf area", *Turkish Journal of Agriculture and Forestry*, 40: 203-212, (2016).
- [44] Varol T., Canakci A. and Ozsahin S., "Prediction of effect of reinforcement content, flake size and flake time on the density and hardness of flake AA2024-SiC nanocomposites using neural networks", *Journal of Alloys and Compounds*, 739: 1005-1014, (2018).
- [45] Söğütlü C., "Bazı faktörlerin zımparalanmış ağaç malzeme yüzey pürüzlülüğüne etkisi", *Politeknik Dergisi*, 8: 345-350, (2005).
- [46] Aslan S., Coşkun H. and Kılıç M., "The effect of the cutting direction, number of blades and grain size of the abrasives on surface roughness of Taurus cedar (*Cedrus Libani A. Rich.*) woods", *Building and Environment*, 43: 696-701, (2008).
- [47] Altun S. and Esmer M., "Isıl işlemin bazı ağaç malzemelerde yüzey pürüzlülüğü ve vernik yapışma direncine etkisi", *Politeknik Dergisi*, 20: 231-239, (2017).
- [48] Budakçı M. and Sönmez A., "Determining adhesion strength of some wood varnishes on different wood surfaces", *Journal of the Faculty of Engineering and Architecture of Gazi University*, 25: 111-118, (2010).