

## Yapay Sinir Ağları (YSA) Kullanılarak CLT Perde Duvarların Yanal Yük Altındaki Rijitliklerinin Kereste Direnç Sınıflarına Göre Tahmin Edilmesi\*

### Predicting Stiffness of CLT Shear Walls Under Lateral Loads According to Timber Strength Classes Using Artificial Neural Network (ANN)

 Abdullah Uğur BİRİNCİ<sup>1</sup>,  Okan İLHAN<sup>1</sup>,  Aydın DEMİR<sup>1</sup>,  Cenk DEMİRKİR<sup>1</sup>

#### Özet

Bu çalışmada, öncelikle yapay sinir ağları (YSA) kullanarak ağaç türü ve kereste direnç sınıfları gibi üretim parametrelerinin CLT perde duvarların yanıl yük altındaki rijitlik performansını üzerindeki etkilerinin belirlenmesi amaçlanmıştır. Daha sonra, analizler sonucunda elde edilen YSA tahmin modellerini kullanarak, CLT perde duvarlar için en yüksek rijitlik değerini verecek orta ve dış tabakalarda kullanılan kereste direnç sınıflarına ait optimum tabaka kombinasyonlarının ortaya konulması amaçlanmıştır. Bu çalışmada, ladin, kızılğaç ve bu iki ağaç türünü içeren hibrit CLT paneller üretilmiştir. Kerestelerin direnç sınıfları TS EN 338 standardına göre hasarsız olarak belirlenmiş ve ladin için C<sub>16</sub>, C<sub>22</sub>, C<sub>30</sub>, kızılğaç için ise D<sub>18</sub>, D<sub>30</sub>, D<sub>40</sub> grubu keresteleri, çalışma kapsamında CLT üretiminde kullanılmak üzere seçilmiştir. Ağaç türü ve direnç sınıfı kombinasyonlarından oluşan 30 farklı test grubu için CLT paneller üretilmiştir. CLT panellerden oluşturulan perde duvarlar ASTM E 72 standardına göre analiz edilmiş, elde edilen maksimum yük ve bu yükteki deplasman miktarlarından rijitlik hesaplanmıştır. YSA modelleri sonucunda, deneysel verilerden yola çıkarak tahmin değerleri elde edilmiş ve bu verilerle optimum tabaka kombinasyonları belirlenmiştir. Buna göre, CLT perde duvarlar için elde edilen optimum kereste direnç sınıfları ve tabaka kombinasyonları, ladinde C<sub>30</sub>-C<sub>18</sub>-C<sub>30</sub>, kızılğaçta D<sub>30</sub>-D<sub>35</sub>-D<sub>30</sub>, hibritlerde C<sub>30</sub>-D<sub>24</sub>-C<sub>30</sub> ve D<sub>30</sub>-C<sub>30</sub>-D<sub>30</sub> olarak tespit edilmiştir.

**Anahtar Kelimeler:** Çapraz Lamine Ahşap (CLT), Kereste Direnç Sınıfı, Yapay Sinir Ağları (YSA), Perde Duvar, Rijitlik

#### Abstract

In this study, it was primarily aimed to determine the effects of production parameters such as wood species and timber strength classes on the stiffness performance of CLT shear walls under lateral load using artificial neural network (ANN). Then, using the ANN prediction models obtained as a result of the analyses, it was aimed to reveal the optimum layer combinations of the timber strength classes used in the middle and outer layers that will give the highest stiffness value for CLT shear walls. In this study, spruce, alder and these two wood species hybrid CLT panels incorporating were produced. The timber strength classes were determined as undamaged according to the TS EN 338 standard, and C<sub>16</sub>, C<sub>22</sub>, C<sub>30</sub>, group timbers for spruce and D<sub>18</sub>, D<sub>30</sub>, D<sub>40</sub> group timbers for alder were selected to be used in CLT production within the scope of the study. CLT panels were produced for 30 different test groups consisting of wood species and strength class combinations. The shear walls formed from CLT panels was analyzed according to the ASTM E 72 standard, the stiffness was calculated from the maximum load obtained and the displacement amounts at this load. As a result of ANN modeling, prediction values were obtained based on experimental data and optimum layer combinations were determined with these data. According to this, the optimum timber strength classes and layer combinations for CLT shear walls were determined as C<sub>30</sub>-C<sub>18</sub>-C<sub>30</sub> for spruce, D<sub>30</sub>-D<sub>35</sub>-D<sub>30</sub> for alder, and C<sub>30</sub>-D<sub>24</sub>-C<sub>30</sub> and D<sub>30</sub>-C<sub>30</sub>-D<sub>30</sub> for hybrids.

**Keywords:** Cross Laminated Timber (CLT), Timber Strength Class, Artificial Neural Networks (ANN), Shear Wall, Rigidity

Geliş Tarihi: 26.02.2024, Düzeltme Tarihi: 26.04.2024, Kabul Tarihi: 15.05.2024

Adres: Karadeniz Teknik Üniversitesi, Orman Fakültesi, Orman Endüstri Mühendisliği Bölümü, 61080, Trabzon, Türkiye

E-mail: [ugurbirinci@ktu.edu.tr](mailto:ugurbirinci@ktu.edu.tr)

\*Bu çalışma, Türk Bilimsel ve Teknik Araştırma Kurumu (TÜBİTAK) 220O012 no'lu projeden üretilmiştir.

## 1. Giriş

Ahşap esaslı yapılar, son yirmi yılda konut ve konut dışı inşaatlarda, ayrıca ahşap kullanımına yatkın olmayan ülkelerde de popülerlik kazanmaktadır. Bu gelişmenin temel nedeni olarak yapı elemanları için kullanılan Glulam, çapraz lamine ahşap (CLT) ve Lamine Kaplama Kereste (LVL) gibi yüksek verimliliğe sahip mühendislik ve sürdürülebilir ahşap ürünlerinin piyasaya sürülmesi gösterilmektedir (Sandoli ve ark., 2021). Mükemmel sismik direncinin yanı sıra çevre dostu ve eko-sürdürülebilirlik özellikleri ahşabı özellikle takdir edilen bir yapı malzemesi haline getirmiştir (Chen ve ark., 2019). CLT paneller, 1990'ların sonlarında Orta Avrupa'da geliştirildikten sonra özellikle Kuzey Amerika'da orta yükseklikte konut ve konut dışı inşaatlarda kullanımı giderek yaygınlaşmıştır (Gagnon ve Pirvu, 2012). CLT; beton ve çeliğe göre daha hafif, inşa süresinin kısa ve karbon ayak izinin düşük olması, deprem dayanıklılığı gibi avantajları nedeniyle müstakil evlerin yanında, çok katlı yapılar, okullar, oditoryumlar, gösteri merkezleri, spor salonları, tiyatrolar, ticari ve dini yapılarda kullanılabilen cazip bir malzeme olarak görülmektedir (Di Bella ve Mitrovic, 2020; Hindman ve Golden, 2020; Hematabadi ve ark., 2020). Bununla birlikte, CLT paneller özellikle platform tipi yapıların ana yanal kuvvet direnç sistemlerinde perde duvar olarak sıkça tercih edilmektedir (Tannert ve ark., 2018). Perde duvarların yanal yük dayanımları, kırılma anındaki direnç, eğilme direnci, rijitlik ve süneklik olmak üzere genel olarak dört faktörden etkilenmektedir (Demir ve ark., 2021). Perde duvarların yük taşıma kapasitesi, kaplama materyali ve çerçeve arasındaki bağlantıların gücünün yanında, perde duvarda kullanılan ahşap materyalin özelliklerinden de etkilenebilmektedir. CLT perde duvarlarda özellikle rijitliğin ağaç türü, kereste kalitesi gibi etmenlerden farklılık gösterebileceği düşünülmektedir.

CLT panellerde kullanılan ağaç türleri incelendiğinde, genel olarak çam, ladin gibi iğne yapraklı ağaçların tercih edildiği literatürde belirlense de son zamanlarda hızlı büyüyen yerli ağaç türlerinin de CLT ve hibrit CLT üretiminde kullanıldığı tespit edilmiştir (Srivaro ve ark., 2020; Dong ve ark., 2023). Tercih edilen ağaç türleri önemli olmakla birlikte kullanılan türlerin kalite ve direnç sınıfı, CLT panel kalitesini etkileyen özelliklerden en önemlileri arasında gösterilmektedir. TS EN 338 (2016) Avrupa normuna göre; iğne yapraklı ağaç türleri için 12 (C<sub>14</sub>, C<sub>16</sub>, C<sub>18</sub>, C<sub>20</sub>, C<sub>22</sub>, C<sub>24</sub>, C<sub>27</sub>, C<sub>30</sub>, C<sub>35</sub>, C<sub>40</sub>, C<sub>45</sub>, C<sub>50</sub>), yapraklı ağaç türleri için ise 8 grup (D<sub>18</sub>, D<sub>24</sub>, D<sub>30</sub>, D<sub>35</sub>, D<sub>40</sub>, D<sub>50</sub>, D<sub>60</sub>, D<sub>70</sub>) olacak şekilde bir direnç sınıflandırması yapılmıştır. Bu sınıflandırmalar kerestenin kalitesini belirlediği gibi satış fiyatını da etkileyen en önemli unsurdur. Yapılan literatür araştırmasında; Avrupa'da CLT

üretimi yapan büyük firmaların üretiminde kullandıkları kerestelerin, TS EN 338 (2016) standardına göre sınıflandırmasını gösteren bir çalışmada; genel olarak C<sub>24</sub> direnç sınıfındaki kerestelerin kullanıldığı ifade edilmiştir (Wiruszewski ve Mazela, 2017). Literatürde yapılan çalışmalarda, CLT üretiminde genel olarak iğne yapraklı ağaçların kullanıldığı ve herhangi bir direnç değeri kıyaslamasından ziyade mevcut tek bir grup üzerinde analizler yapıldığı görülmüş ve çoğunlukla da bu grubun C<sub>24</sub> olduğu tespit edilmiştir (Hassanieh ve ark., 2017; Reynolds ve ark., 2017; Follesa ve Fragiancomo, 2018; Brandner, 2018; Turesson ve ark., 2019; Lie ve ark., 2020). Bunların dışında, C<sub>16</sub> (Kippel ve ark., 2014), C<sub>18</sub> (Soriano ve ark., 2016; Luengo ve ark., 2017), C<sub>22</sub> (Guo ve ark., 2017) ve C<sub>30</sub> (Hadigheh ve Dias da Costa, 2020) direnç sınıflarının da tercih edildiği görülmüştür. Ayrıca bazı çalışmalarda iki farklı direnç sınıfına ait kerestelerin tek bir CLT panelin üretiminde kullanıldığı ifade edilmiştir (O'Dowd ve ark., 2016). Hem Türkiye'de yetişen hızlı büyüyen ağaç türlerinden biri olan kızılğaç kerestelerinin CLT üretiminde kullanılmasına yönelik hem de kereste direnç sınıfları üzerine kapsamlı bir çalışmaya rastlanılmamasından dolayı bu çalışmanın literatüre önemli katkı sağlayacağı düşünülmektedir.

CLT malzemelerin teknolojik özellikleri, mümkün olduğunca maliyet ve süre etkin testler yapılarak belirlenebilmektedir. Ancak CLT üretim parametrelerinin değişmesi durumunda elde edilebilecek direnç değerlerinin belirlenmesi çoklu parametreler göz önüne alındığında yeniden bir maliyet ve süre kaybına neden olabilecek proses oluşturmaktadır. Bu noktada yapay sinir ağları (YSA) kullanımı ile mevcut testlerden elde edilen veriler modellenerek karşılaşılabilecek farklı üretim parametrelerinde ahşap malzemenin göstereceği direnç özelliklerinin tahmin edilmesi mümkün olmaktadır. Yapılan literatür araştırmalarında, yapısal ahşap malzemelere yönelik optimizasyon çalışmalarında YSA modellemelerinin başarı ile kullanıldığı belirlenmiştir (Demir ve ark., 2023; Öztürk ve ark., 2022; Demirkır ve ark., 2013). Bu çalışmada, ağaç türü ve kereste direnç sınıfı gibi üretim parametrelerinin CLT perde duvarların yanal yük altındaki rijitliği üzerindeki etkileri YSA ile belirlenmesi amaçlanmıştır. Ayrıca, YSA modellerini yardımıyla yapılan optimizasyon çalışmalarıyla da CLT paneller için en yüksek rijitlik değerini verecek orta ve dış tabakalarda kullanılan kereste direnç sınıflarının kombinasyonları ortaya konulması amaçlanmıştır.

## 2. Materyal ve Yöntem

### 2.1. Ağaç malzeme


Bu çalışmada, CLT üretiminde en fazla tercih edilen türlerden biri olan ladin (*Picea orientalis L.*), iğne yapraklı ağaç türü olarak seçilmiştir. Ayrıca, hızlı büyüyen türlerden olan kızılgağaç (*Alnus glutinosa subsp. Barbata (C.A. Mey.) Yalt.*), yapraklı ağaç türü olarak seçilmiştir. Farklı bölgelerden, sırasıyla TS 1265 (2012) ve TS EN 14081-1 (2019) standartlarında belirtilen görünüş özelliklerine göre 3 farklı kalite sınıfında ladin ve 2 farklı kalite sınıftan kızılgağaç keresteler temin edilmiştir. Kerestelerin dört tarafı planya makinasında işlenmiş ve kurutulmuş olarak temin edilmiştir. Keresteler, CLT üretimi için en uygun aralık olan  $12\pm 3$  rutubet derecesine sahip olmasına dikkat edilmiştir. Keresteler, CLT üretiminden önce 120x10x1.8 cm ve 240x10x1.8 cm ölçülerinde boyutlandırılmıştır.

### 2.2. Kerestelerin TS EN 338 standardına göre direnç sınıflarının belirlenmesi

Çalışma kapsamında, görünüş özelliklerine göre temin edilen kerestelerin, CLT üretimi öncesi hasarsız yöntemler ile testleri yapılarak TS EN 338 (2016) Standardına göre direnç sınıfları tayin edilmiştir. Kerestelerin direnç sınıflarının belirlenmesinde, CBS-CBT firması tarafından geliştirilmiş Sylvatest 4 akustik test cihazı kullanılmıştır (Şekil 1). Cihaz iki dönüştürücü (verici ve alıcı) arasındaki ahşap malzemede ultrasonik dalgaların uçuş süresini ölçerek eğilme direnci ve elastikiyet modülünü yazılım sayesinde direkt olarak hesaplamakta ve ilgili standarda göre direnç sınıfını göstermektedir. Bununla birlikte, elde edilen verileri grafiğe dönüştürmektedir (Şekil 2).



Şekil 1. Akustik test cihazı ile kerestelerin direnç sınıflarının belirlenmesi



Şekil 2. Akustik test cihazı yazılım verileri

Yapılan hasarsız testler sonucunda, ladin ve kızılâğaç keresteler TS EN 338 (2016) standardına göre C ve D olarak direnç sınıflarına ayrılmıştır. Elde edilen direnç sınıfı gruplarından ladin için C<sub>16</sub>, C<sub>22</sub>, C<sub>30</sub>, kızılâğaç için ise D<sub>18</sub>, D<sub>30</sub>, D<sub>40</sub> grubu keresteleri, çalışma kapsamında CLT üretiminde kullanılmak üzere seçilmiştir. Özellikle iğne yapraklı ağaç türü olan ladin için bu değerler seçilirken, TS EN 338 (2016) standardında C<sub>45</sub> ve C<sub>50</sub> sınıfında kerestenin bulunamayabileceği ifadesi ve yapılan literatür araştırması neticesinde C<sub>30</sub> grubunun üzerindeki direnç sınıfına ait kerestelerin CLT üretiminde kullanımına yönelik çalışmaya rastlanılmaması dikkate alınmıştır. Bu nedenle gruplar seçilirken C<sub>30</sub> standardına kadar ilgili standartta verilen sınıflandırma sıralaması açısından eşit aralıklı olarak direnç sınıfı seçimi yapılmıştır.

### 2.3. CLT panellerin üretilmesi

Ağaç türü ve TS EN 338 (2016) standardındaki direnç sınıflarına göre oluşturulan tabaka kombinasyon gruplarına ait kerestelerin yüzeylerine 160 g/m<sup>2</sup> poliüretan tutkal çözeltisi sürülmüştür. Üretilen CLT panellerde taslak hazırlama işlemi tabakalar birbirine dik olacak şekilde yerleştirilmesiyle yapılmıştır. Taslak oluşturma esnasında bir tabakada kullanılacak kerestelerin, enine kesitlerindeki yıllık halka yönü dikkate alınarak üretilecek malzemenin en az çalışmasını sağlayacak şekilde kızılâğaç, ladin ve hibrit (kızılâğaç ve ladin kombinasyonu) taslaklar oluşturulmuştur. 3 tabakalı olacak şekilde hazırlanan taslak


levhalar, presleme işlemine tabi tutulmuştur. Taslakların preslenmesi; endüstriyel koşullarda dikey ve yan presleme yapabilen hidrolik bir preste gerçekleştirilmiştir. Presleme işleminde soğuk pres uygulanmış ve pres basıncı ladin ve hibrit için  $0.8 \text{ N/mm}^2$ , kızılğaç için  $1.2 \text{ N/mm}^2$ 'ye ayarlanmıştır. Kereste parçaları arasındaki boşluğu en aza indirebilmek için dikey presleme ile  $0.276\text{-}0.550 \text{ N/mm}^2$  arasında bir yan presleme yapılmıştır. Ağaç türü ve TS EN 338 (2016) standardına göre oluşturulan kombinasyonlar neticesinde üretimi yapılan 30 test grubu Tablo 1'de verilmiştir.

**Tablo 1.** Ağaç türü ve TS EN 338 standardına göre oluşturulan test grupları.

Grup No	Ağaç Türü	Tabaka Kombinasyonu
1	Ladin	C <sub>16</sub> - C <sub>16</sub> - C <sub>16</sub>
2		C <sub>22</sub> - C <sub>22</sub> - C <sub>22</sub>
3		C <sub>30</sub> - C <sub>30</sub> - C <sub>30</sub>
4		C <sub>16</sub> - C <sub>22</sub> - C <sub>16</sub>
5		C <sub>22</sub> - C <sub>16</sub> - C <sub>22</sub>
6		C <sub>16</sub> - C <sub>30</sub> - C <sub>16</sub>
7		C <sub>30</sub> - C <sub>16</sub> - C <sub>30</sub>
8		C <sub>22</sub> - C <sub>30</sub> - C <sub>22</sub>
9		C <sub>30</sub> - C <sub>22</sub> - C <sub>30</sub>
10	Kızılğaç	D <sub>18</sub> - D <sub>18</sub> - D <sub>18</sub>
11		D <sub>30</sub> - D <sub>30</sub> - D <sub>30</sub>
12		D <sub>40</sub> - D <sub>40</sub> - D <sub>40</sub>
13		D <sub>18</sub> - D <sub>30</sub> - D <sub>18</sub>
14		D <sub>30</sub> - D <sub>18</sub> - D <sub>30</sub>
15		D <sub>18</sub> - D <sub>40</sub> - D <sub>18</sub>
16		D <sub>40</sub> - D <sub>18</sub> - D <sub>40</sub>
17		D <sub>30</sub> - D <sub>40</sub> - D <sub>30</sub>
18		D <sub>40</sub> - D <sub>30</sub> - D <sub>40</sub>
19	Hibrit	C <sub>16</sub> - D <sub>18</sub> - C <sub>16</sub>
20		C <sub>22</sub> - D <sub>30</sub> - C <sub>22</sub>
21		C <sub>30</sub> - D <sub>40</sub> - C <sub>30</sub>
22		D <sub>18</sub> - C <sub>16</sub> - D <sub>18</sub>
23		D <sub>30</sub> - C <sub>22</sub> - D <sub>30</sub>
24		D <sub>40</sub> - C <sub>30</sub> - D <sub>40</sub>
25		C <sub>16</sub> - D <sub>30</sub> - C <sub>16</sub>
26		C <sub>16</sub> - D <sub>40</sub> - C <sub>16</sub>
27		C <sub>22</sub> - D <sub>40</sub> - C <sub>22</sub>
28		D <sub>18</sub> - C <sub>22</sub> - D <sub>18</sub>
29		D <sub>18</sub> - C <sub>30</sub> - D <sub>18</sub>
30		D <sub>30</sub> - C <sub>30</sub> - D <sub>30</sub>


#### 2.4. Perde duvar analizi

CLT panellerin yanal yük altındaki yapısal performansını belirlemek için perde duvar analizleri gerçekleştirilmiştir. Perde duvar analizi testi ASTM E 72 (2014) standardına göre doğrusal yük altında uygulanmıştır. Kurulan deney düzeneği Şekil 3'te verilmiştir. 20 Ton Kapasiteli Servo Hidro Yükleme Sistemi perde duvar analiz testinde kullanılmıştır.



Şekil 3. Deneysel test düzeneği.

ASTM E 72 (2014) standardında belirtilen yük uygulama prosedürüne göre gerçekleştirilen testlerin ardından, her bir deney grubu için maksimum yük taşıma kapasitesi ve maksimum yükteki yer değiştirme miktarları elde edilmiştir. Analiz sonuçlarına dayanarak, her bir grup için elde edilen grafikler incelenmiş ve her bir grup için temsil edici olan yük-yer değiştirme eğrileri belirlenmiştir. Bu grafikler, ilgili örnek grubun maksimum yükü ve bu yükteki yer değiştirmeyi ifade etmektedir. (Şekil 4).



Şekil 4. Test sonucu elde edilen grafik.

Bu grafiklerin yardımıyla, maksimum yükün %10-40'ı arasında bulunan eğrinin eğimi hesaplanarak CLT panellere ait rijitlik değerleri belirlenmiştir.

## 2.5. Yapay Sinir Ağları (YSA) Modellemesi

YSA Modellemelerinde, TS EN 338 (2016) standardına göre 3'er direnç sınıfından elde edilen deney verileri kullanılarak, standarttaki diğer direnç sınıfları için rijitlik değerlerinin ortaya konulması amaçlanmıştır. Böylelikle, çalışmada kullanılmayan farklı direnç sınıfına sahip kerestelerle üretilecek CLT panellerin yapısal direnç özellikleri, deneylere gerek duymadan maliyet ve zaman kaybı olmadan yüksek güvenilirlikte tahmin

edilmiş olacaktır. Ayrıca, analizlerden elde edilen tahmin modelleri kullanılarak ladin, kızılâğaç ve hibrit CLT paneller için optimum kereste direnç sınıfı kombinasyonları hem dış tabakalar hem de orta tabakalar için ayrı ayrı belirlenmiştir.

Bu araştırmada, temel işlem değişkenleri olarak ağaç türleri ile dış ve orta tabakada kullanılan kerestelerin TS EN 338'e (2016) göre belirlenen direnç sınıfı değerleri kabul edilmiştir. Çıktı değişkeni olarak ise CLT panellerin yapısal özelliklerinden elde edilen rijitlik değerleri kullanılmıştır. MATLAB programı, yapay sinir ağlarının oluşturulması, eğitilmesi, test edilmesi ve optimal parametrelerin belirlenmesi süreçlerinde kullanılmıştır. Veriler, hasarlı deneylerden elde edilmiştir. Ağaç türlerinin, dış ve orta tabakada kullanılan kerestelerin TS EN 338'e (2016) göre belirlenen direnç sınıflarının rijitlik değerleri üzerindeki etkilerini incelemek amacıyla, deneysel veriler eğitim ve test verisi olarak kategorize edilmiştir. Eğitim sürecinde 20 örnek seçilmiş ve geriye kalan 10 örnek, yapay sinir ağının genelleme yeteneğini doğrulamak amacıyla kullanılmıştır. Yapılan testlerde, tahmini değerler gerçek değerlerle karşılaştırılmış ve performans fonksiyonları olarak bilinen ve yaygın olarak kullanılan ortalama karesel hata karekökü (RMSE) ve ortalama mutlak yüzde hata (MAPE) hesaplamalarıyla değerlendirilerek en etkili tahmin modelleri belirlenmiştir. RMSE ve MAPE hesaplamalarına ait denklemler aşağıda verilmiştir.


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

$$MAPE = \frac{1}{N} \left( \sum_{i=1}^N \left[ \left| \frac{t_i - td_i}{t_i} \right| \right] \right) \times 100 \quad (2)$$

Burada  $t_i$ , gerçek değeri;  $td_i$ , model tahmin değerini;  $N$  ise terim sayısını ifade etmektedir.

Analizlerde yüksek performans özellikleriyle en iyi tahmin modeli olarak belirlenen ağ mimarisi Şekil 5'te verilmiştir. Şekilden de görüldüğü üzere, en doğru ve kesin sonuçları tahmin eden modelin ağ mimarisi 1 girdi katmanı, 2 gizli katman ve 1 çıktı katmanından oluşmuştur. Her gizli katmanda 2'şer nöron kullanılmıştır.





Şekil 5. Rijitlik tahmin modeli olarak seçilen YSA mimarisi

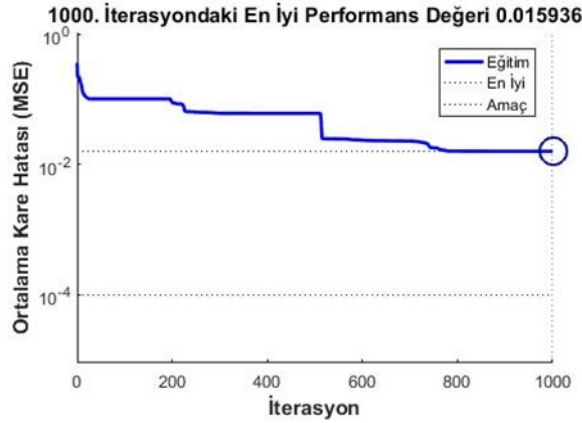
Problemlerin çözümünde ileri beslemeli ve geri yayımlı (Feed Forward and Back Propagation) çok katmanlı (multilayer) YSA tercih edilmiştir. Bu çalışmada, aktivasyon (activation) (transfer) fonksiyonu olarak hiperbolik tanjant sigmoid fonksiyonu (hyperbolic tangent sigmoid function) (tansig) ile doğrusal transfer fonksiyonu (linear transfer function) (purelin), öğrenme kuralı olarak momentumlu gradyan azaltım geri yayılım algoritması (gradient descent with momentum backpropagation algorithm) (traingdm), eğitim algoritması olarak ta levenberg marquardt algoritması (trainlm) seçilmiş, performans fonksiyonu olarak ta 3 numaralı eşitlikle hesaplanan ortalama karesel hata (mean square error) (MSE) kullanılmıştır.

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

### 3. Bulgular ve Tartışma

#### 3.1. Yapay Sinir Ağları (YSA) Modellemesi

Çalışma kapsamında CLT panellere uygulanan yanal yüklemelerden elde edilen rijitlik değerleri kullanılarak yüksek güvenilirlikte ve doğrulukta YSA tahmin modeli elde edilmiştir. Analizler sırasında sayısız model eğitilmiş ve bu modellerin testleri yapılmıştır. En iyi tahmini veren modellerin belirlenmesinde MSE değerleri kullanılmıştır. Bu değerlerin iterasyona göre değişimleri çıktı değişkenine göre Şekil 6'da verilmiştir.



**Şekil 6.** Belirlenen tahmin modelinin iterasyona bağlı olarak MSE değişimleri.

Şekilden de görüleceği üzere, rijitlik tahmin modelinde en iyi performans, 1000. İterasyonda 0.015936 olarak belirlenmiştir. Yüksek performans değerine sahip tahmin modelinin kullanılan eğitim ve test veri setlerinin deneysel bulguları, tahmin bulguları ile hata oranları Tablo 2’de gösterilmiştir. Ayrıca tahmin modeline ait MAPE ve RMSE değerleri Tablo 2’de gösterilmiştir.

**Tablo 2.** Rijitlik değerlerine ait eğitim ve test verileri.

EĞİTİM VERİLERİ				
Ağaç Türü	Tabaka Kombinasyonu	Rijitlik (kN/mm)		
		Gerçek	Tahmin	Hata (%)
Ladin	C22-C22-C22	1.79	1.76	1.46
Ladin	C30-C30-C30	1.40	1.40	-0.10
Ladin	C22-C16-C22	1.24	1.24	-0.09
Ladin	C16-C30-C16	1.34	1.36	-1.82
Ladin	C30-C16-C30	2.08	2.08	0.01
Ladin	C30-C22-C30	1.23	1.23	-0.07
Kızılağaç	D18-D18-D18	1.84	1.88	-2.13
Kızılağaç	D40-D40-D40	1.36	1.36	-0.11
Kızılağaç	D18-D30-D18	1.06	1.06	0.06
Kızılağaç	D30-D18-D30	1.77	1.77	0.00
Kızılağaç	D30-D40-D30	1.28	1.28	0.22
Kızılağaç	D40-D30-D40	1.84	1.84	-0.01
Hibrit	C16-D18-C16	1.73	1.89	-9.18
Hibrit	C22-D30-C22	1.83	1.89	-3.11
Hibrit	D18-C16-D18	2.05	1.89	7.86
Hibrit	D40-C30-D40	1.39	1.39	0.00
Hibrit	C16-D30-C16	2.04	1.89	7.47
Hibrit	C22-D40-C22	1.92	1.92	0.00
Hibrit	D18-C22-D18	1.83	1.89	-3.21
Hibrit	D30-C30-D30	2.58	2.58	0.01
MAPE		1.85		
RMSE		0.06		
TEST VERİLERİ				
Ağaç Türü	Tabaka Kombinasyonu	Rijitlik (kN/mm)		
		Gerçek	Tahmin	Hata (%)
Ladin	C16-C16-C16	1.32	1.32	0.29

Ladin	C <sub>16</sub> -C <sub>22</sub> -C <sub>16</sub>	1.71	1.56	8.65
Ladin	C <sub>22</sub> -C <sub>30</sub> -C <sub>22</sub>	1.54	1.55	-0.81
Kızılağaç	D <sub>30</sub> -D <sub>30</sub> -D <sub>30</sub>	1.44	1.43	0.65
Kızılağaç	D <sub>18</sub> -D <sub>40</sub> -D <sub>18</sub>	1.48	1.56	-5.68
Kızılağaç	D <sub>40</sub> -D <sub>18</sub> -D <sub>40</sub>	1.42	1.39	2.09
Hibrit	C <sub>30</sub> -D <sub>40</sub> -C <sub>30</sub>	1.27	1.39	-9.52
Hibrit	C <sub>16</sub> -D <sub>40</sub> -C <sub>16</sub>	1.77	1.82	-3.07
Hibrit	D <sub>30</sub> -C <sub>22</sub> -D <sub>30</sub>	2.02	1.89	6.48
Hibrit	D <sub>18</sub> -C <sub>30</sub> -D <sub>18</sub>	1.55	1.54	0.72
<b>MAPE</b>		<b>3.80</b>		
<b>RMSE</b>		<b>0.08</b>		


Tablo 2 incelendiğinde, CLT panellerdeki deneysel veriler ile tahmin verileri arasında yakın bir ilişki olduğu ve hata oranlarının düşük olduğu belirlenmiştir. Rijitlik değerleri verilerinde en yüksek hata oranları, ladin CLT paneller için %8.65, kızılğaç CLT paneller için %5.68 ve hibrit CLT paneller için %9.52 olarak hesaplanmıştır. Tabloda verilen tahmin modeline ait MAPE ve RMSE değerleri ayrıca bu uyumun ne kadar yüksek olduğunu kanıtlamıştır. Özellikle MAPE, model performansını değerlendirmek için kullanılan önemli bir kriterdir ve birçok araştırmacı, model performansını değerlendirmek amacıyla MAPE'yi tercih etmiştir (Antanasijević ve ark., 2013; Yadav ve Nath, 2017). Literatürde, MAPE değerinin %10'un altında olması durumunda model performansının yüksek olduğu vurgulanmıştır (Yadav ve Nath, 2017). Bu çalışmada, rijitlik değerleri için elde edilen MAPE değerleri eğitim verileri için %1.85, test verileri için ise %3.80 olarak belirlenmiştir. Bu hata seviyeleri, YSA tahmin modelinin etkili bir şekilde tatmin edici sonuçlar sağladığını ve yeterli doğruluk ve güvenilirliğe sahip olduğunu göstermektedir.

En iyi YSA modelinin belirlenmesinde, MAPE değerlerinin yanı sıra RMSE değerleri de dikkate alınmaktadır, ki bu durum daha geniş bir perspektif sağlamaktadır (Küçükönder ve ark., 2016). Düşük RMSE değerleri, iyi bir model performansını yansıtan önemli parametrelerden biridir (Taşpınar ve Bozkurt, 2014). Rijitlik değerlerine ait eğitim ve test verileri için RMSE değerleri sırasıyla 0.06 ve 0.08 olarak belirlenmiştir. Bu hata seviyeleri, rijitlik değerlerine ait tahmin modeli için tatmin edici olduğunu kanıtlamıştır. Rijitlik değerlerine ait tahmin modelinin bağlantı ağırlıkları ve eşik değerleri sırasıyla Tablo 3'te verilmiştir.


**Tablo 3.** Rijitlik değerlerinin tahmin modelinin bağlantı ağırlıkları ve eşikleri..

Gizli Katman 1	Nöron1	Nöron2	Eşik1
	-5.69	-5.19	0.70
14.05	0.61	-3.07	
5.83	2.47	-	
Gizli Katman 2	Nöron1	Nöron2	Eşik2
	2.37	-3.10	-1.40
-3.25	4.18	1.56	
Çıktı Katmanı	Nöron1	Eşik3	
	-19.08	-0.46	
-18.96	-		

Deneysel çalışmalardan elde edilen veriler ile YSA modellerinden elde edilen tahmin verilerin karşılaştırmaları çıktı değişkenlerine göre Şekil 7’de verilmiştir.

**Şekil 7.** Gerçek veriler ile tahmin verilerinin karşılaştırılması.

Şekil 7 incelendiğinde, deneysel çalışmalarla elde edilmiş verilerin modellerden elde edilen tahmin verileriyle önemli seviyede uyum sağladığı tespit edilmiştir. Ayrıca, deneysel çalışmalardan elde edilen verilerle analiz sonuçlarına dayalı tahmin verileri arasındaki ilişkiyi değerlendirmek amacıyla yapılan regresyon analizleri, tahmin modellerinin geçerliliği ve doğruluğunu belirlemek için kullanılan kritik parametrelerden biridir. Korelasyon katsayıları, 1'e yaklaştıkça modellerin tahmin doğruluğunun arttığı gözlemlenmektedir (Özşahin, 2012). Analizler sonucunda, rijitlik tahmin modeli için hesaplanan korelasyon katsayıları (R) ve regresyon grafikleri Şekil 8’de verilmiştir.




**Şekil 8.** Rijitlik tahmin modeline ait regresyon grafikleri.

Şekil incelendiğinde, rijitlik tahmin modelinin R değeri, eğitim safhasında 0.98454 iken test safhasında 0.93405 olarak hesaplanmıştır. R değerleri dikkate alındığında, korelasyon katsayıları 1'e yakın olan bu modelin, deneysel veriler ile tahmin verilerinin arasındaki uyumun çok iyi olduğu istatistiksel olarak da kanıtlanmıştır. İstatistiksel olarak kanıtlanan tahmin modelinin güvenilirliği ve tahmin kabiliyetlerinin kesinliği artmıştır.

### 3.2. Optimizasyon

YSA tahmin modelleri, deneysel çalışmalarda kullanılmayan girdi değişkenlerine ait ara verilerin çıktılarını tahmin etme konusunda yüksek doğruluk oranlarına ulaşabilmektedir (Varol vd. 2018). Girdi değişkeni olarak belirlenen TS EN 338'e (2016) göre kereste direnç sınıfı değerlerinin ( $C_{16}$ ,  $C_{22}$ ,  $C_{30}$  ve  $D_{18}$ ,  $D_{30}$ ,  $D_{40}$ ) deneylerde kullanılmayan ara değerlerine ( $C_{14}$ ,  $C_{18}$ ,  $C_{20}$ ,  $C_{27}$  ve  $D_{24}$ ,  $D_{35}$ ) karşılık gelen rijitlik değerleri ağaç türüne göre tahmin edilmiş ve bu değerlerin CLT panellerin dış ve orta tabakalarında kullanılan kereste direnç sınıfına göre değişimleri Şekil 9'da verilmiştir.



Şekil 9. Kereste direnç sınıfına göre CLT paneller için rijitlik değerlerinin değişimi.

CLT panellerden üretilen perde duvarların rijitlik değişimleri incelendiğinde, ladinden üretilen duvarlarda dış tabakalarda kullanılan kerestelerin direnç sınıflarının C<sub>27</sub> ve C<sub>30</sub>; orta tabakada kullanılan kerestelerin direnç sınıflarının ise C<sub>18</sub> ve C<sub>20</sub> olması durumunda duvarların rijitliklerinin en yüksek değerlere ulaşacağı tahmin edilmiştir. Kızılağaçtan üretilen panellerde dış tabakalarda kullanılan kerestelerin direnç sınıflarının D<sub>30</sub> ve D<sub>35</sub>; orta tabakada kullanılan kerestelerin direnç sınıflarının ise D<sub>35</sub> olması durumunda duvarların rijitliklerinin en yüksek değerler vereceği tahmin edilmiştir. Hibrit CLT panellerde en yüksek liflere paralel makaslama direnci değerleri, dış tabakasında ladin, orta tabasında kızılağaç olan gruplarda sırasıyla C<sub>30</sub>-D<sub>24</sub> direnç sınıfları kombinasyonunda bulunmuştur. Dış tabakası kızılağaç orta tabakası ladin olan hibrit panellerde ise en yüksek değerler, D<sub>30</sub> ve D<sub>35</sub>'in dış tabakalarda; C<sub>20</sub> ve C<sub>30</sub>'un orta tabakalarda kullanıldığı kombinasyonlardan elde edilmiştir. Analizler sonucunda elde edilen modellerin tahmin değerleri incelenerek ağaç türüne göre optimum kereste direnci sınıfları ve tabaka kombinasyonları tespit

edilmiştir. Belirlenen optimum tabaka kombinasyonları ile bu kombinasyonlara karşılık gelen en yüksek rijitlik değerleri Tablo 4’te verilmiştir.

**Tablo 4.** CLT paneller için optimum kereste direnç sınıfı ve tabaka kombinasyonları.

Ağaç Türü	Tabaka Kombinasyonu (Dış-Orta-Dış)	Tahmin Edilen En Yüksek Rijitlik Değeri (kN/mm)
Ladin	C <sub>30</sub> -C <sub>18</sub> -C <sub>30</sub>	2.60
Kızılağaç	D <sub>30</sub> -D <sub>35</sub> -D <sub>30</sub>	2.21
Hibrit	C <sub>30</sub> -D <sub>24</sub> -C <sub>30</sub>	2.33
Hibrit	D <sub>30</sub> -C <sub>30</sub> -D <sub>30</sub>	2.38

Tablodaki rijitlik değerleri incelendiğinde, ladin kerestelerden üretilen CLT perde duvarların kızılağaç ve hibrit CLT perde duvarlara göre çok daha yüksek değerler verdiği görülmüştür. Dış tabakalarında kızılağaç kerestelerin orta tabakalarında ladin kerestelerin kullanıldığı hibrit panellerden üretilen CLT perde duvarın yanal yük altındaki rijitlik performansı diğer hibrit grubuna göre daha iyi olduğu belirlenmiştir. CLT paneller üzerine YSA ile modelleme ve optimizasyon çalışmalarının sayısı literatürde oldukça sınırlı kalmıştır. Bobadilha ve ark. (2021) YSA modellemelerini CLT panellerin açık havada maruz kaldığı renk değişimlerinde kullanırken; Dong ve ark. (2017) CLT maliyetlerini ve enerji tüketimlerini YSA ile modellemiştir. Bu çalışmaların dışında özellikle CLT panellerin rijitlikleri üzerine herhangi bir çalışmaya rastlanılmamıştır. Bundan dolayı bu çalışma, literatüre yeni bir bakış açısı ve kullanılabilir bir veri kaynağı sunmuştur.

Literatürde iğne yapraklı ağaçlardan üretilen CLT panellerde çoğunlukla C24 direnç sınıfına sahip kerestelerin kullanıldığı tespit edilmiştir (Wiruszewski ve Mazela, 2017). Bu çalışmada YSA sonucunda elde edilen modelden, dış ve orta tabakalarında C24 direnç sınıfındaki kerestelerin kullanıldığında CLT panelin rijitlik değeri 1,56 kN/mm olarak tahmin edilmiştir. Tablo 4’te tabaka kombinasyonlarına göre verilen optimum sonuçlarda ladin için 2,60 kN/mm hesaplanmıştır. CLT üretiminde sıkça tercih edilen C24 direnç sınıfı kerestelerden ziyade, çalışmada belirlenen C30-C18-C30 grubunun oldukça yüksek yapısal dayanım sağladığı tespit edilmiştir. Orta tabakada daha düşük direnç sınıfı kerestelerin kullanılmasının rijitlik değerlerini etkilemediği görülmüş, bu durumun da CLT üretim maliyetlerine olumlu bir etkiye neden olacağı düşünülmüştür. Her ne kadar ülkemizde görsel sınıflandırmaya göre bir kereste fiyatlandırma söz konusu olmasına rağmen, özellikle dünyada yapısal kerestelerin direnç sınıfları düştükçe fiyat daha da düştüğü görülmüştür. Ülkemizde ahşap yapılar ve yapısal ahşap malzemeler üzerine gelişmeler hızlanmakta olup ilerleyen zamanlarda kereste fiyatlandırmanın da direnç sınıfına göre yapılacağı tahmin

edilmektedir. Bundan dolayı, çalışmanın sonuçlarının bu sektörde hem dayanım hem de maliyet açısından son derece önemli olacağı düşünülmektedir.

#### **4. Sonuçlar**

Bu çalışmada, CLT Panellerin kullanıldığı perde duvarların yanal yük altındaki rijitlikleri üzerine ağaç türü ve kereste direnç sınıfı gibi faktörlerin etkisi YSA aracılığıyla tahmin edilerek belirlenmiştir. Ayrıca, hızlı büyüyen yerli ağaç türlerimizden kızılğaç kerestelerinin CLT panel üretiminde kullanılması durumunda göstereceği yapısal performans da ortaya konulmuştur. Deneysel verilerden hesaplanan rijitlik değerleri YSA modellemelerinde kullanılmış ve en iyi tahmin performansına sahip model belirlenmiştir. Rijitlik tahmin modelinde en iyi performans, 1000. iterasyonda 0.015936 olarak belirlenmiştir. R değeri, eğitim safhasında 0.98454 iken test safhasında 0.93405 olarak hesaplanmıştır. MAPE değeri, eğitim verileri için %1.85 ve test verileri için %3.80 olarak tespit edilirken; RMSE değerleri sırasıyla 0.06 ve 0.08 olarak belirlenmiştir. Optimum kereste direnç sınıfları ve tabaka kombinasyonları, rijitlik için ladin CLT perde duvarlarda C<sub>30</sub>-C<sub>18</sub>-C<sub>30</sub>, kızılğaç CLT perde duvarlarda D<sub>30</sub>-D<sub>35</sub>-D<sub>30</sub>, hibrit perde duvarlarda C<sub>30</sub>-D<sub>24</sub>-C<sub>30</sub> ve D<sub>30</sub>-C<sub>30</sub>-D<sub>30</sub> olarak belirlenmiştir.

#### **Teşekkür**

Yazarlar 2200012 nolu proje için sağladığı finansal destek için Türk Bilimsel ve Teknik Araştırma Kurumu'na (TÜBİTAK) teşekkürü bir borç bilir.



## Kaynaklar

- ASTM American Society for Testing and Materials (ASTM) E 72, (2014). Standard Test Methods of Conducting Strength Tests of Panels for Building Construction. West Conshohocken, A, United States.
- Antanasijević, D. Z., Pocajt, V. V., Povrenović, D. S., Ristić, M. Đ., & Perić-Grujić, A. A. (2013). PM10 emission forecasting using artificial neural networks and genetic algorithm input variable optimization. *Science of the Total Environment*, 443, 511-519.
- Bobadilha, G. S., Stokes, C. E., & Verly Lopes, D. J. (2021). Artificial neural networks modelling based on visual analysis of coated cross laminated timber (CLT) to predict color change during outdoor exposure. *Holzforschung*, 75(7), 646-654.
- Brandner, R. (2018). Cross laminated timber (CLT) in compression perpendicular to plane: Testing, properties, design and recommendations for harmonizing design provisions for structural timber products. *Engineering Structures*, 171, 944-960.
- Chen, C. X., Pierobon, F., & Ganguly, I. (2019). Life Cycle Assessment (LCA) of Cross-Laminated Timber (CLT) produced in Western Washington: The role of logistics and wood species mix. *Sustainability*, 11(5), 1278.
- Demir, A., Birinci, A. U., & Öztürk, H. (2021). Yerli Ağaç Türlerinden Üretilen Kontrplak Kaplı Perde Duvarların Yanal Yük Altındaki Performansı. *Bartın Orman Fakültesi Dergisi*, 23(2), 528-535.
- Demir, A., Demirkir, C., Özşahin, S., & Aydın, I. (2023). Artificial neural-network optimisation of nail size and spacings of plywood shear wall. *Wood Material Science & Engineering*, 18(1), 97-106.
- Demirkir, C., Özşahin, Ş., Aydın, I., & Colakoglu, G. (2013). Optimization of some panel manufacturing parameters for the best bonding strength of plywood. *International Journal of Adhesion and Adhesives*, 46, 14-20.
- Di Bella, A., & Mitrovic, M. (2020). Acoustic characteristics of cross-laminated timber systems. *Sustainability*, 12(14), 5612.
- Dong, Q., Xing, K., & Zhang, H. (2017). Artificial neural network for assessment of energy consumption and cost for cross laminated timber office building in severe cold regions. *Sustainability*, 10(1), 84.

- Dong, W., Wang, Z., Chen, G., Wang, Y., Huang, Q., & Gong, M. (2023). Bonding performance of cross-laminated timber-bamboo composites. *Journal of Building Engineering*, 63, 105526.
- Follesa, M., & Fragiacomio, M. (2018). Force-based seismic design of mixed CLT/Light-Frame buildings. *Engineering Structures*, 168, 628-642.
- Gagnon, S., C. Pirvu. 2012. Cross laminated timber (CLT) handbook. Vancouver, Canada: FPInnovations.
- Guo, H., Liu, Y., Chang, W. S., Shao, Y., & Sun, C. (2017). Energy saving and carbon reduction in the operation stage of cross laminated timber residential buildings in China. *Sustainability*, 9(2), 292.
- Hadigheh, S. A., & Dias-da-Costa, D. (2020). Shear strength of cross laminated timber-concrete connections reinforced with carbon fibre polymer composites. In *ACMSM25: Proceedings of the 25th Australasian Conference on Mechanics of Structures and Materials*, 179-185 Springer Singapore.
- Hassanieh, A., Valipour, H. R., & Bradford, M. A. (2017). Experimental and numerical investigation of short-term behaviour of CLT-steel composite beams. *Engineering Structures*, 144, 43-57.
- Hematabadi, H., Madhoushi, M., Khazaeyan, A., Ebrahimi, G., Hindman, D., & Loferski, J. (2020). Bending and shear properties of cross-laminated timber panels made of poplar (*Populus alba*). *Construction and Building Materials*, 265, 120326.
- Hindman, D. P., & Golden, M. V. (2020). Acoustical properties of southern pine cross-laminated timber panels. *Journal of Architectural Engineering*, 26 (2), 05020004.
- Kippel, M., Leyder, C., Frangi, A., Fontana, M. Lam & F. Ceccotti. (2014). Fire tests on loaded cross-laminated timber wall and floor elements. *Fire Safety Science*, 11, 626-639.
- Küçükönder, H., Boyacı, S., & Akyüz, A. (2016). A modeling study with an artificial neural network: developing estimation models for the tomato plant leaf area. *Turkish Journal of Agriculture and Forestry*, 40(2), 203-212.
- Lie, X., Subhani, M., Ashraf, M., Kafle, B., & Kremer, P. (2020). A current-state-of-the-art on design rules vs test resistance of Cross Laminated Timber members subjected to transverse loading. In *CIGOS 2019, Innovation for Sustainable Infrastructure: Proceedings of the 5th International Conference on Geotechnics, Civil Engineering Works and Structures*, 185-190, Springer Singapore.

- Luengo, E., Hermoso, E., Cabrero, J. C., & Arriaga, F. (2017). Bonding strength test method assessment for cross-laminated timber derived stressed-skin panels (CLT SSP). *Materials and structures*, *50*, 1-12.
- O'Dowd, B., Cunningham, L. S., & Nedwell, P. (2016). Briefing: Experimental and theoretical bending stiffness of cross-laminated timber panels. *Proceedings of the Institution of Civil Engineers-Construction Materials*, *169*(6), 277-281.
- Ozturk, H., Demir, A., & Demirkir, C. (2022). Optimization of pressing parameters for the best mechanical properties of wood veneer/polystyrene composite plywood using artificial neural network. *European Journal of Wood and Wood Products*, *80*(4), 907-922.
- Özşahin, Ş. (2012). The use of an artificial neural network for modeling the moisture absorption and thickness swelling of oriented strand board. *BioResources*, *7*(1), 1053-1067.
- Reynolds, T., Foster, R., Bregulla, J., Chang, W. S., Harris, R., & Ramage, M. (2017). Lateral-load resistance of cross-laminated timber shear walls. *Journal of Structural Engineering*, *143*(12), 06017006.
- Sandoli, A., D'Ambra, C., Ceraldi, C., Calderoni, B., & Prota, A. (2021). Sustainable cross-laminated timber structures in a seismic area: Overview and future trends. *Applied Sciences*, *11*(5), 2078.
- Soriano, F. M., Pericot, N. G., & Sierra, E. M. (2016). Comparative analysis of the reinforcement of a traditional wood floor in collective housing. In depth development with cross laminated timber and concrete. *Case studies in construction materials*, *4*, 125-145.
- Srivaro, S., Tomad, J., Shi, J., & Cai, J. (2020). Characterization of coconut (*Cocos nucifera*) trunk's properties and evaluation of its suitability to be used as raw material for cross laminated timber production. *Construction and Building Materials*, *254*, 119291.
- Tannert, T., Follesa, M., Fragiaco, M., Gonzalez, P., Isoda, H., Moroder, D., Xiong, H., & van de Lindt, J. (2018). Seismic design of cross-laminated timber buildings. *Wood and Fiber Science*, *50*, 3-26.
- Taşpınar, F., & Bozkurt, Z. (2014). Application of artificial neural networks and regression models in the prediction of daily maximum PM10 concentration in Düzce, Turkey. *Fresenius Environmental Bulletin*, *23*, 2450-2459.
- Turkish Standards Institution. (2012). TS 1265. Sawn timber (Coniferous) - For building construction. Ankara, TSE.

- Turkish Standards Institution. (2019). TS EN 14081. Timber structures - Strength graded structural timber with rectangular cross section - Part 1: General requirements, Ankara, TSE.
- Turkish Standards Institution. (2016). TS EN 338. Structural timber - Strength classes, Ankara, TSE.
- Tureson, J., Berg, S., & Ekevad, M. (2019). Impact of board width on in-plane shear stiffness of cross-laminated timber. *Engineering Structures*, 196, 109249.
- Varol, T., Canakci, A., & Ozsahin, S. (2018). 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.
- Wieruszewski, M., & Mazela, B. (2017). Cross Laminated Timber (CLT) as an Alternative Form of Construction Wood. *Wood Industry/Drvna Industrija*, 68(4), 359-367.
- Yadav, V., & Nath, S. (2017). Forecasting of PM 10 using autoregressive models and exponential smoothing technique. *Asian Journal of Water, Environment and Pollution*, 14(4), 109-113.