

Mekanik Özelliklere Göre Ağaç Türlerinin Yapay Sinir Ağları ile Tahmini

Predicting wood types in terms of mechanical properties using artificial neural networks

Muhammer İLKUÇAR^{1,a}, Ali İhsan KAYA^{2,b}, Ahmet ÇİFCİ^{*3,c}

¹Mehmet Akif Ersoy Üniversitesi, TBMYO, Bilgisayar Teknolojileri Bölümü, 15100, Burdur

²Mehmet Akif Ersoy Üniversitesi, TBMYO, Tasarım Bölümü, 15100, Burdur

³Mehmet Akif Ersoy Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik Mühendisliği Bölümü, 15030, Burdur

• Geliş tarihi / Received: 04.05.2017 • Düzeltilerek geliş tarihi / Received in revised form: 10.11.2017 • Kabul tarihi / Accepted: 10.11.2017

Öz

Mekanik özellikler malzemelerin dayanımını ve kullanım alanlarını belirleyen en önemli etkenlerdir. Bir ağaç malzemenin hangi malzeme grubunda olduğu ve hangi ağaç türü olduğu mekanik özelliklerine bakılarak bilinebilmektedir. Bu çalışmada ticareti yapılan kızılğaç (*Alnus glutinosa* subsp. *Barbata*), doğu kayını (*Fagus orientalis* Lipsky), karakavak (*Populus nigra*), ceviz (*Juglans regia*), meşe (*Quercus robur*), kestane (*Castanea sativa*), sedir (*Cedrus libani*) ve çam (*Pinus*) gibi önemli bazı ağaç türlerinin mekanik özellikleri yapay sinir ağları ile modellenmiştir. Bu çalışma, herhangi bir konstrüksiyon için ihtiyaç duyulan mekanik özellikleri karşılayacak ideal ağaç malzemenin tespitinde yardımcı olacaktır. Böylece bilimsel çalışmalarda ve ticarete ağaç türü ile ilgili sınıflandırmalar daha etkin bir şekilde yapılabilecektir.

Anahtar kelimeler: Ağaç türleri, Mekanik özellikler, Yapay sinir ağları

Abstract

The mechanical properties are the most important factors determining the strength and usage areas of materials. It can be known from the mechanical properties that a wood material of which material group is in and which wood species it is. In this study, the mechanical properties of some important wood species such as alder (*Alnus glutinosa* subsp. *Barbata*), oriental beech (*Fagus orientalis* Lipsky), black poplar (*Populus nigra*), walnut (*Juglans regia*), oak (*Quercus robur*), chestnut (*Castanea sativa*), cedar (*Cedrus libani*) and pine (*Pinus*) were modelled by using artificial neural networks. This study will assist in the determination of ideal wood material that meets the mechanical properties required for any construction. Thus, classifications related to wood species can be made more effectively in scientific studies and in trade.

Keywords: Wood species, Mechanical properties, Artificial neural networks

*c Ahmet ÇİFCİ; acifci@mehmetakif.edu.tr; Tel: (0248) 213 27 77; orcid.org/ 0000-0001-7679-9945

^a orcid.org/ 0000-0002-4935-8148

^b orcid.org/ 0000-0002-1860-9610

1. Giriş

Doğadan saf biçimde elde edilen ağaç geleneksel bir malzeme olarak; işlenme kolaylığı, direnç özellikleri ve maliyet avantajları nedeniyle yaygın bir kullanım olanağına sahiptir. Ağacın on binlerce farklı kullanım alanı olduğu tahmin edilmektedir. Ağaç malzemenin bu kadar çok kullanım alanının olmasının en büyük nedeni anatomik yapısı, fiziksel ve mekanik özellikleriyle kimyasal bileşiminden kaynaklanmaktadır (Bozkurt ve Erdin, 1997).

Uzun ve mükemmel bir tarihe sahip olan ağaç; insanın yaşamında ve kültürünün gelişme süreci içerisinde yüzlerce yıldır binaların çeşitli kısımlarında taşıyıcı elemanlar, dış cephe kaplamaları, döşeme ve çatı malzemeleri olarak, endüstriyel konstrüksiyonlarda köprüler, traversler, iskelelerde ve daha pek çok alanda kullanılmaktadır (Erdin, 2003). Bunun yanında heterojen yapıda olması ve bu nedenle anizotrop davranması en büyük kusuru olarak görülmektedir (Rowell, 1990).

Herhangi bir malzemenin kullanım yeri seçiminde öncelikle mekanik özelliklerin bilinmesi gereklidir. Ağaç malzemenin mekanik özellikleri; ağaç türüne, özgül ağırlığına, anatomik yapısına, kimyasal bileşimine, coğrafi orijinine, yetiştirme bölgesine, rutubet miktarına, fiziksel yapısına, kuvvetin şiddetine ve etki yönüne bağlıdır. Bu nedenle mekanik özelliklerinin tespit edilmesi diğer malzemelere göre değişken ve farklı olabilmektedir. (Bozkurt ve Erdin, 1997)

Ağaç malzemeyi doğal dayanıklılıklarına göre sınıflandırmak için çeşitli çalışmalar yapılmıştır. Panshin ve De Zeeuw (1980) çalışmalarında Amerikan ağaç türlerini dayanıklı veya çok dayanıklı, orta derece dayanıklı ve az dayanıklı veya dayanıksız olarak sınıflandırmıştır. Berkel (1972) tarafından yapılan çalışmada ağaç türleri dayanma süreleri bakımından çok dayanıklı, orta derece dayanıklı ve az dayanıklı ağaç türleri olarak sınıflandırmıştır. ASTM (American Society for Testing Materials) D2017-81 (1986) standardında denemeler sonucu elde edilen ağırlık kaybına göre yüksek dayanıklı, dayanıklı, orta derece dayanıklı, az dayanıklı veya dayanıksız şeklinde bir sınıflandırma yapılmıştır. Findlay (1985) ise yine dayanıklılık esasına göre ağaç türlerini çok dayanıklı, dayanıklı, orta derece dayanıklı, az dayanıklı ve dayanıksız olarak beş farklı sınıfa ayırmıştır.

Türkiye’de yetişen bazı ağaç türlerinin fiziko-mekanik değerler esas alınarak sahip oldukları mevcut ya da oluşturulmuş bulunan sınıf gruplarına dağılımı yapılmıştır. Sınıflandırmada genelde belirlenmiş olan fiziksel özelliklerden hava kurusu % 12-15 yoğunluk, daralma, mekanik özelliklerden eğilme direnci, eğilmede elastikiyet modülü, dinamik eğilme, basınç, çekme, yarıma, makaslama dirençleri ve sertlik değerleri dikkate alınmıştır (As vd., 2016).

Bir ağaç malzemenin mekanik özelliklerine bakarak onun hangi malzeme grubunda olduğu ve hangi ağaç türü olduğunun bilinmesi büyük bir ihtiyaçtır. Özellikle mühendislik tasarım hesaplamalarında teorik olarak, mekanik özelliği belirli güven sınırlarında yerine getirebilecek malzemenin belirlenmesi bu açıdan çok önemlidir. Bununla beraber laboratuvar çalışmalarında mekanik özelliklerinden ağaç türünün belirlenmesi gerekliliği kendini etkin bir şekilde göstermektedir. Mekanik özelliklerine göre ağaç türünün tespit edilmesi ile ilgili bir çalışmaya rastlanmamıştır. Yapılan çalışmada, yapay sinir ağları (YSA) sınıflandırma yöntemleri yardımıyla, mekanik özelliklerine göre ağaç malzemenin türünün tespiti işlemi yapılmıştır.

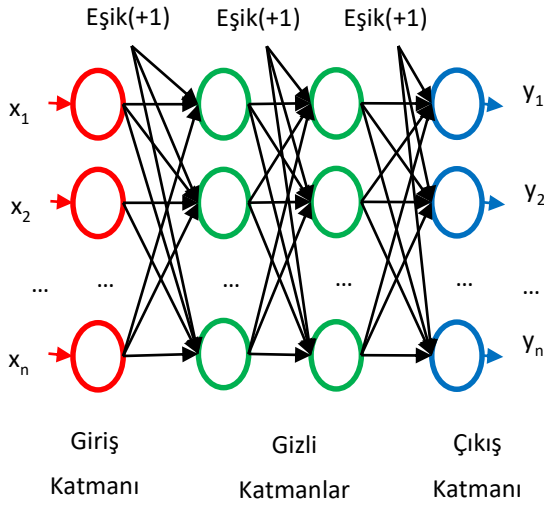
2. Yapay Sinir Ağları

Yapay sinir ağı, bilinen beyin yapısının çalışma prensibi taklit edilerek geliştirilmiş öğrenme/hafıza temelli bir makine öğrenme algoritmasıdır. YSA; esnek ve beklenmedik durumlara karşı mantıklı yaklaşımlarından dolayı matematiksel/istatistiksel yöntemlerle çözülebilen problemlerde dahi tercih edilmeye başlanmıştır. Günümüzde YSA; sosyal bilimler, tıp, mühendislik, gibi farklı disiplinlerde sınıflandırma, kümeleme, tahmin, otonom sürüş, doğal dil işleme, örüntü tanıma gibi farklı problemlerin çözümündeki marifeti ile haklı bir şöhrete sahiptir. Dolayısıyla, kullanım alanı, ağ yapısı ve öğrenme yöntemleri de geliştirilmektedir. Yapılan çalışmada ağacın mekanik özelliklerine göre ağacın türünün tahmini (sınıflandırması) işlemi çok katmanlı ileri beslemeli eğri yayımlı ve radyal temelli YSA kullanılarak gerçekleştirilmiştir.

2.1. Çok Katmanlı İleri Beslemeli Geri Yayımlı Yapay Sinir Ağı

YSA beyin öğrenme mantığından esinlenerek geliştirildiğinden, ağ öncelikli bir öğrenme sürecine tabi tutulmalıdır. Bunun için konu ile ilgili yeteri kadar gerçek veri kullanılarak ağı


öğretilmesi işlemi gerçekleştirilir. Öğrenme süreci statik olduğu gibi, yeni gelişen şartlara göre sürekli öğrenen yani dinamik de olabilir. Ağın öğrenmesi; daha önce hiç görmediği, bilmediği bir veri için dahi bir yorum getirebildiği, uygun çıkışın elde edilebileceği ağırlık değerlerinin hesaplanması sürecidir. Bir YSA öğretmek için farklı öğrenme metotları kullanılabilir (Anthony ve Bartlett, 2009). Literatürde farklı amaçlar için kullanılan farklı türde YSA modelleri mevcuttur. Şekil 1’de çok katmanlı ileri beslemeli-geri yayımlı (ÇKİBGY) yapay sinir ağı yapısı görülmektedir.



Şekil 1. Çok katmanlı YSA yapısı

Bu tür ağlarda bir giriş katmanı, bir çıkış katmanı ve en az bir gizli katman bulunur. Her katmandaki düğümler bir sonraki katmandaki düğümleri besleyecek şekilde birbirine bağlıdır. Giriş katmanındaki düğüm sayısı problemdeki öz nitelik sayısı ile ilişkilidir. Bir düğüm giriş bilgilerinin sıfır olması durumunda tüm hesaplamaların sıfır olmaması için, giriş katmanını hariç tüm katmanlara değeri (+1) olan bir eşik düğüm ilave edilmelidir. Çıkış düğüm sayısı olarak, istenen sonuçları karşılayabilecek kadar düğüm tasarımcı tarafından eklenebilir. Gizli katman sayısı ve her gizli katmandaki düğüm sayısı ile ilgili literatürde bir hesaplama mevcut değildir. Problemin özelliğine göre gizli katman sayısı ve bunların düğüm sayıları değiştirilerek farklı ağ yapıları düzenlenip en iyi sonucu veren YSA ağı, tasarımcı tarafından tespit edilmelidir. Giriş katmanını hariç diğer katmanlardaki düğümler (algılayıcı) kendisine gelen sinyalleri işleyerek bir çıktı üretir. Şekil 2’de YSA’ya ait bir düğüm yapısı verilmiştir.

Bir düğüm, kendisine gelen ağırlık değerleri ve verilerin çarpımlarının toplamını alıp bir net değeri üretir (denklem 1).




Şekil 2. YSA düğüm yapısı

Bu değer bir transfer fonksiyonu yardımıyla [0,1] veya [-1,1] aralığına çekilir. Çok katmanlı YSA geri yayılım hesaplamasında, türevi kolay alınmasından ve sürekli olmasından dolayı, işlem kolaylığı sağlayan sigmoid transfer fonksiyonu (şekil 3) tercih edilir (denklem 2). Literatürde sinüs, hiperbolik tanjant, lineer, step vb. farklı transfer fonksiyonları kullanılmaktadır.

$$net = w_0 + \sum_{k=1}^n (x_k w_k) \quad (1)$$

$$f(net) = \frac{1}{(1+e)^{-net}} \quad (2)$$



Şekil 3. Sigmoid fonksiyonu

YSA’lar öğrenme şekillerine göre genel olarak gözetimli (Supervised Learning), gözetimsiz (Unsupervised Learning) ve pekiştirmeli öğrenme (Reinforcement Learning) olarak gruplandırılabilir.

Çalışmada sınıflandırma işlemi yapıldığından gözetimli öğrenme YSA kullanılmıştır. Bu tür öğrenme işlemi; ağ ileri doğru beslendikten sonra hata değerleri (ağdan elde edilen çıkış ile beklenen çıkış değeri arasındaki fark $Hata = beklenen_değer - gerçekteşen_değer$), geriye doğru yansıtılarak, hatayı minimum edecek şekilde ağırlık değerlerinin değiştirilmesi

işlemidir. Başka bir deyişle ağıın öğrenmesi işlemi, hatayı minimum edecek ağırlık değerlerinin belirlenmesi sürecidir. Bu işlem için farklı optimizasyon teknikleri kullanılabilir. Ağıın hata değerini minimum yapmak için, dereceli azalma (Gradient Descent) yöntemi yaygın olarak kullanılmaktadır. Bu prensibe göre, çıkıştan girişe doğru zincirleme olarak düğümlerin çıkış fonksiyonu (transfer fonksiyonu) türevleri ağırlıklara yansıtılarak öğrenme işlemi gerçekleştirilir (denklem 3, 4, 5). Denklem 4'te δ_k değeri hata fonksiyonu türevidir. Geriye doğru yayılımında, bir düğümün toplam hata miktarı değeri ona gelen hata miktarlarının ağırlıkları ile çarpımı toplamı kadar olacaktır. Denklem 5'de hata miktarları dikkate alınarak ağırlık değişimi yapılmıştır.

$$\frac{\partial E}{\partial w_i} = \frac{\partial}{\partial y_i} \frac{\partial y_i}{\partial r_i} \frac{\partial r_i}{\partial w_i} \quad (3)$$

$$\delta_k = \sum_{k=0}^K \delta_y * w_{k,z} \quad (4)$$

$$W_{i,k} = W_{i,k} + \delta_y x_i f(\text{net}_k)' \quad (5)$$

Ağıın eğitimi ve test süreçlerinde bazı performans kriterlerine göre karar verilir. Performans kriterleri olarak ağıın hata değerlerine bakılır. Çalışmada hataların mutlak değerlerinin toplamının ortalaması (Mean Absolute Error-MAE) kullanılmıştır (Denklem-6).

$$MAE = \frac{1}{n} \sum_{i=0}^n |z_i - y_i| \quad (6)$$

Eğitilmiş YSA test verileri ile çalıştırılıp doğru ve yanlış tahmin oranlarına bakılarak performans (regresyon) ölçüsü olarak değerlendirilebilir.

Levenberg-Marquardt Algoritması


Levenberg-Marquardt algoritması (LMA) Gauss-Newton metodunu ve Steepest Descent metodunu birleştiren yinelemeli bir yöntemdir. Gauss-Newton algoritmasının hız avantajını, Steepest Descent metodunun da kararlılığını almıştır. Gauss-Newton algoritmasından daha güçlüdür, çünkü çoğu durumda hata yüzeyi kuadratik durumdan çok daha karmaşık olsa bile iyi bir şekilde yakınsayabilir. LMA, Gauss-Newton algoritmasına göre biraz daha yavaş olma eğiliminde olmasına rağmen (yakınsak durumda), Steepest Descent metodundan çok daha hızlı yakınsar (Yu ve Wilamowski, 2011). LMA şu şekilde verilebilir (Wen vd., 2011):

$$\Delta x = -(J^T(x)J(x) + \mu I)^{-1}J(x)e(x) \quad (7)$$

Burada x ağırlık vektörü, μ 0'dan büyük bir sabit ve e hata vektörüdür. P eğitim örnek sayısını ve N değişken sayısını belirtmek üzere J , $(P \times 1) \times N$ boyutunda Jacobiyen matrisi göstermektedir. I birim matristir. Denklem 7'deki μ önemli bir sabittir. μ değeri artarsa LMA, Steepest Descent metodu gibi, μ değeri 0'a doğru azaldığında Gauss-Newton metodu gibi davranır.

2.2. Radyal Temelli Fonksiyon Ağı

Radyal temelli fonksiyon ağı (Radial Basis Function Network-RBFN) ilk defa Broomhead ve Lowe (1988) tarafından bazı problemlerin çözümünde başarılı bir şekilde kullanılmıştır. RBFN bir giriş katmanı, bir gizli katman ve bir çıkış katmanından oluşan üç katmanlı bir yapıya sahiptir (Şekil 4).



Şekil 4. K adet gizli katmandan oluşmuş bir RBFN yapay sinir ağı yapısı (Arisariyawong ve Charoenseang, 2002).

Bu tür ağlarda tüm katmanlardaki düğümler birbirine bağlıdır. Giriş ve çıkış düğüm sayısı probleme göre belirlenir. Gizli katman düğüm sayısı ise problemin performansına direkt etki eder ve en çok eğitim verisi sayısı kadar olabilir. Gizli katman düğüm sayısı, problemin eğitimi sırasında belirli sayıdan başlatılıp dinamik olarak belirli miktarlarda artırılarak ağıın eğitimi gerçekleştirilir. Giriş katmanı ile gizli katman arasında ağırlık değerleri yoktur. Ağırlık değerleri sadece gizli katman ile çıkış katmanı arasındadır. Gizli katman transfer fonksiyonu olarak literatürde farklı dağılım fonksiyonları (kuadratik, invers kuadratik vb.) kullanılmasına rağmen en popüler olanı gaussian radyal fonksiyondur.

Gizli katman çıkış değerleri denklem 8'deki radyal fonksiyon tarafından üretilir. Denklemde, x : veri, c_i : giriş veri seti ortalaması (centrality-merkezi), σ_i : i . nitelik verilerinin standart sapması olarak verilmiştir.

$$R_i(x) = e^{\left(-\frac{\|x-c_i\|^2}{2\sigma_i^2}\right)} \quad (8)$$

RBFN çıkış değeri olarak gizli katman radyal fonksiyon çıkış değeri ($R_i(x)$) ile gizli katman-çıkış katmanı ağırlık değerlerinin (w_i) çarpımlarının toplamı şeklindedir (denklem 9). Nihai çıkış değeri çıkış düğüm değerlerinin aritmetik ortalaması alınarak bulunur (denklem 10).

$$y_i(x) = \sum_{i=1}^K w_i R_i(x) \quad (9)$$

$$y_i(x) = \frac{\sum_{i=1}^n w_i R_i(x)}{\sum_{i=1}^n R_i(x)} \quad (10)$$

RBFN'de parametre ve hesaplamalar az olduğundan hesaplama süresi de kısa olur. RBFN fazla kaynak (işlemci, ram) kullanmadığından kaynakların kısıtlı olduğu yerlerde tercih edilebilir. RBFN iyi bir genelleme olanağı, daha az düğüm kullanma ve kısa hesaplama olanağı sunar (Moradkhani vd., 2004).

3. Ağaç Türlerinin Mekanik Özelliklere Göre Sınıflandırılması

Ağaçların farklı ortamlarda farklı etkilere karşı gösterdiği tepkiler onun mekanik özelliklerini oluşturur. Mekanik özellikleri doğası gereği az da olsa birbirinden farklılıklar gösterir. Dolayısıyla mekanik özelliklerinden yola çıkılarak ağacın türü tahmin edilebilir. Çalışmada kızılâğaç (*Alnus glutinosa subsp. Barbata*), doğu kayını (*Fagus orientalis Lipsky*), karakavak (*Populus nigra*), ceviz (*Juglans regia*), meşe (*Quercus robur*), kestane (*Castanea sativa*), sedir (*Cedrus libani*) ve çam (*Pinus*) gibi sekiz farklı ağaç türüne ait yedi mekanik özellik değerine göre, farklı YSA sınıflandırma metodları (RBFN, ÇKİBGY) kullanılarak ağacın türü tahmin edilmiştir.

Her malzemenin aynı koşullar altında yoğunluğu, genleşmesi, burkulması ve büzülmesi farklıdır. Dolayısıyla basınca, itmeye, çekmeye ve burkmaya karşı dirençleri de farklılıklar göstermektedir. Bu gibi etkilere karşı verilen tepkiler malzemenin mekanik özelliklerini oluşturur. Mekanik özellikler, malzemelerin kullanım yerleri ile ilgili karar vermede büyük paya sahiptirler.

Tüm malzemeler gibi ağaç malzemeleri kullanırken, kullanım yeri ve koşulları için mekanik özellikleri dikkate alınmalıdır. Tablo 1'de ağaçların bazı mekanik özelliklerini belirleme fonksiyonları verilmiştir. Belirli koşullar altında ağacın yoğunluğu, basınca karşı direnci, eğilme direnci, çekme direnci, burkulma direnci gibi özellik ölçümleri yapılarak ağacın mekanik özellikleri elde edilmiştir.

Tablo 1. Ağaç malzemenin mekanik özellikleri


Mekanik Özellikler
Yoğunluk (Tam Kuru)
Liflere Paralel Basınç Direnci
Eğilme Direnci
Eğilme Elastikiyet Modülü
Dinamik Eğilme Direnci
Makaslama Direnci
Liflere Paralel Çekme Direnci

Çalışmada kullanılan mekanik özellik verileri çeşitli kaynaklardan elde edilmiştir (Güller ve Ay, 2001; Kantay vd., 2000; Bal vd., 2012; Kaymakçı vd., 2011; Korkut ve Bektaş, 2008; Düz kale vd., 2015; Malkoçoğlu, 1994; Güller vd., 2011; Ay ve Şahin, 2002; Dündar, 2002; Kahveci, 2012). Daha farklı ağaç malzemelerin mekanik özelliklerinin ölçülmesi işlemi için ayrı bir laboratuvar çalışması gerekmektedir. Çalışmada, sekiz farklı ağaç türüne ait yedi farklı mekanik öznelik olan 180 veri kullanılmıştır. Bunlardan bazılarının mekanik özellikleri Tablo 2' de verilmiştir. Verilerin tümü sayısal veri türünden olup eksik veri bulunmamaktadır. Çalışmada kullanılan verilerin tamamına İlkuçar (2017) kaynağından ulaşılabilir.

Tablo 2. Bazı ağaç türleri ve mekanik özellikleri

Ağaç Türü	Yoğunluk (Tam Kuru)	Liflere Paralel Basınç Direnci	Eğilme Direnci	Eğilme Elastikiyet Modülü	Dinamik Eğilme Direnci	Makaslama Direnci	Liflere Paralel Çekme Direnci
Kızılâğaç	0,454	42,3	79,05	8781,6	0,58	6,276	76,3065
Doğu Kayını	0,59	61,74	122	12050	1,09	9,9	131,6
Kara Kavak	0,375	35	50,25	8630	0,247	5	77
Ceviz	0,62	56	121	10259,7	0,95	9,6	101
Meşe	0,64	58,2	117,5	12161	0,6	10,2	90
Kestane	0,59	56,96	77	9050	0,59	9,7	137
Sedir	0,524	44,6	75,8	6668,2	0,38	5,2	101
Çam	0,56	55	109	10200	1,68	9,8	112

Şekil 5'te sistemin YSA ağ yapısı görülmektedir.



Şekil 5. Ağaçların teknik özelliklerine göre türünün YSA ile tahmini işleminin ağ yapısı

Problemdede yedi öznelik olduğundan ağın giriş düğüm sayısı yedi adettir. Çıkış düğüm sayısı da sınıflandırması yapılacak ağaç türü kadardır. Çalışmada gizli katman olarak tek katman kullanılmıştır. Gizli katman düğüm sayıları değiştirilerek farklı ağ mimarileri elde edilerek eğitim yapılmış ve performans değerleri karşılaştırılarak ideal ağ yapısı bulunmaya çalışılmıştır.

Tablo 3'te ÇKİBGY yapay sinir ağı 7 giriş, 8 çıkış katmanı ve farklı gizli katman mimarileri ile eğitilmiş ve ağın test verisine karşı doğru tahmin oranı ile hata miktarı gösterilmiştir. YSA parametreleri olarak; en iyi performans değerini veren (Tablo 4) 0.5 öğrenme katsayısı, 0.5 momentum değeri, sigmoid transfer fonksiyonu ve hataların mutlak değerlerinin toplamının ortalaması (Mean Absolte Error- MAE) performans ölçeği kullanılmıştır. Verilerin %70'i eğitim, kalan %30'da test için kullanılmıştır. Eğitim ve test verileri 180 veri içerisinde rastgele seçilmiştir.

Performans değeri; eğitilmiş ağın; test verisinden ne kadarını doğru tahmin ettiğini gösterir ve (*Doğru Tahmin Sayısı / Test Veri Sayısı *100*) şeklinde hesaplanır.

Tablo 3'te görüldüğü gibi gizli katman düğüm sayısı 4'ten başlatılıp (giriş veri nitelik sayısının yarısı) 30'a kadar ikişer artırılarak test edilmiştir. Tabloda görüldüğü gibi ağ mimarisi ile performans değeri arasında, belirli bir ilişki görülmemektedir. %96.29 doğruluk oranına sahip iki YSA mimarisi (7-16-8 ve 7-26-8) en iyi performans değerine sahiptir. Burada 7 giriş katmanı düğüm sayısını, 16 veya 26 gizli katman düğüm sayısını ve 8'de çıkış katmanı düğüm sayısını belirtmektedir.

Tablo 3. ÇKİBGY yapay sinir ağı 7 giriş, 8 çıkış katmanı ve farklı gizli katman mimarileri ile eğitilmiş ve ağın test verisine karşı doğru tahmin oranı ile hata miktarı

Gizli Katman Düğüm Sayısı	Performans	Hata Miktarı
4	%85.18	0.0502
6	%90.74	0.0349
8	%88.88	0.0316
10	%90.74	0.0255
12	%92.59	0.0286
14	%90.74	0.0281
16	%96.29	0.0193
18	%90.74	0.0282
20	%92.59	0.0250
22	%92.29	0.0298
24	%94.44	0.0235
26	%96.29	0.0183
28	%90.74	0.0275
30	%94.44	0.0212

Aynı performansa sahip ağlardan, daha az gizli katman sayısına sahip olan ağ, daha az hesaplama gerektirdiğinden tercih edilmelidir. Öte yandan hata oranları da önemlidir. Daha düşük hata oranına sahip YSA ağı tercih sebebi olmalıdır. Bu durumda Tablo 3'e göre en iyi performans ve en düşük hata oranı değerine sahip olan 7-16-8 ağ mimarisi en uygun çok katmanlı ileri beslemeli geri yayımlı YSA olacaktır.

En iyi performansa sahip ağ mimarisi (7-16-8) farklı YSA parametreleri (öğrenme, momentum) ile testler yapılmış ve elde edilen sonuçlar Tablo 4'te gösterilmiştir. Çalışmada kullanılan veri için momentum değerinin ve öğrenme katsayısının performansı çok az etkilediği görülmektedir. En iyi performans öğrenme oranı 0.5 ve momentum 0.5 değeri için elde edilmiştir.

Tablo 4. ÇKİBGY yapay sinir ağı 7-16-8 mimarisi için farklı öğrenme oranı ve momentum değerleri için performans ve hata oranları

Momentum	Öğrenme oranı	Performans	Hata Miktarı
	0.1	%94.44	0.0263
	0.2	%96.29	0.0218
0.5	0.3	%96.29	0.0196
	0.6	%96.29	0.0175
	0.8	%96.29	0.0195
	0.1	%96.29	0.0202
0.3	0.5	%96.29	0.0190
0.5		%96.29	0.0173
0.8		%96.44	0.0210

Çok katmanlı YSA da en iyi ağ yapısına ait test verisi karışıklık matrisine (confusion matrix) göre farklı ağaç türlerine ait 54 test verisinden 8 kızılâğaç verisinden 2 tanesi sedir olarak yanlış tahmin edilmiş, diğer ağaç türlerinin tümü doğru tahmin edilmiştir (Tablo 5).

Tablo 5. Karışıklık matrisi

a	b	c	d	e	f	g	h	Ağaç türleri
6	0	0	0	0	0	2	0	a = Kızıl Ağaç
0	7	0	0	0	0	0	0	b = Doğu Kayını
0	0	3	0	0	0	0	0	c = Kara Kavak
0	0	0	7	0	0	0	0	d = Ceviz
0	0	0	0	6	0	0	0	e = Meşe
0	0	0	0	0	8	0	0	f = Kestane
0	0	0	0	0	0	8	0	g = Sedir
0	0	0	0	0	0	0	7	h = Çam

Çalışmada çok katmanlı ileri beslemeli geri yayımlı YSA ile birlikte RBFN YSA ile de veriler test edilmiş ve her iki YSA'ya ait sınıflandırma performans sonuçları Tablo 6'da verilmiştir. Tablodan da görüldüğü gibi RBFN'de %92.59 doğruluk oranı gibi iyi bir performans göstermiştir. RBFN ağlar daha az hesaplama gerektirdiğinden, düşük maliyetli cihazlar olan mikro denetleyici gibi düşük saat hızı ve belleğe sahip aygıtlarda tercih edilebilir.

Tablo 6. Farklı YSA yöntemlerine göre sınıflandırma performans sonuçları

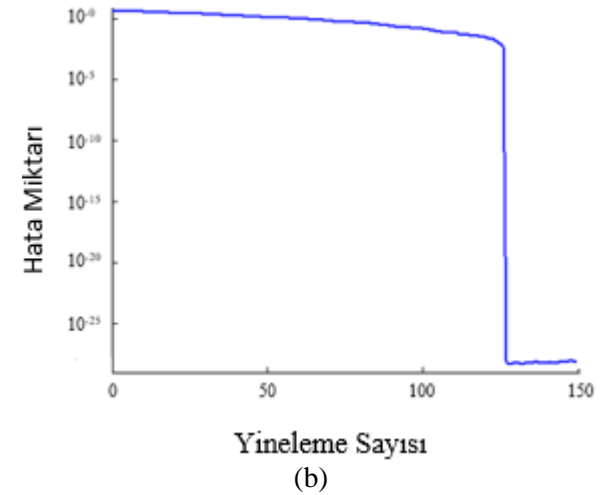
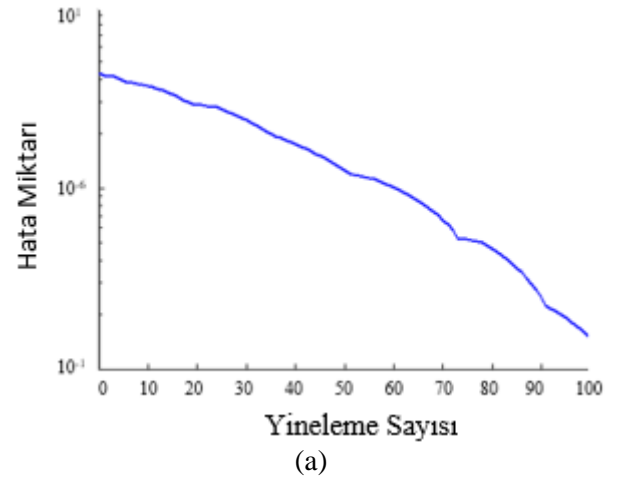
YSA Yöntemi	Doğru Tahmin Oranı	Hata Miktarı
RBFN	%92.59	0.0185
ÇKİBGY	%96.29	0.0173

Şekil 6'da ÇKİBGY ağın 7-16-8 mimarisi eğitim sırasında yinelemelere göre hata miktarı değişim grafiği verilmiştir. Grafikte görüldüğü gibi yinelemeler ilerledikçe hata miktarı azalmaktadır. 1000 yinelemeden sonra hata miktarı sabit kalmaktadır, burada eğitim işlemi durdurulmuştur. Eğitime devam etmek çözümü kötüleştirir.

RBF ağı eğitimi gizli katman düğüm sayısı değiştirilerek yapılmaktadır. Gizli katman düğüm sayısındaki belirli bir değerden sonra hata oranında dramatik bir değişim yaşanmaktadır. Bu yüzden hata değişim grafiği Şekil 7 (a) ve Şekil 7 (b) şeklinde iki bölüm halinde verilmiştir. RBFN gizli katman sayısı 120' den itibaren hata miktarında hızlı bir düşüş görünmekte ve bu sayı 130'a ulaştığında en düşük hata seviyesine ulaşmaktadır. En iyi performans için ağın gizli katman sayısı bu seviyede tutulmalıdır.



Şekil 6. ÇKİBGY ağın eğitim hata miktarı



Şekil 7. (a) İlk 100 yineleme için RBF ağın eğitim hata miktarı değişim grafiği **(b)** Tüm yinelemeler için RBF ağın eğitim hata miktarı değişim grafiği.

4. Sonuç ve Öneriler

Çalışmada sekiz farklı ağaç türüne ait yedi farklı mekanik özelliğe sahip 180 veri farklı tip (ÇKİBGY, RBFN) ve mimaride YSA kullanılarak ilk defa mekanik özelliklerinden ağacın türünün tahmini işlemi yapılmıştır.

Performans sonuçları açısından çok katmanlı ileri beslemeli geri yayımlı YSA %96.29 doğruluk oranında tahmin yaparken, RBFN YSA %92.59 oranında tahminde bulunmuştur. RBFN ile ÇKİBGY arasında %3.7'lik bir performans farkı gözükmemektedir. Ancak RBFN YSA daha az parametre ve hesaplamaya sahip olduğundan daha kısa sürede öğrenmekte ve daha hızlı hesaplama yapabilmektedir. Dolayısıyla tahmin işlemini mikro denetleyici gibi düşük kapasiteli (MHz seviyesinde frekanslarla çalışan ve sınırlı hafızası olan) cihazlarda yapılabilmesi için tercih sebebi olabilir.

Çalışma, herhangi bir konstrüksiyon için ihtiyaç duyulan mekanik özellikleri karşılayacak ideal ağaç malzemenin tespitinde yardımcı olacaktır. Böylece belirli güven aralığında malzeme ile ilgili yanılma payı minimize edilecektir.

Çalışma ve elde edilen sonuçlar, ağaç malzemenin teknik özelliklerini bulup buna göre ağacın türünü tespit edebilen mikro denetleyici kontrollü elektro-mekanik bir cihaz üretilmesinde yardımcı olacaktır.

5. Kaynaklar

Arisariyawong, S. ve Charoenseang, S., 2002, Dynamic Self-Organized Learning for Optimizing the Complexity Growth of Radial Basis Function Neural Networks, IEEE International Conference on Industrial Technology, 11-14 Dec. 2002, Bangkok, Thailand, p. 655-660.

As, N., Dündar, T. ve Büyüksarı, Ü., 2016. Classification of wood species grown in Turkey according to some physico-mechanic properties, Journal of the Faculty of Forestry Istanbul University, 66, 2, 727-735.

ASTM D2017-81, 1986. Accelerated Laboratory Test of Natural Decay Resistance of Woods.

Ay, N., & Şahin, H. (2002). Maçka-Çatak Bölgesi Anadolu Kestanesi (*Castanea Sativa* Mill.) Odununun Bazı Mekanik Özellikleri. Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi, 3(1), 87-95.

Bal B. C., Bektaş İ. ve Kaymakçı A., 2012. Toros sedirinde genç odun ve olgun odunun bazı fiziksel ve mekanik özellikleri, Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences, 15, 2, 17-27.

Berkel A., 1972, Ağaç Malzeme Teknolojisi, Ağaç Malzemenin Korunması ve Emrenye Tekniği, İ.Ü. Orman Fakültesi, Yayın No: 1745/183, Sermet Matbaası, İstanbul.

Bozkurt, A. Y., ve Erdin, N., 1997, Ağaç Teknolojisi, Yayın No: 3998, ISBN 975-404-449-X, İstanbul, s. 346-357.

Broomhead D. S. ve Lowe D., 1988. Multivariable functional interpolation and adaptive network, Complex Systems, 2, 321-355.

Dündar, T. (2002). Demirköy yöresi ıstranca meşelerinin (*Quercus hartwissiana* stev.) mekanik özellikleri. Journal of the Faculty of Forestry Istanbul University| İstanbul Üniversitesi Orman Fakültesi Dergisi, 52(2), 159-176.

Düz kale, G., Bektaş, İ., Tunç, H. H. ve Doğanlar, Y., 2015. Zeytin ağacı (*Olea europaea*) odunun bazı fiziksel ve mekanik özelliklerinin belirlenmesi, Düzce Üniversitesi Ormancılık Dergisi, 10, 2, 29-35.

Erdin, N., 2003, Ağaç Malzeme Kullanımı ve Çevreye Etkisi, İnterteks İnşaat 2003 Fuarı, Ahşap Seminerleri, 20-22 Şubat, İstanbul.

Findlay, W. P. K., 1985, Preservation of Timber in the Tropics, Martinus Nijhoff/DR W. Junk Publishers, ISBN 90-247-3112-7, Dordrecht, Netherlands.

Güller B. ve Ay N., 2001. Artvin yöresi sakallı kızılğaç (*Alnus glutinosa* subsp. *barbata* (C. A. Mey.) Yalt.) odununun bazı mekanik özellikleri, Turkish Journal of Agriculture and Forestry, 25, 2, 129-138.

Güller, B., Isik, K. ve Cetinay, S. (2011). Genetic variation in *Pinus brutia* Ten.: Wood density traits. BioResources, 6(4), 4012-4027.

İlkuçar, (2017). <http://www.ilkucar.com/data/agacmek.xlsx> (Erişim tarihi:25.08.2017)

Kahveci, E. (2012). Farklı Yetiştirme Ortamı Koşullarının Sakallı Kızılğaç (*Alnus glutinosa* subsp. *barbata* (CA Mey.) Yalt.) Odununun Bazı Fiziksel ve Mekanik Özelliklerine Etkileri. Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Trabzon.

Kantay, R., As, N. ve Ünsal, Ö., 2000. The mechanical properties of walnut (*Juglans*

- regiaL.) wood, Turkish Journal of Agriculture and Forestry, 24, 6, 751-756.
- Kaymakçı, A., Bal, B. C. ve Bektaş, İ., 2011. Pavlonya odununun bazı özellikleri ve kullanım alanları, Kastamonu Üniversitesi Orman Fakültesi Dergisi, 11, 2, 228-238.
- Korkut, S., ve Bektas, I., 2008. The effects of heat treatment on physical properties of Uludag fir (*Abies bornmuelleriana* Mattf.) and Scots pine (*Pinus sylvestris* L.) wood, Forest Products Journal, 58, 3, 95-99.
- Malkoçoğlu, A. K. (1994). Doğu Kayını (*Fagus orientalis* Lipsiky) Odununun Teknolojik Özellikleri, Doktora Tezi, KT Ü. Orman Fakültesi, Trabzon.
- McCulloch W. S. ve Pitts W., 1943. A logical calculus of the ideas immanent in nervous activity, Bulletin of Mathematical Biophysics, 5, 115-133.
- Moradkhani H., Hsu K., Gupta H. V. ve Sorooshian S., 2004. Improved streamflow forecasting using self-organizing radial basis function artificial neural networks, Journal of Hydrology, 295, Issues 1-4, 246-262.
- Panshin, A. J. ve De Zeeuw, C., 1980, Textbook of Wood Technology, Mc Graw-Hill, Inc. Fourth Edition, ISBN: 0-07-04844-4, New York.
- Rowell, R. M., 1990, Materials Science of Lignocellulosics, Materials Research Society Symposium Proceedings, 197, Pittsburgh, PA, p. 3-9.
- Wen, L., Li, Z., Han, Z., Xie, X., Zhang, R., 2016, The External Characteristics Simulation System of Diesel Engine Based on Levenberg-Marquardt Algorithm, IEEE International Conference on Industrial Informatics - Computing Technology, Intelligent Technology, Industrial Information Integration (ICIICII), 3-4 Dec. 2016, Wuhan, China, p. 30-33.
- Yu, H. ve Wilamowski, B. M., 2011, Levenberg-Marquardt training. Industrial Electronics Handbook Intelligent Systems. Wilamowski, B. M. and Irwin, J. D. (eds.), CRC Press, Boca Raton. pp. 1-16.