

Ormanların Çap Dağılımlarının Modellenmesinde Derin Öğrenme Algoritmalarının Kullanımı: Trabzon ve Giresun Ormanları Doğu Ladini-Sarıçam Karışık Meşcereleri Örneği

İ. Ercanlı^{1,*}, F. Bolat¹, H. Yavuz²

¹ Çankırı Karatekin Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü, 18200, ÇANKIRI

² Karadeniz Teknik Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü, 61080, TRABZON

MAKALE KÜNYESİ

Geliş Tarihi: 11 Kasım 2018

Kabul Tarihi : 31 Aralık 2018

*Sorumlu yazarın e-posta adresi:
ilkerercanlı@karatekin.edu.tr

ÖZ

Bu çalışmada, Yapay zeka uygulaması olan Derin Öğrenme Algoritmaları ile meşcerelerin çap dağılımlarını modellenmesi amaçlanmış, bu amaçla da Trabzon ve Giresun Orman Bölge Müdürlükleri sınırları içerisinde yer alan eşityaşlı Doğu Ladini-

Sarıçam karışık meşcerelerinden (LCs veya CsL) Ercanlı (2010) tarafından alınan 161 adet örnek alanlardan elde edilen veriler kullanılmıştır. Meşcerelerin çap dağılımlarının %25, %50 ve %95'lik yüzdelerine göre parametreleri hesaplanan 3 parametrelili Weibull olasılık yoğunluk fonksiyonuna ilişkin Hata kareler Toplamı (HKT) değeri; 6126730, Hataların Ortalama Kare Kökü (HKOK) değeri; 67.5172, $R^2_{düz.}$ değeri; 0.6121, AIC değeri; 11351.16 ve SBC değeri ise; 11366.77 olarak elde edilmiştir. Derin öğrenme algoritmasının eğitim süreci, örnek alanların belirli çap basamağına karşılık gelen ağaç sayısı ($n \text{ ha}^{-1}$) özelliğinin çıktı değişkeni; örnek alanın toplam ağaç sayısı ($N \text{ ha}^{-1}$), ilgili çap basamağının orta değeri (cm) ve dağılımın %25, %50 ve %95'lik yüzdelerine girdi değişkeni esas alınarak, "nfolds=5" alt seçeneği ile "k sayısı kadar çapraz doğrulama" yöntemi ile uygulanmıştır. Bu eğitim süreci, R yazılımının H_2O paketi kullanılarak gerçekleştirilmiş, algoritma yapısının oluşturulmasında, nöron sayısı; 100 ve transfer fonksiyonu "Rectifier" fonksiyonu seçilmiştir. Derin öğrenmede, ağın başarısını etkileyen katman sayısının belirlenmesinde ise, derin öğrenme algoritmalarına ilişkin 8 farklı katman (3, 4, 5, 6, 7, 8, 9, 10 katman seçenekleri) seçeneği çeşitli istatistiksel başarı ölçüt değerlerine göre karşılaştırılmıştır. Yapılan bu karşılaştırmada, HKT değeri; 1286083, HKOK değeri; 30.9570, $R^2_{düz.}$ değeri; 0.9184, AIC değeri; 9252.41 ve SBC değeri ise; 9278.44 olarak elde edilen 5 katmanlı derin öğrenme algoritması, çap dağılımını modellemede en başarılı olarak belirlenmiştir. 3 parametrelili Weibull olasılık yoğunluk fonksiyonuna göre derin öğrenme ile HKT değerinde; % 79.01 azalış, HKOK değerinde % 54.15 azalış, $R^2_{düz.}$ değerinde % 30.63 artış, AIC değerinde % 18.49 azalış ve SBC değerinde % 18.37 azalış elde edilmiştir.

Anahtar kelimeler: Çap Dağılımı, Derin Öğrenme Algoritması, Tahmin, Hata kareler toplamı

Use of Deep Learning Algorithms for Modelling Forest Diameter Distributions: A Case Study of Oriental Spruce and Scots Pine Mixed Stands in Trabzon-Giresun Forest

ABSTRACT

To model diameter distribution by using Deep Learning Algorithms, an application of an Artificial Intelligence, the data, obtained from 161 plots sampled by Ercanlı (2010) from even aged Scotch Pine-Oriental Spruce mixed stands located in Trabzon and Giresun Forest District Enterprise, were used in this study. Sum of Squared Errors (SSE), Root Mean Squared Error (RMSE), $R^2_{adj.}$, AIC and SBC for 3-Parameter Weibull probability density function were 6126730, 67.5172, 0.6121, 11351.16 and 11366.77, respectively. The Deep Learning Algorithm were trained including the target independent as number of trees (ha^{-1}) at any diameter class in the sample plots and input variables as total

Bu makaleye atf:

Ercanlı, İ., Bolat, F., Yavuz, H., 2018. Ormanların Çap Dağılımlarının Modellenmesinde Derin Öğrenme Algoritmalarının Kullanımı: Trabzon ve Giresun Ormanları Doğu Ladini-Sarıçam Karışık Meşcereleri Örneği. Anadolu Orman Araştırmaları Dergisi 4(2): 122-132.

number of trees of sample plots, middle value of any diameter class, %25, %50 and %95 percent values of these diameter distributions and also based on the cross-validation fitting process with “nfolds=5”. This training process were carried out using H₂O open source machine learning platform in R software environment and also the number of 100 neurons and “Rectifier” transfer function were selected in training algorithms. Especially, eight different layer choices (3, 4, 5, 6, 7, 8, 9, 10 layer choices) for deep learning algorithms were compared based on different success criteria to determine best predictive number of layer. Based on these criteria, five-layer deep learning algorithm yielded the best predictive results for individual volume values with SSE of 1286083, RMSE of 30.9570, R²adj. of 0.9184, AIC of 9252.41 and SBC of 9278.44. Compared five-layer deep learning algorithm with 3-Parameter Weibull probability density function, 79.01% decrease in SSE, 54.15% decrease n RMSE, 30.63% increase in R²adj., 18.49% decrease in AIC and 18.37% decrease in SBC were obtained by the deep learning algorithm.

Keywords: Diameter Distribution, Deep Learning Algorithm, Prediction, Mean squared error

1. Giriş

Ormanlıkta, çeşitli koşullar altındaki meşcerelerin artım ve büyüme değerlerinin tahmin edilmesinde, envanter verilerinin güncellenmesinde, meşcerelerden elde edilebilecek odun hasılasının belirlenmesinde, silvikültürel işlem seçeneklerinin değerlendirilmesinde yaygın bir biçimde artım ve büyüme modelleri kullanılmaktadır (Burkhart, 1995; Garcia, 2001). Bu bakımdan, büyüme modelleri, meşcerelerin bugünkü ve gelecekteki artım ve büyüme değerleri ile meşcere dinamiklerindeki değişimi tahmin etmektedir (Gadow and Hui, 1999). Ormanlardan elde edilecek ürün çeşitlerine ilişkin tahminler, başta ormancılık planlaması olmak üzere çeşitli ormancılık çalışmalarında önemli bir bilgi girdisidir (Maltamo, 1997; van Laar and Akça, 2007). Meşcereler hakkındaki ayrıntılı tahminlerin elde edilmesi, meşcere içinde ağaçların çap basamaklarına dağılımlarının ortaya konulması ve tahmin edilmesi ile mümkün olabilmektedir (Rennolls et al., 1985). Meşcerelerin çap dağılımlarının tahmin edilmesinde, çap dağılımının (frekans tablosunun), belirli bir olasılık yoğunluk fonksiyonunu “probability density function (pdf)” temel alınarak modellenmesi, en yaygın kullanılan yöntemdir. İstatistik yoğunluk fonksiyonları, belirli çap değerlerine ilişkin frekans değerinin toplam birey sayısına oranını veren istatistiksel fonksiyonlar olup, bu fonksiyonlar yardımıyla, başta ağaç sayısı olmak üzere, meşcerelerin göğüs yüzeyi ve hacim değerlerinin farklı çap basamaklarına dağılımlarına ilişkin tahminler elde edilebilmektedir (Ercanlı, 2010). Çap dağılımı konusundaki ilk çalışmalar, 1883 yılında Gram’ın kayın meşcerelerinin çap dağılımlarını normal dağılımla ve 1898 yılında De Liocourt’un değişik yaşlı meşcerelerde çap dağılımlarını exponential dağılımla tanımladığı çalışmalarıdır (Ercanlı, 2010). 1930’lı yıllarda, çeşitli matematik serileri kullanılarak çap dağılımları modellenmeye çalışılmıştır. Ormancılıkta, 1960’lı yıllarla birlikte (Clutter and Bennet, 1965) çap dağılımlarının modellenmesinde, istatistik yoğunluk

fonksiyonlarının “probability density function (pdf)” kullanımına ilişkin çalışmalar yürütülmüştür. Özellikle, ormancılıkta modellenmenin daha da önem kazanması ile çap dağılımlarının modellenmesinde farklı olasılık yoğunluk fonksiyonları kullanılarak birçok çalışma gerçekleştirilmiştir (Bailey and Dell, 1973; Smalley and Bailey, 1974; Hafley and Schreuder, 1977; Rennolls et al., 1985; Knoebel et al., 1986; Pukkala et al., 1990; Saramäki, 1992; Maltamo et al., 1995; Maltamo, 1997; Packard, 2000; Liu et al., 2004; Palahi et al., 2006; Podlaski 2006; Nord-Larsen and Cao, 2006; Palahi et al., 2007). Bu konuda yapılan çeşitli araştırmalarda farklı olasılık yoğunluk fonksiyonları önerilmesine karşın, 3 parametrelili Weibull fonksiyonu, model yapılarının oldukça esnek olmaları ve farklı çap dağılımlarını modellemedeki başarıları ile diğer dağılım fonksiyonlarına göre öne çıkmıştır (Bailey and Dell 1973; Matney and Sullivan 1982; Liu et al., 2004; Cao, 2004; Palahi et al., 2006). Ülkemizde ise, çap dağılımı modellenmesinde olasılık yoğunluk fonksiyonları kullanılarak farklı türler için çeşitli çalışmalar gerçekleştirilmiştir (Saraçoğlu, 1988; Yavuz, 1992; Carus, 1996; Atıcı, 1998; Yavuz vd., 2002; Carus ve Çatal, 2008; Ercanlı, 2010; Sönmez vd., 2010; Kahrman ve Yavuz, 2011; Karakaş, 2013; Ercanlı vd., 2013; Doğdaş, 2014; Bolat, 2015a; Güneş, 2015).

Çap dağılımlarını belirli olasılık fonksiyonu ile modellenmesi yanında, artım ve büyüme modellenmesinde, yapay zeka uygulamaları olan Yapay Sinir Ağları (YSA) ve Derin Öğrenme Algoritmalarının kullanımı da önem kazanmaktadır. Özellikle son yıllarda, YSA’nın çeşitli tek ağaç ve meşcere özelliklerinin artım ve büyüme değerlerinin tahmin edilmesinde kullanımına ilişkin çalışmalar gerçekleştirilmiştir. Ülkemizde YSA tekniği kullanılarak, Özçelik et al. (2008), ağaç hacimlerini; Diamantopoulou and Özçelik (2012) ve Özçelik et al. (2013), Bolat (2015b), ağaç boyunu; Özçelik et al. (2014), ağaçların gövde çaplarını; Diamantopoulou et al. (2015), 2 parametrelili Weibull olasılık yoğunluk fonksiyonun parametrelerini;

Ercanlı vd. (2016a) ve Günlü ve Ercanlı (2017), uzaktan algılama verileri ile meşcere karbonunu, Ercanlı vd. (2016b) çap artımını; Bolat ve Ercanlı (2016) ve Ercanlı ve Bolat (2017), çap dağılımlarını; Ercanlı vd. (2015), ağaçların yaş-boy ilişkilerini; Şenyurt vd. (2015), çeşitli meşcere özelliklerini; Ercanlı vd. (2018), yaprak alan indeksini tahmin etmişlerdir. Yapay zekanın diğer bir çeşidi olan Derin Öğrenme algoritmaları ise, tahminleme ve sınıflandırma gibi uygulamalarda oldukça başarılı sonuçlar verebilmektedir (LeCun et al., 2015; Carranza-Rojas et al., 2017). Derin öğrenme kavramı, 2010'lu yıllarda kullanılmaya başlanmış olup, özellikle derin öğrenme ile çok sayıda, milyonlarca ve hatta milyarlarca, veriye ilişkin analizlerin çok katmanlı olarak yapılması, etkin ve başarılı sonuçların üretebilmesini sağlamaktadır. Derin öğrenme yapısal olarak, YSA ile benzerlikler göstermesine karşın; yapay sinir ağları, genelde 1-2 katman ve 20-30 nörona ile sınırlı bir yapıya sahip iken, derin öğrenme 5-10 katman ve yüzlerce ve binlerce nöron ile oldukça karmaşık bir yapıda olabilmektedirler. Başta derin öğrenme olmak üzere, yapay zeka tekniklerinin bu karmaşıklığı da, bu tekniklerin insan beyninin öğrenme ve karar verme yöntemlerinden esinlenerek geliştiriliyor olmasından gelmektedir. Günümüz literatüründe, ormanların büyüme tahminleri için YSA kullanımına ilişkin belirli sayıda çalışma gerçekleştirilmesine karşın, diğer bir yapay zeka çeşidi olan derin öğrenme algoritmalarını kullanan bilimsel çalışmalar henüz başlangıç aşamasındadır. Bu çalışmada, Ülkemizin Doğu Karadeniz Bölgesinde yer alan Trabzon ve Giresun Orman Bölge Müdürlüklerinde önemli bir yayılım gösteren Doğu Ladini-Sarıçam karışık meşcerelerinin çap dağılımlarının modellenmesinde Derin öğrenme Algoritmalarının kullanımının değerlendirilmesi amaçlanmıştır.

2. Materyal ve yöntem

Bu çalışmada, araştırma materyali olarak, Trabzon ve Giresun Orman Bölge Müdürlükleri (O. B. M.) sınırları içerisinde yer alan eşityaşlı Doğu Ladini-Sarıçam karışık meşcerelerinden (LCs veya CsL) Ercanlı (2010) tarafından alınan 161 adet örnek alanlardan elde edilen veriler kullanılmıştır. Bu çalışmada, Trabzon O.B.M. sınırları içerisindeki Torul Orman İşletme Müdürlüğü Zigana Orman İşletme Şefliğinden 30, Kürtün O.İ.Ş.'den 20, Sarıçadağ O.İ.Ş.'den 18, Örümcek O.İ.Ş.'den 20, Maçka Orman İşletme Müdürlüğü Çatak O.İ.Ş.'den 8 ve Sürmene O.İ.M. Çaykara O.İ.Ş.'den 10 adet olmak üzere toplam 106 adet örnek alan alınmıştır (Ercanlı, 2010). Giresun O.B.M. sınırları içerisindeki Tirebolu O.İ.M. Akılbaba O.İ.Ş.'den 17,

Dereli O.İ.M. İkisü O.İ.Ş.'den 14, Espiye O.İ.M. Karaduğa O.İ.Ş.'den 24 adet olmak üzere toplam 55 adet örnek alanlar alınmıştır (Ercanlı, 2010).

Örnek alanlar daire biçiminde olup, büyüklükleri meşcere yapısı ve karışım durumuna göre 600 m² ile 1200 m² arasında değişmektedir. Çalışma kapsamında alınan örnek alanlarda; göğüs çapları 8 cm ve daha büyük tüm ağaçlarda göğüs çapı (d_{1.30}), her iki tür için çap basamaklarında dengeli bir şekilde dağıtılan 20-25 ağaçta boy, tepe başlangıç yüksekliği, tepe çapı, dip kütük çapı (d_{0.30}) ve çift kabuk kalınlığı ölçülmüştür. Ölçülen bu boy değerlerinin ayrıca hektarda 100 ağaç yöntemine göre belirlenmiş sayıda en boylu ağaçları içermesine de özen gösterilmiştir. Çap ölçümleri, çap ölçer ile mm hassasiyetinde, boy ölçümleri ise; Vertex Haglöf Boy Ölçer ile cm hassasiyetinde gerçekleştirilmiştir.

Araştırma materyali olan toplam 161 örnek alan verisinden, 137 örnek alan verisi rasgele seçilerek, Derin Öğrenme Algoritmalarının eğitiminde ve tahminlerin elde edilmesinde kullanılmış olup; 24 adet örnek alan verisi ise, eğitim süreci gerçekleştirilmiş olan ağı denetlenmesinde ve simülasyonların elde edilmesinde kullanılmıştır.

2.1. Çap dağılımlarının modellenmesi

Orman meşcereleri içindeki farklı çap basamaklarındaki ağaç sayılarını tahmin etmek üzere istatistik biliminin bir konusu olan Olasılık Yoğunluk Fonksiyonlarının “Probability Density Function (pdf)” kullanımı yaygındır. Olasılık yoğunluk fonksiyonları, belirli bir çap değerinde (x değeri) ya da çap değerleri arasında bulunan birey sayısının (f, frekans değeri), meşceredeki toplam birey sayısına olan oranını, 0 ile 1 arasındaki bir değer olarak veren fonksiyonlardır. Olasılık yoğunluk fonksiyonları, ayrıca belirli bir çap değerine kadar olan kümülatif toplam birey sayısının oranını da verebilmektedir. Ormanlık literatüründe, çok farklı fonksiyonlarının karşılaştırılmasına ilişkin çalışmalar yapılmış olup, özellikle esnek ve farklı dağılımları temsil kabiliyetleri ile 3 Parametrelili Weibull olasılık yoğunluk fonksiyonu çap dağılımlarının modellenmesinde başarılı sonuçları ile öne çıkmıştır (Smalley and Bailey 1974, Lohrey and Bailey 1977; Feduccia et al. 1979, Matney and Sullivan 1982, Clutter et al. 1984, Baldwin and Feduccia 1987; Liu et al., 2004; Čavlović et al., 2006; Palahi et al. 2006; Zhang and Liu, 2006; Gorgoso-Varela et al. 2007; Jiang and Brooks 2009; Andrasev et al. 2009). Bu bakımdan, bu çalışmada da, diğer çalışmalarda başarıyla kullanılmış olan 3 parametrelili Weibull olasılık yoğunluk fonksiyonu, çap dağılımlarını

modellemek üzere seçilmiştir. 3 parametrelili Weibull Olasılık Yoğunluk Fonksiyonu (Bailey and Dell, 1973) aşağıdaki gibi gösterilebilir;

$$F(x, \alpha, \beta, \gamma) = \frac{\alpha}{\beta} \cdot \left(\frac{x-\gamma}{\beta}\right)^{\alpha-1} \cdot \exp\left(-\left(\frac{x-\gamma}{\beta}\right)^{\alpha}\right) \quad (1)$$

Bu formülde, x: çap (cm), α, β, γ ise olasılık yoğunluk fonksiyonun parametreleridir. Bu parametrelerden, α (alfa); Weibull olasılık yoğunluk fonksiyonun konum (location) parametresi iken, β (beta); ölçek (scale) parametresi ve γ (lambda) ise; biçim (shape) parametresidir. Kümülatif Weibull dağılımı ise aşağıda verilmiştir.

$$F(x, \alpha, \beta, \gamma) = 1 - \exp\left(-\left(\frac{x-\gamma}{\beta}\right)^{\alpha}\right) \quad (2)$$

Weibull fonksiyonun konum parametresi (α); çap dağılımdaki en küçük çap değeri ile ilişkili iken, ölçek parametresi (β); çap dağılımının yaygınlığını ve

biçim parametresi (γ) ise; dağılımın şeklini tanımlamaktadır.

3 parametrelili Weibull fonksiyonuna ilişkin parametrelerinin tahmin edilmesinde, farklı yöntemler önerilmesine karşın, basit ve uygulanabilir yöntemler olan ve dağılımların modellenmesinde başarılı sonuçlar veren yüzelikleri esas olan eşitlikler kullanılmıştır (Knowe, 1992; Bailey et al., 1989; Knowe et al., 1997; Liu et al., 2004; Cao, 2004; Poduel, 2011; Poduel and Cao, 2013). Bu çalışmada; çap dağılımlarının %25, %31, %50, %63 ve %95'lik değerlerine karşılık gelen çapları esas alan 4 farklı eşitlikler esas alınarak, 3 parametrelili Weibull fonksiyonuna ilişkin parametreler hesaplanmıştır (Cao, 2004; Poduel, 2011; Poduel and Cao, 2013). Çap dağılımının yüzeliklerini esas alan eşitlikler, Çizelge 1'de ayrıntılı olarak verilmiştir. Bu eşitliklerdeki çap dağılımlarının yüzelik değerleri, SPSS adlı bir istatistik paket programı kullanılarak hesaplanmıştır (SPSS 15.0 Inc., 2005).

Çizelge 1. Olasılık Yoğunluk fonksiyonlarının parametrelerinin tahminine ilişkin Eşitlikler (Cao, 2004; Produel, 2011; Produel and Cao, 2013).

Yöntem	Eşitlikler
%31 ve %63'lük değerleri esas alan eşitlikler	$\alpha = 0.5 \cdot d_{min}$ $\gamma = \frac{\ln\left(\frac{\ln(1-0.63)}{\ln(1-0.31)}\right)}{\ln(d_{0.63}-\alpha)-\ln(d_{0.31}-\alpha)}$ $\beta = \frac{d_{0.63}-\alpha}{(-\ln(1-0.63))^{\frac{1}{\gamma}}}$
%50 ve %95'lük değerleri esas alan eşitlikler	$\alpha = 0.5 \cdot d_{min}$ $\gamma = \frac{\ln\left(\frac{\ln(1-0.95)}{\ln(1-0.50)}\right)}{\ln(d_{0.95}-\alpha)-\ln(d_{0.50}-\alpha)}$ $\beta = \frac{d_{0.50}-\alpha}{(-\ln(1-0.50))^{\frac{1}{\gamma}}}$
%25, %50 ve %95'lük değerleri esas alan eşitlikler	$\alpha = 0.5 \cdot d_{min}$ $\gamma = \frac{\ln\left(\frac{\ln(1-0.95)}{\ln(1-0.25)}\right)}{\ln(d_{0.95}-\alpha)-\ln(d_{0.25}-\alpha)}$ $\beta = \frac{d_{0.50}-\alpha}{(-\ln(1-0.50))^{\frac{1}{\gamma}}}$
%31, %50 ve %63'lük değerleri esas alan eşitlikler	$\alpha = 0.5 \cdot d_{min}$ $\gamma = \frac{\ln\left(\frac{\ln(1-0.63)}{\ln(1-0.31)}\right)}{\ln(d_{0.63}-\alpha)-\ln(d_{0.31}-\alpha)}$ $\beta = \frac{d_{0.50}-\alpha}{(-\ln(1-0.50))^{\frac{1}{\gamma}}}$

Eşitliklerde; n; örnek alandaki ağaç sayısını, d_{min} ; örnek alandaki minimum çapı, $d_{0.25}$, $d_{0.31}$, $d_{0.50}$, $d_{0.63}$, $d_{0.95}$; çap dağılımda verileri küçükten büyüğe doğru sıralandığında %25'lik, %31'lik, %50'lik, %63'lik ve %95'lik veriye karşılık gelen çap değerini göstermektedir.

2.2. Derin öğrenme algoritmaları

Derin Öğrenme Algoritmaları, yapay zeka yöntemlerinden birisi olup, insan beyninin öğrenme ve karar verme karakteristikleri esas alınarak geliştirilmiştir. Yapay zekanın derin öğrenme algoritmalarından daha eski olan ve daha fazla kullanım alanı bulmuş olan yapay sinir ağları; giriş (input layer), gizli (hidden layer) ve çıktı (output layer) katmanları olmak üzere belirli sayıda katman içeren bir yapıya sahip iken, derin öğrenme ise çok sayıda 5,10 ve hatta onlarca katmanı içeren oldukça kompleks bir yapıdadır. Derin öğrenme algoritmalarının çok katmanlı ve kompleks yapıları yanında, eğitim süreçlerinin gerçekleştirilmesinde, bilgisayarların Grafik İşlemci ünitelerini (Graphics Processing Unit, GPU) kullanmaları ile de öne çıkmaktadırlar. 2010 yılından itibaren, yapay sinir

ağların ötesinde bir yapay zeka uygulaması olarak kullanımı öne çıkmaya başlayan Derin öğrenme Algoritmaları, günümüzde hızla popülerlik kazanmıştır. Gerek yapay sinir ağları gerekse çok katmanlı bir yapay sinir ağ çeşidi olan Derin Öğrenme Algoritmaları ile ormanların, meşcerelerin ve tek ağaçların artım ve büyüme değerlerinin tahmini, çeşitli yazılımlar vasıtasıyla gerçekleştirilebilmektedir. Bir Derin Öğrenme Algoritması ile tahminlerin elde edilmesi, temelde veriler arasındaki ilişkileri (giriş ve çıktı değişkenleri ilişkileri) öğrenme sürecini (training) içermekte olup, öğrenme süreci de oldukça yoğun matematik işlemlerden oluşmaktadır. Bu çalışmada, derin öğrenme algoritmalarına ilişkin eğitim süreçlerinin gerçekleştirilmesinde, R yazılım dilinde oluşturulmuş (kodlanmış) H₂O paketi kullanılmıştır (H₂O.ai Team, 2018). H₂O paketi, açık kaynak kodlu

bir yapay zeka platformu olup, “Generalized Linear Models”, “Gradient Boosting Machines”, “Random Forests”, “Deep Neural Networks (Deep Learning)”, “Stacked Ensembles”, “Naive Bayes”, “Cox Proportional Hazards”, “K-Means”, “PCA” ve “Word2Vec” gibi yapay zeka uygulamalarını içermektedir. Özellikle, R yazılımı ile kodlanmış olan H₂O paketi, çok sayıda veriden ve değişkenden oluşan sistemlere ilişkin analizleri gerçekleştirmekte oldukça etkin, hızlı ve başarılı sonuçlar verebilmektedir. R yazılım mimarisine sahip H₂O paketi, bu bakımdan oldukça kompleks derin öğrenme algoritmalarını çözebilmekte ve tahminler elde edebilmektedir.

Bir derin öğrenme algoritmasını oluştururken, katman sayısı, nöron sayısı ve transfer fonksiyon çeşidi gibi algoritma parametrelerinin belirlenmesi, tahmin sonuçlarının başarısını etkileyen önemli karar süreçleridir. Ayrıca, özellikle derin öğrenme ile tahmin edilecek olan ve çıktı değişkeni olarak isimlendirilen özellik ile tahminde girdi değişkeni olacak çeşitli özelliklerin belirlenmesi de, ağın tahmin başarısını etkileyen diğer parametreler olarak karşımıza çıkmaktadır. Bu çalışmada, meşcerelerin farklı çap basamaklarındaki (kademelerindeki) ağaç sayılarının tahmin edilmesi amaçlandığından; derin öğrenmeye ilişkin çıktı değişkeni; belirli bir çap kademesinde (çap basamağı aralığı 4 cm olarak alınmış olup; 8.0-12, 12.1-16, 92.1-96 ve 96.1-100 cm’lik çap kademeleri gibi) bulunan ağaç sayısının (f, frekans değeri), örnek alan büyüklüğüne göre hesaplanmış hektardaki (n ha⁻¹) değeri alınmıştır. Algoritmanın girdi değişkenleri ise; ilgili çap kademesi orta değerine karşılık gelen çap değeri (cm), örnek alanın toplam ağaç sayısı (N ha⁻¹) ve olasılık yoğunluk fonksiyonlarının parametrelerinin tahminine ilişkin eşitliklerde en başarılı olarak belirlenen dağılımın yüzdelik değerlerine karşılık gelen çap değerleridir (cm). Derin öğrenme algoritmalarında, çok sayıda farklı katman ve nöron sayıları ile transfer fonksiyonu seçenekleri söz konusudur. Bu çalışmada, nöron sayısı sabit tutulmuş ve 100 olarak seçilmiş olup, ayrıca transfer fonksiyonu da “*Rectifier*” fonksiyonu esas alınmıştır. Derin öğrenmenin en temel özelliği olan gizli katman (hidden layer) sayısı için de, 3 katman sayısından (derin öğrenme algoritmasının minimum katman sayısı) 10 katman sayısına olmak üzere 8 farklı (3, 4, 5, 6, 7, 8, 9 ve 10 katmanlı) katman sayıları seçeneği ile veri eğitimi gerçekleştirilmiş, çap basamaklarına karşılık gelen ağaç sayılarının tahmin sonuçlarının başarı durumları karşılaştırılmıştır.

Derin öğrenme algoritması ile tahminlerin elde edilmesinde diğer bir önemli konu da, eğitimde ve denetimde kullanılacak verilerin ayrılması yöntemi

olup; “k sayısı kadar çapraz doğrulama” (K-Fold Cross Validation) yöntemi, eğitim sürecinin başında %75 eğitim-%25 test verisi ayırımını esas alan basit yaklaşıma göre, veri ayırmada oluşabilecek hataları en az indirgeyebilmektedir. H₂O paketi, “nfolds” alt seçeneği ile “k sayısı kadar çapraz doğrulama” yöntemi, eğitim sürecine katılabilmektedir. Bu çalışmada da, “k sayısı kadar çapraz doğrulama” yöntemi, “nfolds” seçeneği, en çok tercih edilen değer olan 5 değeri esas alınarak (nfolds=5) uygulanmıştır.

2.3. Derin öğrenme algoritma tahminlerinin simülasyonu ve denetlenmesi

Yapay zeka uygulamaları ile eğitim süreçlerinde söz konusu olabilecek önemli bir sorunda, ağın verileri ezberlemesi ve eğitimin tam olarak sağlanamaması ve ağın belirli girdi değişkenlere tesadüfi değerler atamasıdır. Bu problemin denetlenme süreci de; ağın eğitiminde kullanılmamış bir veri seti için tahminlerin elde edilmesi (simülasyonların) ve bu tahmin değerleri ile gözlem değerleri arasındaki farkın test edilmesi ile yapılabilmektedir. Bu çalışmada da, verilerin eğitiminde kullanılmamış olan 24 örnek alan verisi için derin öğrenme algoritması ile tahminler elde edilmiş ve bu örnek alanlar için derin öğrenme algoritmasına dayanan ağın simülasyonu gerçekleştirilmiştir. Söz konusu bu simülasyona ilişkin tahmin değerleri ile gözlem değerleri arasındaki fark test edilmesinde ise, “Eşleştirilmiş İki Örnek Testi (Paired t test)” kullanılmıştır. Bu örnek alanların farklı çap sınıfları için gözlemlenen ağaç sayıları ile en başarılı olarak belirlenen derin öğrenme algoritması kullanılarak tahmin edilen ağaç sayıları arasında, istatistiksel olarak bir farklılık olmaması durumunda (p>0.05); ağın ezberlemesi probleminin olmadığı ve ağın etkin ve doğru tahminler verebildiği sonucuna varılır. Bununla birlikte gözlemlenen ve ağ tarafından tahmin edilen ağaç sayıları arasında istatistiksel olarak anlamlı bir fark olması durumunda ise (p<0.05); derin öğrenme algoritmasının doğru tahminler sunamadığı sonucuna varılabilir.

2.4. Karşılaştırma ölçütleri

Bu çalışmada, çap dağılımının çeşitli yüzdelik değerlerini kullanan 3 parametrelili Weibull olasılık yoğunluk fonksiyonu ile farklı katman sayılarına sahip derin öğrenme algoritmalarına dayanan yapay zeka ile tahminler elde edildikten sonra, farklı yöntemler ile elde edilecek tahminlerin başarı durumlarının karşılaştırılmasında istatistiki ölçüt değerleri kullanılmıştır. Bu başarı ölçütleri ise;

Düzeltilmiş Belirtme Katsayısı (R^2_{adi}), Akaike Bilgi Ölçütü (AIC), Schwarz'ın Bayesian Bilgi Ölçütü (SBC), Hataların Ortalama Kare Kökü (the root

mean square error, RMSE) değeri olmak üzere dört adettir. Kullanılan bu ölçütlere ilişkin formüller aşağıda verilmiştir.

$$\text{Düzeltilmiş Belirtme Katsayısı } (R^2_{düz.}) = 1 - \frac{HKT \cdot (n-1)}{YAKT \cdot (n-p)} \quad (3)$$

$$\text{Akaike Bilgi Ölçütü } (AIC) = n \cdot \ln\left(\frac{HKT}{n}\right) + 2k \quad (4)$$

$$\text{Schwarz'ın Bayesian Bilgi Ölçütü } (SBC) = n \cdot \ln\left(\frac{HKT}{n}\right) + k \cdot \ln(n) \quad (5)$$

$$\text{Hataların Ortalama Kare Kökü } (RMSE) = \sqrt{\frac{HKT}{n-k}} \quad (6)$$

3. Bulgular

Bu formüllerde, HKT; regresyon dışı kareler toplamı olup, gözlem değerinden farklı yöntemler ile elde edilen tahmin değerlerinin çıkarılması ile elde edilen model hatalarının karesi olarak hesaplanmıştır. YAKT ise; Y ayrılış kareler toplamı olup, gözlem değerinden gözlem değerlerine ilişkin ortalama değerinin çıkarılması elde edilen farkın karesi alınarak hesaplanmıştır. Formüllerdeki k değeri; tahminlerde kullanılan girdi değişken sayısını, n; veri sayısını göstermektedir. Bu ölçüt değerlerinden, 0 ile 1 arasında değer alan belirtme katsayısının, mümkün olduğunca 1'e yakın bir değer alması istenilmektedir. Diğer ölçüt değerlerinin küçük değerler alması, daha başarılı tahminlerin elde edildiğini göstermektedir.

Çizelge 2'de, bu çalışmada kullanılan 3 parametrelili Weibull fonksiyonun parametrelerinin dağılımın yüzde değerleri ile hesaplanmasına ilişkin 4 farklı eşitlik için elde edilen başarı ölçütleri görülmektedir. Bu ölçüt değerlerinden HKT; 6126730 ile 8841762, RMSE; 67.5172 ile 81.0790, $R^2_{düz.}$; 0.4864 ile 0.6121, AIC; 11351.16 ile 11843.27 ve SBC; 11366.77 ile 11853.68 arasında değişmektedir. Bu başarı ölçütleri değerlendirildiğinde; meşcerelerin çap dağılımlarını modellemeye en başarılı formül olarak; %25, %50 ve %95'lik değerleri esas alan eşitlikler belirlenmiştir (Çizelge 2). %25, %50 ve %95'lik değerleri esas alan eşitlikler ile 3 parametrelili Weibull fonksiyonun parametrelerinin hesaplanmasına ilişkin yöntemin HKT değeri; 6126730, RMSE değeri; 67.5172, $R^2_{düz.}$ değeri; 0.6121, AIC değeri; 11351.16 ve SBC değeri ise; 11366.77 olarak hesaplanmıştır.

Çizelge 2. 3 parametrelili Weibull fonksiyonun parametrelerinin farklı yüzdelik değerlere göre hesaplanmasına ilişkin başarı ölçüt değerleri.

Parametre Tahmin Yöntemleri	HKT	RMSE	$R^2_{düz.}$	AIC	SBC
%50 ve %95'lik değerleri esas alan eşitlikler	7201437	73.1726	0.5444	11566.86	11577.27
%25, %50 ve %95'lik değerleri esas alan eşitlikler	6126730	67.5172	0.6121	11351.16	11366.77
%31, %50 ve %63'lük değerleri esas alan eşitlikler	8111988	77.6898	0.4864	11729.24	11744.85
%31 ve %63'lük değerleri esas alan eşitlikler	8841762	81.0790	0.4406	11843.27	11853.68

Bu çalışmada, çap dağılımının modellenmesinde en başarılı olarak belirlenen %25, %50 ve %95'lik değerleri ile örnek alanlarının toplam hektardaki ağaç sayıları (hektarda) ve çap basamağı orta değerlerini; girdi değişkenleri, ilgili çap basamağında bulunan hektardaki ağaç sayılarını da çıktı değişkeni esas alarak derin öğrenme algoritması ile eğitim süreçleri farklı katman sayıları için gerçekleştirilmiştir. Çizelge 3'te, derin öğrenme algoritmasına ilişkin farklı katman sayıları için çeşitli başarı ölçüt değerleri verilmiştir. Bu ölçüt değerlerinden HKT; 1286083 ile 1822275, RMSE;

30.9570 ile 36.8494, $R^2_{düz.}$; 0.8844 ile 0.9184, AIC; 9252.41 ile 9721.82 ve SBC; 9278.44 ile 9747.85 arasında değişim göstermektedir. Bu ölçüt değerleri değerlendirildiğinde, çap dağılımlarını modellemeye en başarılı yapay zeka uygulaması, 5 katmanlı derin öğrenme algoritması olarak belirlenmiştir. Bu derin öğrenme algoritmasına ilişkin yöntemin HKT değeri; 1286083, RMSE değeri; 30.9570, $R^2_{düz.}$ değeri; 0.9184, AIC değeri; 9252.41 ve SBC değeri ise; 9278.44 olarak elde edilmiştir.


Çizelge 3. Derin öğrenmeye ilişkin farklı katman sayıları için hesaplanan başarı ölçüt değerleri.

Derin Öğrenme Katman Sayısı	HKT	RMSE	$R^2_{düz.}$	AIC	SBC
3 katman	1822275	36.8494	0.8844	9721.82	9747.85
4 katman	1761953	36.2344	0.8883	9676.47	9702.50
5 katman	1286083	30.9570	0.9184	9252.41	9278.44
6 katman	1384147	32.1155	0.9122	9351.39	9377.42
7 katman	1326290	31.4371	0.9159	9293.88	9319.90
8 katman	1656492	35.1333	0.8950	9593.34	9619.36
9 katman	1392241	32.2093	0.9117	9359.24	9385.27
10 katman	1425038	32.5864	0.9096	9390.61	9416.64

Bu çalışmada, ağ ile elde edilen tahminleri denetlemek için; 5 katmanlı derin öğrenme algoritması ile ağın eğitiminde kullanılmamış olan 24 adet örnek alan verisi için tahminler elde edilmiştir. Bu tahmin değerleri ile gözlem değerleri arasındaki farka ilişkin “Eşlendirilmiş İki Örnek Testi (Paired t test)” sonucunda; veri sayısı $n=240$ olup, ortalama fark $\bar{D}=-6.0872$, farka ilişkin standart sapma $S_D=68.2109$, t hesap değeri $t=-1.383$, $p=0.168$ olarak hesaplanmış olup, bu örnek alanların farklı çap basamaklarındaki gözlemlenen ağaç sayıları ile 5 katmanlı derin öğrenme algoritması ile tahmin

edilen ağaç sayıları arasında % 95 güvenle anlamlı bir farklılık belirlenmemiştir.

Bu çalışmada çap dağılımlarını modellemede en başarılı olarak belirlenen 5 katmanlı derin öğrenme algoritması kullanılarak, çalışma kapsamındaki 2 örnek alan için farklı çap basamaklarındaki tahmini ağaçları elde edilmiş ve bu örnek alanların farklı çap basamaklarındaki gözlemlenen ve tahmin edilen çap dağılımları Şekil 1’de verilmiştir. Bu şekil incelendiğinde, 5 katmanlı derin öğrenme algoritması ile önemli ölçüde gözlemlenen çap dağılımlarına benzer değişimler elde edildiği görülmektedir.



Şekil 1. İki örnek alan için 5 katmanlı derin öğrenme algoritması ile tahmin edilen çap dağılımları ile aktüel çap dağılımlarını karşılaştırmalı gösteren grafik.

4. Tartışma ve sonuç

Bu çalışmada, yapay zekanın bir uygulaması olan derin öğrenme algoritmalarının çap dağılımlarının modellenmesinde kullanılabilirliği araştırılmıştır. Bu amaçla, Trabzon ve Giresun Orman Bölge Müdürlüklerinde yayılış gösteren Doğu Ladini-Sarıçam karışık meşcerelerinden Ercanlı (2010) tarafından alınmış 161 örnek alan verisi kullanılmıştır. Örnek alanların çap dağılımlarını modellemek üzere 3 parametrelili Weibull olasılık yoğunluk fonksiyonlarının parametreleri, dağılımın yüzdeliklerini esas alan bir eşitliklerle hesaplanmış, parametreleri bu eşitlikler ile elde edilen bu fonksiyon kullanarak tahmini çap dağılımları elde edilmiştir. Elde edilen bu tahminlerin başarı durumları, çeşitli başarı ölçütlerine göre karşılaştırılmış, en başarılı olarak da; çap dağılımın

%25, %50 ve %95’lik yüzdelik değerleri ile fonksiyon parametrelerini hesaplayan eşitlik belirlenmiştir. Bu eşitlik ile parametreleri hesaplanan 3 parametrelili Weibull fonksiyonuna ilişkin HKT değeri; 6126730, RMSE değeri; 67.5172, $R^2_{düz.}$ değeri; 0.6121, AIC değeri; 11351.16 ve SBC değeri ise; 11366.77 olarak elde edilmiştir. Yapay zekâ uygulaması olan derin öğrenme algoritmalarına ilişkin 8 farklı katman (3, 4, 5, 6, 7, 8, 9, 10 katman seçenekleri) seçeneği, çeşitli başarı ölçüt değerlerine göre karşılaştırılmış, HKT değeri; 1286083, RMSE değeri; 30.9570, $R^2_{düz.}$ değeri; 0.9184, AIC değeri; 9252.41 ve SBC değeri ise; 9278.44 olarak elde edilen 5 katmanlı derin öğrenme algoritması, çap dağılımını modellemede en başarılı derin öğrenme algoritması olarak belirlenmiştir. Çap dağılımı modellenmesinde, istatistik yöntemlerden en çok tercih edilen ve başarılı sonuçlar veren 3 parametrelili Weibull olasılık

yoğunluk fonksiyonu ile bir yapay zeka uygulaması olan derin öğrenme algoritmalarının çap dağılımlarını modellemesine ilişkin sonuçlar karşılaştırıldığında; derin öğrenme algoritmalarının, 3 parametrelili Weibull olasılık yoğunluk fonksiyonuna göre oldukça başarılı sonuçlar verdiği görülmektedir. Özellikle, 3 parametrelili Weibull olasılık yoğunluk fonksiyonuna göre derin öğrenme ile HKT değerinde; 6126730 değerinden 1286083 değerine azalış (% 79.01 azalış), RMSE değerinde; 67.5172 değerinden 30.9570 değerine azalış (% 54.15 azalış), $R^2_{düz.}$ değerinde; 0.6121 değerinden 0.9184 değerine artış (% 30.63 artış), AIC değerinde; 11351.16 değerinden 9252.41 değerine azalış (% 18.49 azalış) ve SBC değerinde; 11366.77 değerinden 9278.44 değerine azalış (% 18.37 azalış) elde edilmiştir. Bu değerler değerlendirildiğinde, derin öğrenme algoritmaları ile orman meşcerelerinin çap dağılımının modellenmesinde önemli başarı artışları ve iyileşmeleri elde edilmiştir. Benzer iyileşmeler, ülkemizde yapay sinir ağları konusunda yapılan Özçelik et al. (2008), Diamantopoulou and Özçelik (2012), Özçelik et al. (2013), Özçelik et al. (2014), Diamantopoulou et al. (2015), Ercanlı vd. (2015), Şenyurt vd. (2015), Bolat (2015b), Ercanlı vd. (2016), Bolat ve Ercanlı (2016), Ercanlı vd. (2016), Günlü ve Ercanlı (2017), Ercanlı ve Bolat (2017), Ercanlı vd. (2018) çalışmalarda ve dünyada yapılan birçok çalışmada da elde edilmiştir. Yapı olarak yapay sinir ağlarının daha ötesinde kompleks bir yapıya sahip olan derin öğrenme algoritmalarının uygulandığı bu çalışmada, klasik olasılık yoğunluk fonksiyonlarına çap dağılımlarının modellenmesinde başarı artışları ve iyileşmeler belirgindir. Bu başarılı sonuçlar, derin öğrenme algoritmasının oldukça kompleks ve nonlinear yapısı ile orman meşcerelerinin farklı çap dağılımlarını başarılı temsil kabiliyeti ile açıklanabilir. 5 katmanlı derin öğrenme algoritmasında, 5 katmanda 100 nörondan oluşan oldukça fazla sayıda ağırlık (weights) değeri kullanılmakta olup, bu kompleks ağ yapısı, derin öğrenmeye farklı veri yapılarını başarıyla modelleyebilme kabiliyeti kazandırmaktadır. Böylece derin öğrenme algoritmaları, klasik regresyon modelleriyle zor ve mümkün olmayan tahmin başarılarının elde edilmesi mümkün olabilmektedir. Derin öğrenme algoritmasına modellemede başarılı sonuçlar elde edilmesine imkan veren bu kompleks ağ yapısı, derin öğrenme algoritmasının anlaşılmasını ve uygulanmasını zorlaştırabilmektedir. Genel olarak, çalışmalarda denklem yapıları verilebilen istatistiksel fonksiyonların basit yapıları yanında, 5 katmanda 100'er adet ağırlık değerleri gibi çok sayıda ağırlık değerine sahip olan derin öğrenme algoritmasının denklem yapısının verilmesi ve elle

hesaplamaları içeren uygulamaların yapılması mümkün değildir. Bu bakımdan, derin öğrenme algoritmalarının uygulamaları, ancak çeşitli bilgisayar yazılımları ve programları ile mümkün olup, günümüz bilgisayar çağında yaşadığımız göz önüne alındığında, bunun da çok zor olmadığı açıktır.

Bu çalışmada çap dağılımlarının modellenmesinde başarıyla uygulanan derin öğrenme algoritmalarının, meşcere hacmi, göğüs yüzeyi, biyokütlesi ve karbonu gibi diğer meşcere özellikleri ile çap, boy, hacim ve artımı gibi tek ağaç özelliklerinin tahminindeki başarı durumları da araştırılması gerekmektedir. Yeni bir yöntem olarak ormancılık literatürüne giren bir yapay zeka uygulaması derin öğrenmenin, meşcere ve tek ağaç özelliklerinin tahmininde, klasik istatistik yöntemlerine karşı bir alternatif olarak değerlendirilmesine ilişkin farklı çalışmaların gerçekleştirilmesi önemli bir ihtiyaç olarak karşımıza çıkmaktadır. Ayrıca yapay zeka ile elde edilecek tahminlerin, belirli ölçüt değerlerine göre başarı durumları yanında, ormancılık uygulamalarında önemli olan büyüme kanuniyetleri bakımından değerlendirilmesi de önemli olmaktadır.

Kaynaklar

- Andrasev, S., Bobinac, M., Orlovic, S. 2009. Diameter structure models of Black Poplar selected clones in the section Aigeiros (Duby) obtained by the Weibull distribution. Sumarski List 133, 589-603
- Atıcı, E. 1998. Değişikyaşlı Doğu Kayını (*Fagus orientalis* Lipsly.) Ormanlarında Artım ve Büyüme, Doktora Tezi, İstanbul Üniversitesi. İstanbul Üniveristesi Fen Bilimleri Enstitüsü, İstanbul.
- Bailey, R. L., Dell, T. R. 1973. Quantifying Diameter Distributions with The Weibull Functio. Forest Science, 19, 97-104.
- Bailey, R. L., Burgan, T. M., Jokela, E. J. 1989. Fertilized mid-rotation aged slash pine plantations—Stand structure and yield prediction models. South. J. Appl. For. 13, 76-80.
- Baldwin, V. C., Feduccia, D. P. 1987. Loblolly pine growth and yield prediction for managed West Gulf plantations. USDA For. Serv. Res. Pap. SO 236, 27 p.
- Bolat F. 2015a. Bursa-Kestel Orman İşletme Şefliği içerisindeki meşcereler için çap dağılım modellerinin geliştirilmesi. Yüksek Lisans Tezi, Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü, 77 s.
- Bolat, F. 2015b. Predictions for Oriental Beech Tree Heights Based on Artificial Neural Network in Kestel Forests, The 10th International Beech Symposium, 1-6 September, 2015, Kastamonu, Turkey.
- Bolat, İ., Ercanlı, İ. 2016. Using Artificial Neural Network in Describing Diameter Distribution in an Even-Aged Forest. International Forestry Symposium, 7-10 December 2016, Kastamonu-Turkey

- Burkhardt, H. 1995. Modeling Forest Growth. *Encyclopedia of Environmental Biology*, 2, 535-543.
- Čavlović, J., Božić, M., Boncina, A. 2006. Stand Structure of an Uneven-Aged Fir–Beech Forest with an Irregular Diameter Structure: Modeling The Development of The Belevine Forest, Croatia. *European Journal of Forest Research*, 125, 4, 325-333.
- Cao, Q. V. 2004. Predicting Parameters of A Weibull Function for Modeling Diameter Distribution. *Forest Science*, 50, 682 – 685.
- Carranza-Rojas, J., Goeau, H., Bonnet, P., Mata-Montero, E., Joly, A. 2017. Going deeper in the automated identification of Herbarium specimens. *BMC Evol. Biol.* <http://dx.doi.org/10.1186/s12862-017-1014-z>.
- Carus, S. 1996. Aynı Yaşlı Doğu Kayını (*Fagus orientalis* Lipsly.) Meşcerelerinde Çap Dağılımın Bonitet ve Yaşa Göre Değişimi. *İstanbul Orman Fakültesi Dergisi*, 46, 171-181.
- Carus, S., Çatal, Y. 2008. Kızılcım (*Pinus brutia* Ten.) Meşcerelerinde 7-Ağaç Örnek Nokta Yöntemiyle Meşcere Ağaç Sayısının Çap Basamaklarına Dağılımının Belirlenmesi. *Süleyman Demirel Üniversitesi, Orman Fakültesi Dergisi*, 2, 158-169.
- Clutter, J. L., Bennett, F. A. 1965. Diameter Distributions in Old-Field Slash Pine Plantation. *Georgia Forest Research Council, Report No.13*.
- Clutter, J. L., Harms, W. R., Brister, G. H., Rhenney, J. W. 1984. Stand structure and yields of site-prepared loblolly pine plantations in the lower coastal plain of the Carolinas, Georgia, and North Florida. *USDA For. Serv. Gen. Tech. Rep. SE-27*, 173 p.
- Doğdaş, İ. 2014. Burdur-Ağlasun yöresi kızılçım (*Pinus brutia* Ten.) ormanlarında meşcere ağaç sayısı, hacim ve hacim artımının çap basamaklarına dağılımının modellenmesi. Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü 98s, Isparta.
- Diamantopoulou, M. J., Özçelik, R. 2012. Evaluation of different modeling approaches for total tree-height estimation in Mediterranean Region of Turkey. *Forest Systems*, 21, 3, 383-397.
- Diamantopoulou, M. J., Özçelik, R., Crecente-Campo, F., Eler, Ü. 2015. Estimation of Weibull function parameters for modeling tree diameter distribution using least squares and artificial neural networks methods. *Biosystem engineering*, 133, 33-45.
- Ercanlı, İ. 2010. Trabzon ve Giresun orman bölge müdürlükleri sınırları içerisinde yer alan Doğu Ladini (*Picea orientalis* (L.) Link)-Sarıçım (*Pinus sylvestris* L.) Karışık meşcerelerine ilişkin büyüme modelleri, Doktora Tezi, K.T.Ü., Fen Bilimleri Enstitüsü, Trabzon.
- Ercanlı İ., Bolat F., Kahrıman A. 2013. Comparing parameter recovery methods for diameter distribution models of Oriental spruce (*Picea orientalis* (L.) Link.) and Scotch pine (*Pinus sylvestris* L.) mixed stands located Trabzon and Giresun Forest Regional Directorate. *International Caucasian Forestry Symposium (24-26 October)*, 119-126, Artvin, Turkey.
- Ercanlı, İ., Kahrıman, A., Bolat, F. 2015. Applications of Artificial Neural Network for Predicting The Relationships Between Height And Age For Oriental Beech. *The 10th International Beech Symposium*, 1-6 September, 2015, Kastamonu, Turkey.
- Ercanlı, İ., Günlü, A., Şenyurt, M., Bolat, F., Kahrıman, A. 2016a. Artificial neural network for predicting stand carbon stock from remote sensing data for even-aged scots pine (*pinus sylvestris* l.) Stands in the taşköprü-çiftlik forests. *1st International Symposium of Forest Engineering and Technologies (FETEC 2016)*, Bursa Technical University, Faculty of Forestry, 2-4 June 2016, Bursa-TURKEY.
- Ercanlı, İ., Kahrıman, A., Yavuz, H. 2016b. Predicting Oriental Spruce and Scots Pine Tree Diameter Increments Based on Artificial Neural Network Located in Mixed Oriental Spruce-Scots Pine Stands at Trabzon and Giresun Forest District. *International Forestry Symposium*, 7-10 December 2016, Kastamonu-Turkey
- Ercanlı, İ., Bolat. 2017. Diameter distribution Modeling based on Artificial Neural Networks for Kunduz Forests. *International Symposium on New Horizons in Forestry-ISFOR 2017*, Isparta University, Faculty of Forestry, 18-20 October, Isparta, Turkey.
- Ercanlı, İ., Günlü, A., Şenyurt, M., Keleş, S. 2018. Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey. *Forest Ecosystems*, 5-29.
- Feduccia, D. P., Dell, T. R., Mann, W. F., Polmer, B. H. 1979. Yields of unthinned loblolly pine plantations on cutover sites in the West Gulf region. *USDA For. Serv. Res. Pap. So-148*, 88 p.
- Gadow, K. V., Hui, G.Y. 1999. *Modeling Forest Development*. Kluwer Academic Publishers, Dordrecht, 213 p.
- Garcia, O. 2001. Growth and Yield in British Columbia Background and Discussion. *University of Northern British Columbia General Technical Report*, 88 p.
- Günlü, A., Ercanlı, İ. 2017. Evaluating some artificial neural networks and multiple linear regression model for predicting carbon of pure oriental beech stand in Göldağ forests. *International Symposium on New Horizons in Forestry-ISFOR 2017*, Isparta University, Faculty of Forestry, 18-20 October, Isparta, Turkey.
- Güneş, S. 2015. Isparta yöresi Kızılcım meşcerelerinde çap dağılımının örnek nokta ağaç sayısına göre modellenmesi. Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, 85 s.
- Gorgoso-Varela, J. J., Alvarez-Gonzalez, J. G., Rojo, A., Grandas-Arias, J. A. 2007. Modelling diameter distributions of *Betula alba* L. stands in northwest Spain with the two-parameter Weibull function. *Invest. Agrar. Sist. Recur. For.* 16: 113-123.
- Hafley, W. L., Schreuder, H. T. 1977. Statistical distributions for fitting diameter and height data in even-aged stands. *Canadian Journal Forest Research*, 7, 481–487.
- H2O.ai Team., 2018. H2O documentation, URL: <http://docs.h2o.ai>
- Jiang, L. C., Brooks, J. R. 2009. Predicting diameter distributions for young longleaf pine plantations in Southwest Georgia. *South. J. Appl. For.* 33: 25-28.

- Kahrıman, A., Yavuz, H. 2011. Sarıçam (*Pinus sylvestris* L.)-Doğu Kayını (*Fagus orientalis* Lipsky) Karışık Meşcerelerinde Çap Dağılımlarının Olasılık Yoğunluk Fonksiyonları ile Belirlenmesi. Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi, 12, 2, 109-125.
- Karakaş R. 2013. Önsen doğal Fıstıkçamı (*Pinus pinea* L.) meşcerelerinde çap dağılımlarının modellenmesi. Yüksek Lisans Tezi, Kahramanmaraş Sütcü İmam Fen Bilimleri Enstitüsü, 67s.
- Knoebel, B. R., Burkhart H. E., Beck, D. E., 1986. A Growth and Yield Model for Thinned Stands of Yellow-Poplar. Forest Science Monograph, 27, 39 p.
- Knowe, S. A. 1992. Basal Area and Diameter Distribution Models for loblolly Pine Plantations with Hardwood Competition in The Piedmont and Upper Coastal Plain. South. J. Appl. For., 16, 93-98.
- Knowe, S. A., Ahrens, G. A., DeBell, D. S. 1997. Comparison of diameter-distribution prediction, stand-table -projection and individual-tree growth modeling approaches for young red alder plantations. Forest Ecology and Management, 96, 207-216.
- LeCun, Y., Bengio, Y., Hinton, G. 2015. Deep learning. Nature 521, 436-444.
- Liu, C., Zhang, S. Y., Lei, Y., Newton, P. F., Zhang, L., 2004. Evaluation of Three Methods for Predicting Diameter Distributions of Black Spruce (*Picea Mariana*) Plantations in Central Canada. Canadian Journal of Forest Research, 34, 2424 - 2432.
- Lohrey, R. E., Bailey, R. L. 1977. Yield tables and stand structure for unthinned long leaf pine plantations in Louisiana and Texas. USDA For. Ser. Res. Pap. SO-133. 55 p.
- Maltamo, M., 1997. Comparing basal area diameter distributions estimated by tree species and for the entire growing stock in a mixed stand. Silva Fennica, 31, 1, 53-65.
- Maltamo, M., Puumalainen, J., Paivinen, R. 1995. Comparison of Beta and Weibull Functions for Modeling Basal Area Diameter Distributions in Stands of *Pinus Sylvestris* and *Picea Abies*. Scandinavian Journal of Forest Research, 10, 184-295.
- Matney, T. G., Sullivan, A. D. 1982. Compatible Stand and Stock Tables for Thinned and Unthinned Loblolly Pine Stands. Forest Science, 28, 161-171.
- Nord-Larsen, T., Cao, Q. V. 2006. A Diameter Distribution Model for Even-Aged Beech in Denmark. Forest Ecology and Management, 231, 218-225.
- Özçelik, R., Diamantopoulou, M.J., Wiant, H. R., Brooks, J. R. 2008. Comparative study of standard and modern methods for estimating tree bole volume of three species in Turkey. Forest Products Journal, 58, 6, 73-81.
- Özçelik, R., Diamantopoulou, M. J., Crecente-Campo, F., Eler, U. 2013. Estimating Crimean juniper tree height using nonlinear regression and artificial neural network models. Forest Ecology and Management 306, 52-60.
- Özçelik, R., Diamantopoulou, M. J., Brooks, J. R. 2014. The use of tree crown variables in over-bark diameter and volume prediction models. iForest-Journal of Biogeosciences and Forestry, 7:132-139.
- Packard, K. C., 2000. Modeling Tree Diameter Distributions for Mixed-Species Conifer Forests in the Northeast United States. Master Thesis, State University of New York, New York, USA., 129 p.
- Palahi, M., Pukkala, T., Trasobares, A. 2006. Calibrating Predicted Tree Diameter Distributions in Catalonia (Spain). Silva Fennica, 40, 3, 487-500.
- Palahi, M., Pukkala, T., Trasobares, A. 2007. Modeling The Diameter Distribution of *Pinus sylvestris*, *Pinus nigra* and *Pinus halepensis* Forest Stands in Catalonia Using the Truncated Weibull Function, Forestry, 79, 5, 553-562.
- Podlaski R. 2006. Suitability of The Selected Statistical Distributions for Fitting Diameter Data in Distinguished Development Stages and Phases of Near-Natural Mixed Forests in The Świątokrzyski National Park (Poland). Forest Ecology and Management, 236, 393-402
- Poudel, K. P. 2011. Evaluation of methods to predict Weibull parameters for characterizing diameter distributions, MSc. Graduate Faculty of the Louisiana State University and Agricultural and Mechanical College, 60 p.
- Poudel, K. P., Cao, Q. V. 2013. Evaluation of methods to predict Weibull parameters for characterizing diameter distributions. Forest Science, 59, 2, 243-252.
- Pukkala, T., Saramaki, J., Mubita, O., 1990. Management Planning System for Tree Plantations; A Case Study for *Pinus Kesiya* in Zambia. Silva Fennica, 24, 171-180.
- Rennolls, K., Geary, D. N., Rollinson, T. J. D. 1985. Characterizing Diameter Distributions by The Use of The Weibull Distribution. Forestry, 58, 58-66.
- Saraçoğlu, Ö. 1988. Karadeniz Yöresi Göknaar Meşcerelerinde Artım ve Büyüme. O. G. M. Yayınları, No: 25, 312.
- Saramäki J. 1992. A growth and yield prediction model of *Pinus kesiya* (Royle ex Gordon) in Zambia. Acta Forestalia Fenica 230, 68 p.
- Smalley, G. W., Bailey, R. L. 1974. Yield Tables and Stand Structure for Shortleaf Pine Plantations in The Tennessee, Alabama and Georgia Highlands. USDA Forest Service Research Paper, 97 p.
- SPSS Institute Inc. 2005. SPSS Base 12.0 User's Guide, 688 p.
- Sönmez, T., Günlü, A., Karahalil, U., Ercanlı, İ., Şahin, A. 2010. Saf Doğu Ladini Meşcerelerinde Çap Dağılımının Modellenmesi, "III. Ulusal Karadeniz Ormançılık Kongresi Bildiriler Kitabı. 20-22 Mayıs 2010, Artvin", Cilt: I, 388-398
- Şenyurt, M., Ercanlı, İ., Yavuz, H., Kahrıman, A. 2015. Predicting Stand Yield Parameters Based On Artificial Neural Network for Oriental Beech in Kestel Forests, Bursa. The 10th International Beech Symposium, 1-6 September, 2015, Kastamonu, Turkey.
- van Laar A., Akça A. 2007. Forest mensuration: in Managing Forest Ecosystems, Dordrecht, The Netherlands: Springer. 383 p.
- Yavuz, H. 1992. Değişik Yaşlı Meşcerelerde Büyümenin Markov Zincirleri Yöntemi ile Analiz Edilmesi. Doktora Tezi, K.T.Ü Fen Bilimleri Enstitüsü, Trabzon, 230 s.

Yavuz, H., Gül, A. U., Mısır, N., Özçelik, R., Sakıcı, O. E. 2002. Meşcerelerde Çap Dağılımlarının Düzenlenmesi ve Bu Dağılımlara İlişkin Parametreler ile Çeşitli Meşcere Ögeleri Arasındaki İlişkilerin Belirlenmesi. Orman Amenajmanında Kavramsal Açılımlar ve Yeni Hedefler Sempozyumu, 18-19 Nisan İstanbul.

Zhang, L., Liu, C. 2006. Fitting Irregular Diameter Distributions of Forest Stands by Weibull, Modified Weibull and Mixture Weibull Models. Journal Forest Research, 11, 369-372.