

**ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**ÇAP DAĞILIMLARININ DERİN ÖĞRENME ALGORİTMALARI İLE
MODELLENMESİ: ILGIN (KONYA) YÖRESİ ANADOLU KARAÇAMI
MEŞCERELERİ ÖRNEĞİ**

Ömer Faruk ORHAN

ORMAN MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI

2025

Her hakkı saklıdır

TEZ ONAYI

Ömer Faruk ORHAN tarafından hazırlanan “Çap Dağılımlarının Derin Öğrenme Algoritmaları ile Modellenmesi: Ilgın (Konya) Yöresi Anadolu Karaçamı Meşcereleri Örneği” adlı tez çalışması 09.05.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalında **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman : Prof. Dr. İlker ERCANLI

Jüri Üyeleri :

Başkan : Prof. Dr. İlker ERCANLI
Orman Mühendisliği Anabilim Dalı
Çankırı Karatekin Üniversitesi

Üye : Doç. Dr. Muammer ŞENYURT
Orman Mühendisliği Anabilim Dalı
Çankırı Karatekin Üniversitesi

Üye : Doç. Dr. Oytun Emre SAKICI
Orman Mühendisliği Anabilim Dalı
Kastamonu Üniversitesi

Yukarıdaki sonucu onaylarım

Prof. Dr. Ersoy YILMAZ

Enstitü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğine göre hazırlamış olduğum **“Çap Dağılımlarının Derin Öğrenme Algoritmaları ile Modellenmesi: Ilgın (Konya) Yöresi Anadolu Karaçamı Meşcereleri Örneği”** konulu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, tezin Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü’nden başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve bu çalışmanın Çankırı Karatekin Üniversitesi tarafından kullanılan “Bilimsel İntihal Tespit Programı”yla tarandığını, “intihal içermediğini” beyan ederim. Çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması halinde ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm. Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim (09/05/2025).

Ömer Faruk ORHAN

ÖZET

Yüksek Lisans Tezi

ÇAP DAĞILIMLARININ DERİN ÖĞRENME ALGORİTMALARI İLE MODELLENMESİ: ILGIN (KONYA) YÖRESİ ANADOLU KARAÇAMI MEŞCERELERİ ÖRNEĞİ

Ömer Faruk ORHAN

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Orman Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. İlker ERCANLI

Bu çalışmada, Ilgın Orman İşletme Müdürlüğü sınırları içerisinde yayılış gösteren Anadolu Karaçamı meşcerelerinin çap dağılımlarının bir yapay zeka tekniği olan Derin Öğrenme Algoritmaları ile modellenmesi amaçlanmıştır. Konya Bölge Müdürlüğü, Ilgın Orman İşletme Müdürlüğü sınırları içerisinde yer alan Ilgın, Akşehir ve Aşağıçığıl Orman İşletme Şefliklerinde yayılış gösteren saf Anadolu Karaçamı meşcerelerden alınmış 408 adet örnek alan verisi kullanılarak, 3 Parametrelili Weibull ve 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonlarının parametreleri, maksimum olabilirlik yöntemi, çap dağılımlarının çeşitli yüzdelik ve moment değerleri ile bu moment ve yüzdelikleri birlikte içeren hibrid yöntemleri esas alan eşitliklere dayanan yöntemler ile hesaplanmıştır. Derin Öğrenme Algoritması (DÖA) olarak hiperbolik tanjant sigmoid tipinde aktivasyon tipi ve 100 adet nöron sayısı sabit tutulup; 3, 5, 7 ve 10 gizli katman seçenekleri olmak üzere 4 farklı gizli (ara) katman sayısı seçeneği ile birlikte aşırı uyum soruna bir çözüm olarak değerlendirilebilen 3 farklı hiper-parametre (öğrenme oranı, moment oranı ve erken durdurma) çeşidi değerlerinin özelleştirilmesini içerecek şekilde DÖA modellerinin eğitimleri gerçekleştirilmiştir. DÖA modellerinin çap dağılımlarında kullanımı değerlendirildiğinde; en başarılı olarak belirlenen %31 ve %63'lük yüzdelik değerleri ile parametreleri hesaplanan 3 parametreli Weibull olasılık yoğunluk fonksiyonunun OMH değeri, 41.701 adet/ha; HKOK değeri, 57.486 adet/ha; HKOK% değeri, % 55.481; R^2 değeri, 0.701; AIC değeri, 9590 ve BIC değeri, 11226 olarak elde edilmişken; en başarılı olarak belirlenen 7 ara katmana sahip 0.001 değeri ile Moment oranı (Moment rate) hiper-parametre özelleştirmesini içeren DÖA modelinin HKOK değerinin, 49.193 adet/ha; HKOK% değerinin, % 47.628; R^2 , 0,784; AI değerinin; 1905 ve BIC değerinin; 2239 olarak elde edildiği görülmektedir. Bu bakımdan, çap dağılımlarını modellemesinde Derin Öğrenme Algoritmalarının olasılık yoğunluk fonksiyonlarına göre daha başarılı sonuçlar verdiği değerlendirilebilir.

2024, 63 Sayfa

ANAHTAR KELİMELER: Çap dağılımı, Olasılık yoğunluk fonksiyonu, Derin öğrenme algoritmaları, Aşırı uyum

ABSTRACT

Master of Science Thesis

MODELLING DIAMETER DISTRIBUTION BY DEEP LEARNING ALGORITHMS: A CASE STUDY IN ANATOLIAN BLACK PINE STANDS IN ILGIN (KONYA) REGION

Ömer Faruk ORHAN

Çankırı Karatekin University
Graduate School of Natural and Applied Sciences
Department of Forest Engineering

Advisor: Prof. Dr. İlker ERCANLI

This study aims to model the diameter distributions of Anatolian Black Pine (*Pinus nigra* subsp. *pallasiana*) stands using Deep Learning Algorithms (DLA)'s model, an artificial intelligence technique. Utilizing data from 408 sample plots collected from pure Anatolian Black Pine stands distributed across Ilgın, Akşehir, and Aşağıçiğil Forest Planning Units within Ilgın Forest Enterprise Directorate from the Konya Regional Directorate, the parameters of 3-parameter Weibull and 4-parameter Johnson SB probability density functions were calculated by using the maximum likelihood method, the moment and percentile methods based on various percentile and moment values of diameter distributions and hybrid methods. Deep Learning Algorithm (DLA) models were trained with a fixed hyperbolic tangent sigmoid activation function and 100 neurons, incorporating four different hidden layer configurations (3, 5, 7, and 10 hidden layers), along with the customization of three hyperparameters (learning rate, momentum rate, and early stopping) that can be considered as solutions to the overfitting problem. When evaluating the performance of Deep Learning Algorithm models in diameter distributions, the best predictive 3-parameter Weibull probability density function (calculated with 31% and 63% percentile values) yielded a Mean Absolute Error (MAE) of 41.701 stems/ha, Root Mean Square Error (RMSE) of 57.486 stems/ha, RMSE% of 55.481%, R^2 value of 0.701, AIC value of 9590, and BIC value of 11226. In contrast, the most successful Deep Learning Algorithm model—featuring 7 hidden layers with a momentum rate hyperparameter of 0.001—produced an RMSE of 49.193 stems/ha, RMSE% of 47.628%, R^2 value of 0.784, AIC value of 1905, and BIC value of 2239. In this regard, it can be concluded that the Deep Learning model provides more accurate results in modeling diameter distributions compared to traditional probability density functions.

2025, 63 pages

Keywords: Diameter Distribution, Probability Density Function, Deep Learning Algorithm, Overfitting

ÖNSÖZ VE TEŞEKKÜR

“Çap Dağılımlarının Derin Öğrenme Algoritmaları ile Modellenmesi: Ilgın (Konya) Yöresi Anadolu Karaçamı Meşcereleri Örneği” adlı bu çalışma Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalında yüksek lisans tez çalışması olarak hazırlanmıştır. Başlangıç aşamasından, çalışmanın sonlandırılmasına kadar geçen sürede yardım ve desteklerini esirgemeyen herkese sonsuz teşekkür ederim.

İlk olarak çalışma konusunun seçiminden, çalışmanın sonlandırılmasına kadar her aşamada desteğini esirgemeyen, bilgi ve tecrübesinden sıkça yararlandığım danışman hocam Sayın Prof. Dr. İlker ERCANLI’ya, Doç. Dr. Muammer ŞENYURT’a ve Doç. Dr. Oytun Emre SAKICI’ya ve ayrıca bu çalışma verilerinin elde edilmesinde emeği geçen tüm orman amenajmanı çalışanlarına teşekkürlerimi bir borç bilirim. Son olarak bütün hayatım boyunca beni hem maddi hem de manevi olarak destekleyen ve her durumda yanımda olduklarını bildiğim aileme sonsuz şükranlarımı sunarım.

Ömer Faruk ORHAN

Çankırı, Mayıs 2025

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	ii
ÖNSÖZ VE TEŞEKKÜR	iii
İÇİNDEKİLER.....	iv
SİMGELER DİZİNİ	v
KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ	1
2. MATERYAL VE YÖNTEM	11
2.1 Materyal	11
2.2 Yöntem	15
2.2.1 Olasılık Yoğunluk Fonksiyonları	15
2.2.2 Olasılık yoğunluk fonksiyonlarının parametrelerinin tahmin edilmesi.....	16
2.2.3 Derin Öğrenme Algoritmaları	21
2.2.4 Modellerin değerlendirme süreçleri ve başarı ölçütleri	28
3. BULGULAR VE TARTIŞMA	32
3.1 Olasılık Yoğunluk Fonksiyonlarına ilişkin sonuçlar.....	32
3.2 Derin Öğrenme Algoritmalarına ilişkin sonuçlar	37
4. SONUÇ VE ÖNERİLER	42
KAYNAKLAR	50
ÖZGEÇMİŞ	63

SİMGELER DİZİNİ

m	Metre
m^2	Metrekare
m^3	Metreküp
ha	Hektar
Σ	Toplam
α	3 parametrelili Weibull fonksiyonun konum parametresi
β	3 parametrelili Weibull fonksiyonun ölçek parametresi
γ	3 parametrelili Weibull fonksiyonun biçim parametresi
λ	4 parametrelili Johnson SB fonksiyonun ölçek parametresi
$\square$	4 parametrelili Johnson SB fonksiyonun konum parametresi
$\square$	4 parametrelili Johnson SB fonksiyonun 1. biçim parametresi
$\square$	4 parametrelili Johnson SB fonksiyonun 2. biçim parametresi

KISALTMALAR DİZİNİ

AIC	Akaike Bilgi Ölçütü
BIC	Bayesian Bilgi Ölçütü
R^2	Belirtme Katsayısı
DÖA	Derin Öğrenme Algoritması
HKOK	Hata Kareler Ortalamasının Karekökü
HKOK%	Hata Kareler Ortalamasının Karekökü Yüzdesi
OMH	Ortalama Mutlak Hata

ŞEKİLLER DİZİNİ

Şekil 2.1. Çalışma alanı Orman İşletme Şefliklerinin coğrafik konumları	12
Şekil 2.2. 3 ara katmanlı DÖA modeline ilişkin model yapısı (Ercanlı vd., 2023)	23
Şekil 2.3. Erken Durdurma Stratejisinin şekilsel gösterimi (Ercanlı vd., 2023)	27
Şekil 3.1. 1 ve 150 numaralı örnek alanların gözlemlenen çap basamaklarına ağaç sayısı dağılımı ile 3 parametrelili Weibull fonksiyonu ile tahmin edilen ağaç sayısı dağılımı	35
Şekil 3.2. 1. ve 150. numaralı örnek alanların gözlemlenen çap basamaklarına ağaç sayısı dağılımı ile 4 parametrelili Johnson SB fonksiyonu ile tahmin edilen ağaç sayısı dağılımı	36
Şekil 3.3. 1. ve 150. numaralı örnek alanların gözlemlenen çap basamaklarına ağaç sayısı dağılımı ile DÖA modeli ile tahmin edilen ağaç sayısı dağılımı	41

ÇİZELGELER DİZİNİ

Çizelge 2.1. Farklı Meşcere tiplerinde alınan örnek alanlarda ölçülen ağaçların göğüs çaplarına (cm) ilişkin tanımlayıcı istatistiki bilgiler	13
Çizelge 2.2. 3 parametreleri Weibull fonksiyonun parametrelerinin moment ve yüzdelikleri esas alan yöntemlerle hesaplanmasına ilişkin eşitlikler (Cao 2004; Poudel and Cao 2013).....	19
Çizelge 2.3. 4 parametreleri Johnson SB fonksiyonun parametrelerinin hesaplanmasına ilişkin eşitlikler (Scolforo <i>et. al.</i> 2003 ve Gorgoso <i>et al.</i> 2012).....	20
Çizelge 3.1. Olasılık yoğunluk fonksiyonlarının parametrelerini hesaplamada kullanılan yöntemlere ilişkin hesaplanan başarı ölçütleri	33
Çizelge 3.2. Olasılık yoğunluk fonksiyonlarının parametrelerini hesaplamada kullanılan yöntemlere ilişkin hesaplanan rölatif sıra numaraları.....	34
Çizelge 3.3. DÖA modellerine ilişkin hesaplanan başarı ölçütleri	39
Çizelge 3.4. DÖA modellerine ilişkin hesaplanan rölatif sıra numaraları	40

1. GİRİŞ

Ormanlar, doğal ekosistemlerin temel bileşenlerinden birisi olan ve dünya üzerindeki biyoçeşitliliğin korunmasında hayati bir rol oynayan ekosistemlerdir. Farklı bitki ve hayvan türlerine ev sahipliği yapan ormanlar, biyolojik ekosistemlerin dengesi korunmasında büyük önem arz eder. Ayrıca, ormanlar atmosfere salınan karbondioksiti bünyelerinde tutma kapasiteleri ile de iklim değişikliğiyle mücadelede kritik bir işlev üstlenir. Bu süreç, sadece küresel ısınmayı yavaşlatmakla kalmaz; aynı zamanda hava kalitesinin iyileşmesine de katkıda bulunur (Köse vd. 2001, Başkent 1999) Bunun yanı sıra, ormanlar insan toplulukları için birçok ekonomik ve sosyal fayda sunmaktadır. Orman ürünleri, tarım ve turizm gibi sektörler için önemli kaynaklar sağlar. İnsanlar, ormanları aynı zamanda rekreasyon faaliyetleri için bir alan olarak kullanarak fiziksel ve mental sağlıklarını destekleyebilirler. Su döngüsünü düzenlemesi ve toprak erozyonunu önlemesi gibi ekosistem hizmetleri, tarımsal üretkenliği artırarak yerel ekonomilere de katkıda bulunur. Bu nedenle, ormanların korunması ve sürdürülebilir yönetimi, gelecekteki nesiller için vazgeçilmez bir öneme sahiptir (Asan 2000, Asan vd. 2001).

Orman planlaması, sürdürülebilir kaynak yönetiminin temel unsurlarından biridir ve ormanlardan devamlı ve optimal bir şekilde yararlanmayı sağlamak amacıyla büyük bir önem arz eder. Ormanlar, ekosistem hizmetleri, biyoçeşitlilik ve iklim düzenlemesi gibi birçok kritik işlevi yerine getirirken, aynı zamanda ekonomik açıdan da yerel topluluklar için önemli bir gelir kaynağı oluşturur. Bu nedenle, ormanların planlı bir şekilde yönetilmesi, hem çevresel dengeyi koruma hem de ekonomik faydaları maksimize etme açısından gereklidir (Asan vd. 2001, Başkent ve Keleş 2004). Ormancılıkta planlama, doğal kaynakların verimli ve sürdürülebilir bir şekilde kullanılmasını sağlamak için gereklidir. Planlama süreçleri, ağaç kesimi, rehabilitasyon, koruma ve rekreasyon alanlarının dengeli bir şekilde yönetilmesine olanak tanır. Böylece, ormanların ekolojik sağlığı korunurken, yerel toplulukların ekonomik refahı da desteklenmiş olur. Sonuç olarak, ormanları planlamak, gelecek nesillerin ihtiyaçlarını karşılamak ve doğal kaynaklarımızı korumak için kritik bir adımdır (Başkent 1996).

Ormanların sürdürülebilir yönetimi açısından ormanların ekosistemlerinin artım ve büyüme potansiyellerinin yanı sıra meşcere yapıları hakkında detaylı bilgi sahibi olmak, bu ormanlık alanların planlamasında önemli bir bilgi altlığı olarak rol oynamaktadır. Meşcere içindeki ağaçların çap basamaklarına dağılımlarının belirlenmesi, meşcere yapılarının tanımlanmasında en önemli unsurlardan birisidir (Yavuz vd. 2002, Bolat 2014). Meşcere yapıları tanımlanmasında farklı yaklaşımlar ve tanımlamalar olmasına karşın, orman alanlarındaki ağaç türlerinin çap basamaklarına göre dağılımının sayısal olarak ortaya koyulması olarak basit bir şekilde belirtilebilir. Bir meşceredeki ağaçların çap basamaklarına dağılımının meşcerelerin biyolojik çeşitliliği, yaş durumu, sıklık derecesi ve karışım oranı ile olan ilişkilerinin de bilinmesi önem arz eder. Bu şekildeki meşcere yapıları hakkındaki ayrıntılı bilgiler, başta orman amenajmanı olmak üzere çeşitli ormancılık uygulamaları için önemli bir veri kaynağı niteliğine sahip olup, meşcere yapılarının ortaya konması, ormanlar hakkında verilecek kararlarda dikkate alınması gereken bir meşcere özelliği olarak önem arz ederler.

Orman planlamasında ve ekonomik analizlerde, meşcere içindeki ağaçların çap dağılımlarının sayısal olarak belirlenmesi ve tahmin edilmesi, ormanlardan elde edilecek ürün çeşitlerinin tespit edilmesinde de temel bilgi kaynağı olmaktadır. Meşcere içindeki ağaçların belirli bir ürün çeşidinin göstergesi olan (21 cm'den daha fazla çapa sahip ağaçların tomruk sınıfına girmesi gibi) çap sınıflarına ve kademlerine dağılımı, bu ormanların ekonomik ve ekolojik değerlerini tespit etmek ve yönetmek için gereklidir (Yavuz vd. 2002). Günümüzde ve gelecekteki ormanların çap dağılımlarının belirlenmesi ve tahmini de, ormanların yönetimi ve planlaması açısından önemli bir bilgi kaynağı sunmaktadır (Maltamo 1997). Meşcerelerin çap dağılımlarının tahmin edilmesinin, ormanların planlanmasında kritik bir gereksinim olduğunu ve bu bakımdan da, meşcere yapılarının detaylı analizi, ormancılık uygulamalarının bilimsel ve uygulamalı bir biçimde gerçekleştirilmesine olanak tanırken, sürdürülebilir orman yönetimi için de bir temel oluşturur. Dolayısıyla, ormanların yönetimi ve planlaması açısından meşcere yapılarının ortaya konulması, hem ekosistem dengesi hem de

ekonomik faydalar açısından büyük önem arz etmektedir. (Rennols *et. al.* 1985, Borders and Patterson 1990, Laar and Akça 2007).

Ormancılıkta, meşcerelerin çap dağılımlarının ortaya konulması ve modellenmesi konusunda çalışmalar, 1883 yılında Gram'ın kayın meşcerelerinin çap dağılımlarını normal dağılım ile modellemesi ile başlamıştır. Devam eden süreçte, 1898 yılında De Liocourt'un yaptığı çalışma ise değişik yaşlı meşcerelerde çap dağılımlarını üssel (eksponansiyel) dağılım ile modellemiştir (Leak 1965, Packard 2000). Meyer and Stevenson (1943), De Liocourt'un exponential dağılım modelini "Negatif Eksponansiyel Dağılım" biçimine dönüştürerek değişik yaşlı karışık meşcerelerde çap dağılımını incelemek için kullanmışlardır. Bu dönemde, özellikle 1930'lu yıllarda matematik serileri ve istatistiksel yöntemler aracılığıyla çap dağılımlarını modelleme çabaları başlamış, ancak 1960'lı yıllarda olasılık yoğunluk fonksiyonları "*probability density function, pdf*" ile daha sistematik ve modelleme yaklaşımı benimsenmiştir.

Olasılık yoğunluk fonksiyonları, çap dağılımlarını belirli bir çap başmağındaki ağaç sayısının meşceredeki toplam ağaç sayısına oranı olarak tahmin etmekte olup, bu oran 0 ile 1 arasında değişen değerler olmaktadır (Bailey and Dell 1973). Ormancılıkta, çap dağılımlarını modellemek amacıyla çok farklı olasılık yoğunluk fonksiyonları önerilmiş ve kullanılmıştır. Clutter and Bennet (1965) tarafından yapılan ilk çalışmada, çap dağılımlarını dört parametrelili beta fonksiyonu ile modellemiş (Packard 2000); Normal, Lognormal, Gamma, Beta, Johnson's SB ve Weibull dağılımı gibi farklı fonksiyonlar da, meşcerelerdeki ağaçların çap basamaklarına dağılımlarını modellemek için kullanılan fonksiyonlar olarak öne çıkmıştır (Ercanlı ve Yavuz 2010). Bailey and Dell (1973), Smalley and Bailey (1974), Haffley and Schreuder (1977), Rennols *et al.* (1985), Knoebel *et al.* (1986), Pukkala *et al.* (1990), Saramäki (1992), Packard (2000), Liu *et al.* (2004), Podlaski (2006) ve Palahi *et al.* (2007) gibi araştırmalar, çap dağılımlarını modelleyen çeşitli olasılık yoğunluk fonksiyonlarının kullanımını öne çıkaran çalışmalardır. Bu çalışmalar değerlendirildiğinde, ormancılıkta çap dağılımlarının modellenmesinde Normal (Bailey 1980), Lognormal (Bliss and Reinker 1964), Gamma (Nelson 1964), Beta (Clutter and Bennet 1965), Johnson's SB (Johnson 1949) ve Weibull fonksiyonlarının (Weibull 1951) kullanıldığı görülmektedir. Bu

çeşitlilik, ormancılıkta çap dağılımlarının daha iyi anlaşılmasını ve daha doğru tahminler yapılmasını sağlamakta, aynı zamanda ormancılık yönetimi ve sürdürülebilir ormancılık uygulamalarının geliştirilmesine önemli katkılar sunmaktadır.

Türkiye'de çap dağılımlarının modellenmesine yönelik bilimsel araştırmalar, 1980'lerin sonlarından günümüze kadar uzanan bir süreçte gelişim göstermiş ve ilk çalışmalar olarak da, değişik yaşlı meşcereler için Saraçoğlu (1988) ve Atıcı (1996)'nın Meyer'in üssel fonksiyonu kullandığı çalışmalar olarak öne çıkmıştır. Daha sonraki yıllarda, Carus (1996), aynı yaşlı Doğu kayını meşcerelerinin çap dağılımlarının bonitet endeksi ve yaşa göre değişimini incelemiş ve meşcerelerdeki ağaçların çap basamaklarına dağılımının %65'lik açıklayıcılıkla bonitet endeksi ve yaşa bağlı olduğunu ortaya koymuştur. Carus (1998), çeşitli dağılımların çap dağılımını modellemede başarı durumlarını karşılaştırmış, Gamma dağılımının çap dağılımını ortaya koymada başarılı olduğunu ifade etmiştir. Yavuz vd. (2002), doğal ve yapay Dişbudak meşcerelerinde Weibull dağılımı ile çap dağılımlarını belirlemiş ve bu fonksiyonun parametreleri ile meşcere yaşı ve bonitet endeksi arasındaki ilişkileri ortaya koymuştur. Carus ve Çatal (2008), ağaçların çap basamaklarına dağılımının değişik yaş ve bonitet derecesine göre değişimini ortaya koymuş ve çap dağılımını modellemede lognormal fonksiyonun olduğunu ortaya koymuştur. Ercanlı ve Yavuz (2010), Doğu ladini-Sarıçam karışık meşcerelerinin çap dağılımlarını 2 parametrelili Gamma, 3 parametrelili gamma, Beta, log-normal, Normal, 2 parametrelili Weibull, 3 parametrelili Weibull ve Johnson S_B 'ye göre ortaya koymuşlar ve Doğu ladini meşcereleri için 4 parametrelili Johnson S_B fonksiyonun ve Sarıçam meşcereleri için ise 3 parametrelili Weibull fonksiyonun en başarılı fonksiyon olduğunu belirlemişlerdir. Sakıcı ve Gülsunar (2012), Weibull (2P ve 3P) fonksiyonunun, karışık Gökmar meşcerelerdeki çap dağılımını modellemede başarılı sonuçlar verdiğini ortaya koymuştur. Özdemir (2013) olasılık sıklık fonksiyonunun parametrelerini, bonitet, yaş ve sıklık değişkenlerine göre modellemişler ve bu model yardımıyla birim alan düzeyinde ağaçların çaplarını türetmişlerdir. Karakaş (2013), doğal Fıstık çamı meşcerelerinin çap dağılımlarını Weibull fonksiyonu ile oluşturmuş ve bu fonksiyona ait parametrelerin tahmininde maksimum olabilirlik, yüzdelik değerleri esas alan yöntem ve hibrid yöntemini kullanmış ve en başarılı parametre tahmin yönteminin yüzdelikleri esas alan metot olduğunu ortaya koymuştur. Ercanlı vd.

(2013) 3-parametrelili Weibull fonksiyonunun parametrelerini çap dağılımının bazı yüzdelik ve moment değerleri ile tahmin etmiş ve 25%, 50% and 63% değerleri kullanan yöntemin en başarılı olduğunu ortaya koymuşlardır. Doğdaş (2014), Burdur-Ağlasun yöresi Kızılçam (*Pinus brutia* Ten.) ormanlarında ağaç sayısı, hacim ve hacim artımının çap basamaklarına dağılımlarının modellenmesinde; çap dağılımlarını temsil etmede en başarılı fonksiyonların meşcere ağaç sayısı için Johnson S_B fonksiyonu ve meşcere hacim ve meşcere hacim artımı için 3 Parametrelili Gamma olduğunu tespit etmiştir. Ercanlı vd. (2016), Weibull (3P) fonksiyonunun Vezirköprü-Sarıçiçek ormanlarının çap dağılımını modellemede başarılı olduğunu belirlemiştir. Özdemir (2016), Douglas göknarının çap dağılımını modellemede Weibull (2P) fonksiyonunu başarılı bulmuştur. Bolat ve Ercanlı (2017), Bursa-Kestel ormanlarının çap dağılımını modellemesinde, Weibull (3P) fonksiyonunun %97,7'lik tahmin gücü sağladığını ifade etmiştir. Sakıcı ve Dal (2021), sarıçam meşcerelerinin çap dağılımlarını modellemede Johnson SB fonksiyonunun en başarılı fonksiyon olduğunu belirlemiştir. Seki (2022), Karabük bölgesinde yer alan saf doğu kayını meşcerelerin çap dağılımlarını 2 parametrelili Weibull fonksiyonu ile modellemiş ve bu fonksiyonun parametreleri ile çeşitli meşcere özellikleri arasındaki ilişkileri belirlemiştir. Alkan vd. (2023), 3 parametrelili Weibull fonksiyonun parametrelerinin tahmini için kullanılan regresyon denkleminin katsayılarını tahmin etmek amacıyla, Görünürde Uyumsuz Regresyon Denklemi (SUR) ve Değiştirilmiş Kümülatif Dağılım Fonksiyon Regresyonu (MCDF) olmak üzere iki farklı yaklaşım ile parametre tahmin yöntemi, moment ve yüzdelik temelli parametre çözümleme yöntemleri ve hibrit yöntem olmak üzere dört farklı yöntem kullanılmış; SUR yaklaşımı ile geliştirilen modellerde moment temelli yöntemin ve MCDF yönteminde ise hibrit yöntemin en başarılı sonuçları verdiği belirlemiştir. Seki ve Sakıcı (2024), 4 parametrelili Johnson SB, 2 parametrelili Gamma, 3 parametrelili Gamma, 2 parametrelili Weibull ve 3 parametrelili Weibull fonksiyonlarının üç farklı ekorejyonda yayılış yapan doğal ve saf Karaçam meşcerelerine ilişkin çap dağılımları modelleme başarılarını karşılaştırmış, Johnson SB fonksiyonunun tüm ekorejyonlar için oldukça başarılı sonuçlar verdiğini belirlemiştir. Alkan vd. (2023), Doğu kayını meşcerelerinin çap dağılımları için Weibull dağılım fonksiyonun parametrelerinin tahmini için geliştirilen regresyon denkleminin katsayılarını tahmin etmek amacıyla, Görünürde Uyumsuz Regresyon Denklemi (SUR) ve Değiştirilmiş

Kümülatif Dağılım Fonksiyon Regresyonu (MCDF) olmak üzere iki farklı yaklaşım ile parametre tahmin yöntemi olarak da, moment ve yüzdelik temelli parametre çözümleme yöntemleri ve hibrit yöntem olmak üzere dört farklı yöntem kullanılmıştır.

Son yıllarda ise, özellikle 3 parametrelili Weibull fonksiyonu ile 4 parametrelili Johnson fonksiyonlarının kullanımı öne çıkmış ve genel kabul görmüştür. Bu olasılık yoğunluk fonksiyonları, 3 ve 4 parametrelili esnek yapıları sayesinde farklı çap dağılımlarını modellemede başarılı sonuçlar elde edilmesini sağlamaktadır. Bu kapsamda, bu fonksiyonlarının parametrelerinin tahmininde ve çap dağılım simülasyonlarının elde edilmesinde, farklı yaklaşımlar önerilmiş ve kullanılmıştır. Olasılık yoğunluk fonksiyonlarının standart parametre tahmin yöntemi olan maksimum olabilirlik yöntemi yanında; Lei (2008), moment yönteminin maksimum olabilirlik yönteminde daha başarılı sonuçlar verdiğini ve Liu *et al.* (2009) yüzdelik değerleri esas alan yönteminin maksimum olabilirlik, moment, hibrid yönteminden daha başarılı sonuçlar verdiğini koymuşlardır. Bu çalışmalar yanında, Knowe (1992), Bailey *et al.* (1989) Knowe *et al.* (1997), Liu *et al.* (2004), Cao (2004), Poudel (2011) ve Poudel and Cao (2013) yapmış olduğu çalışmalarda çap dağılımlarının aritmetik ortalama standart sapma gibi moment değerleri ile %25, %31, %50, %63 ve %95'lik değerlerine karşılık gelen çap değerlerini esas alan eşitliklerle 3 parametrelili Weibull veya 4 parametrelili Johnson SB fonksiyonlarının parametre değerlerini tahmin eden yöntem ve formüller önermiş ve kullanmışlardır.

Çap dağılımlarının belirli olasılık fonksiyonlarıyla modellenmesinin yanı sıra, artım ve büyüme süreçlerinin tahmininde yapay zeka tabanlı yöntemler olan Yapay Sinir Ağları (YSA) ve Derin Öğrenme Algoritmaları (DÖA) giderek daha fazla önem kazanmaktadır. Özellikle son yıllarda, YSA ve YSA'nın farklı bir uygulaması olan DÖA'nın hem tek ağaç hem de meşcere düzeyindeki çeşitli özelliklerin artım ve büyüme değerlerinin tahmininde kullanılmasına yönelik çok sayıda çalışma gerçekleştirilmiştir. Derin Öğrenme Algoritmaları (DÖA), çok katmanlı Yapay Sinir Ağları (YSA) mimarisi üzerine inşa edilmiş olup, milyonlarca hatta milyarlarca veri örneğini işleyebilme kapasitesine sahiptir. 2010'lu yılların başlarında popülerlik kazanan bu algoritmalar, geleneksel YSA modellerinin sınırlı katman ve nöron

yapılarının ötesine geçerek, genellikle 5 ila 10 katman ile yüzlerce nöron içeren daha karmaşık yapılar sunmaktadır (LeCun *et al.* 2015, Carranza-Rojas *et al.* 2017). Yapay zekâ alanının önemli bir alt disiplini olan DÖA, özellikle tahminleme ve sınıflandırma gibi uygulamalarda gösterdiği yüksek başarı düzeyi ile dikkat çekmektedir. Çok katmanlı yapı, verilerin derinlemesine incelenmesini sağlayarak, daha verimli ve doğru sonuçların elde edilmesine olanak tanımaktadır. Özellikle ormancılık alanında, çeşitli düzeylerdeki büyüme özelliklerini tahmin etmeye yönelik geliştirilmiş birçok Yapay Sinir Ağı (YSA) modeli bulunmasına rağmen, Derin Öğrenme Algoritmalarının (DÖA) bu alandaki potansiyeli henüz tam anlamıyla açığa çıkmamıştır. YSA'nın bir uzantısı olarak kabul edilen DÖA, tahmin ve sınıflandırma gibi uygulamalarda yüksek başarılar sergileyebilmekte olup, çok katmanlı yapısı sayesinde büyük ve karmaşık veri setlerinde etkili sonuçlar elde edebilmektedir. DÖA'nın potansiyeli, ormancılıkta daha karmaşık büyüme ilişkilerinin modellenmesini mümkün kılmakta ve bu sayede daha hassas tahminler yapılmasına imkân tanımaktadır. Günümüzde, DÖA'nın ormancılık alanındaki uygulamaları sınırlı kalmakta olup, bu alandaki araştırmalar hâlâ başlangıç aşamasındadır. Ancak, DÖA'nın sunduğu daha karmaşık yapılar, daha fazla katman ve nöron içermesiyle, ormancılıkla ilgili karmaşık ilişki ve etkileşimlerin daha etkin bir şekilde modellenmesini sağlayarak, doğru tahminlere ulaşmayı mümkün kılmaktadır.

Ülkemizde YSA ve DÖA modelleri kullanılarak gerçekleştirilen artım ve büyüme tahmin çalışmaları incelendiğinde, bu yapay zeka yöntemlerinin ormancılık alanındaki uygulamalarının henüz yeterli düzeyde olmadığı gözlemlenmektedir. Özellikle ağaçlara ilişkin artım ve büyümenin modellenmesine yönelik yapılan çalışmalarda, Özçelik vd. (2008) ağaç hacimlerinin tahmininde kullanılan yöntemleri karşılaştırmıştır. Bu çalışmada, geleneksel yöntemler (Huber formülü ve yöresel hacim denklemi), modern teknikler (Paracone, centroid, control-variate, importance sampling) ve cascade korelasyon yapısına dayalı Yapay Sinir Ağı (YSA) modelleri ele alınmış olup, en başarılı tahminlerin YSA modelleri ile elde edildiği bulunmuştur. Diamantopoulou ve Özçelik (2012), ağaç boyu tahminlerinde genelleştirilmiş regresyon yapısına dayanan Yapay Sinir Ağı (YSA) modelleri ile doğrusal olmayan regresyon modellerini karşılaştırmış ve YSA'nın daha başarılı boy tahmin sonuçları verdiğini ortaya koymuştur. Özçelik vd. (2013), karaçam ağaçlarının boylarının tahmin edilmesinde

genelleştirilmiş boy denklemleri, karışık etkili modellemeye dayanan doğrusal olmayan modeller ve Yapay Sinir Ağı (YSA) yöntemlerini karşılaştırmış ve en doğru ve başarılı tahminlerin geri yayılım (Back Propagation) algoritmasına dayalı YSA yapısı ile elde edildiğini göstermiştir. Özçelik vd. (2014), kızılçam ağaçlarının gövde çapı ve gövde hacmi tahminlerinde, tepe özelliklerine ilişkin değişkenlerin etkisini Yapay Sinir Ağı (YSA) ile incelemiş; özellikle Levenberg-Marquardt algoritmasına dayalı YSA'nın en başarılı tahmin sonuçlarını verdiğini ortaya koymuştur. Diamantopoulou *et al.* (2015), iki parametrelili Weibull olasılık yoğunluk fonksiyonunun parametrelerinin tahmin edilmesinde Levenberg-Marquardt algoritmasını kullanan Yapay Sinir Ağı (YSA) ile çap dağılımlarını modellemede başarılı sonuçlar elde etmiştir. Bu çalışmalar yanında, Bolat (2015), ağaç boyunu; 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. (2018a), yaprak alan indeksini ve Ercanlı vd. (2018b), ağaçların hacmini YSA modelleri ile tahmin etmişlerdir. Sakıcı ve Özdemir (2018), Kayın-Gökmar karışık meşcerelerinde gövde çapı tahminleri için farklı YSA modellerini gövde çapı denklemleri ile karşılaştırmış, YSA modelleri ile ağaçların belirli yükseklikteki gövde çapını tahmininde daha başarılı sonuçlar elde etmiştir. Sakıcı ve Günlü (2018) uzaktan algılama verilerini kullanarak yapay sinir ağları ile meşcere parametrelerini etmiş ve YSA modellerinin daha kabul edilebilir doğrulukta sonuçlar ürettiğini ifade etmişlerdir. Ercanlı vd. (2018c), Doğu Ladini-Sarıçam Karışık Meşcerelerinin çap dağılımlarının modellenmesinde farklı katman sayılarını içeren DÖA modelleri ve 3 parametrelili Weibull fonksiyonu ile elde edilen çap dağılımına ilişkin tahmin başarılarını karşılaştırmış, DÖA ($R^2=0.9184$) modelleri ile Weibull fonksiyonuna ($R^2= 0.6121$) göre tahmin başarısında belirgin bir iyileşme elde etmiştir. Şenyurt ve Ercanlı (2019), regresyon modeli ve yapay sinir ağlarını kullanarak ağaç hacimlerini tahmin etmişlerdir. Model doğrulukları değerlendirildiğinde birbirine yakın sonuçların elde edildiği ifade etmişlerdir. Şenyurt vd. (2020), basit doğrusal regresyon modelleri ve yapay sinir ağları modeli ile dip kütük çapı ve göğüs çapı arasındaki ilişkiyi araştırmışlardır. Elde edilen sonuçlar iki modelleme tekniğinin benzer başarılarla sahip olduğunu göstermiştir. Ercanlı ve Bolat (2020), Ankara Orman Bölge Müdürlüğü sınırları içerisinde yayılış

yapan doğal ve saf Anadolu Karaçamı meşcereleri için tek ağaç gövde çapı ve gövde hacminin uyumlu gövde çapı denklemleri ve yapay sinir ağları ile tahmin edilmesi olanaklarının araştırılması amaçlanmış, tek girişli tahminler için 100 nöronlu ve çift girişli tahminler için de 50 nöronlu “Bayesian regularization backpropagation (trainbr)” eğitim fonksiyonu ve girdi katmanı ile ara katman arasında; “tansig”, ara katman ile çıktı katmanı arasında “purelin” aktivasyon fonksiyonu içeren ileri beslemeli ve geri yayımlı YSA modeli ile tek girişli tahminler için, % 91.08’lik ve çift girişli tahminler için de % 96.34’lük model açıklayıcılığı elde etmişlerdir. Ercanlı (2020a) ve Ercanlı (2020b) yapay sinir ağlarından daha karmaşık bir yapıya sahip olan Derin Öğrenme tekniği ve doğrusal olmayan karışık etkili model ile ağaçların göğüs çapları ve boyları arasındaki ilişkiyi incelemiştir. Bu çalışmada, Derin Öğrenme tekniğinin ileri düzey regresyon tekniği olan karışık etkili modelden daha başarılı bulunmuştur. Günlü ve Ercanlı (2020) meşcerelerin sahip olduğu karbon miktarlarını tahmin etmek için regresyon ve yapay sinir ağları modellerini kullanmışlardır. Yapay sinir ağlarının belirtme katsayısında %13 oranında iyileşme sağladığını ortaya koymuştur. Ogana ve Ercanlı (2021), DÖA tipindeki Yapay Zeka modeli ile farklı ağaç grupları için ağaçların boy tahminlerini gerçekleştirmiş, farklı tür grupları için 6,7 ve 9 katmana ve 100 nörona sahip DÖA modellerinin en başarılı olarak belirlendiği bu çalışmada, bu çap-boy tahminlerine dayanan biyokütle tahminlerinde DÖA modellerinin kullanımı ile hata ölçütlerinde yaklaşık %30’luk bir iyileşme elde edilmiştir. Bolat (2021), Ankara Orman Bölge Müdürlüğü sınırları içerisinde yer alan Anadolu Karaçamı meşcerelerinin büyüme ve artımının tahminlerinin elde edilmesinde Bayesçi yapay sinir ağlarını kullanmış, bu YSA modelleri ile çeşitli başarı ölçütlerine göre başarılı sonuçlar elde etmiştir. Karatepe vd. (2022) tarafından gerçekleştirilen çalışmada, ağaç boyu tahminlerinin modellenmesinde doğrusal olmayan karışık etkili model ve yapay sinir ağları (YSA) yöntemleri karşılaştırmalı olarak değerlendirilmiş, model performans ölçütlerinden biri olan Uyum İndeksi (UI) açısından karışık etkili modelin daha başarılı sonuçlar verdiği tespit etmişlerdir. Bolat vd. (2023) tarafından gerçekleştirilen çalışmada, Anadolu Karaçamı (*Pinus nigra* subsp. *pallasiana*) meşcerelerinde büyüme ve artım tahminlerinin modellenmesi amacıyla Yapay Sinir Ağı (YSA) modelleri kullanılmış, eğitilen YSA modellerinin ormancılık bilimindeki büyüme ve artım kanunlarına uygun tahminler üretme potansiyeline ilişkin değerlendirmede, öğrenme

oranı ve moment katsayısı optimizasyonu içeren YSA modellerinin, ağaç büyümesindeki biyolojik trendleri daha doğru şekilde ortaya koyabildiğini belirlemişlerdir. Ercanlı vd. (2023), Doğu Ladini-Sarıçam karışık meşcerelerindeki Doğu Ladini ağaçlarında gerçekleştirilen gövde analizi verileri ile yaş-boy ilişkilerinin modellenmesinde; Doğrusal Olmayan Regresyon Modelleri ve Otoregresif Modeller ile çeşitli eğitim ve aktivasyon fonksiyonları ile farklı nöron sayısı seçeneklerini içeren YSA eğitimlerini gerçekleştirmiş, çeşitli başarı ölçütleri ile büyüme kanuniyetlerini esas alan değerlendirmede, tek parametreyi rastgele parametre olarak içeren karışık etkili doğrusal olmayan regresyon modellerinin, YSA modelleri de dahil olmak üzere diğer modelleme teknikleri arasında en iyi sonuçları verdiğini belirlemiştir. Ercanlı (2024), ağaç gövde çapı ve hacim tahminlerinde derin öğrenme algoritmalarının aşırı uyum sorununu azaltmak ve tahminlerde biyolojik gerçekçiliği sağlamak amacıyla hiperparametre optimizasyonu (öğrenme oranı, momentum) ve düzenlileştirme teknikleri (erken durdurma, L1/L2, dropout) kullanmış, bu hiper-parametre optimizasyonu ve düzenlileştirme tekniklerinin uygulandığı DÖA modellerinin standart modellere kıyasla daha başarılı sonuçlar verebilmeleri yanında, biyolojik açıdan anlamlı tahminler ürettiğini de göstermiştir.


Bu çalışmada, Ülkemizde daha önce yapılmış yapay zeka çalışmalarına bir katkı olarak, Ilgın Orman İşletme Müdürlüğü sınırları içerisinde yayılış gösteren Anadolu Karaçamı meşcerelerinin çap dağılımlarının bir yapay zeka tekniği olan Derin öğrenme Algoritmaları ile modellenmek üzere çeşitli eğitimlerin gerçekleştirilmesi ve mevcut yöntemlerden olan olasılık yoğunluk fonksiyonları ile çap dağılımlarının modellenme başarılarının karşılaştırılması amaçlanmaktadır.

2. MATERİYAL VE YÖNTEM

2.1 Materyal

Bu çalışmada, Konya orman Bölge Müdürlüğü, Ilgın Orman İşletme Müdürlüğü sınırları içerisinde yer alan Ilgın Orman İşletme Şefliği, Akşehir Orman İşletme Şefliği ve Aşağıçığıl Orman İşletme Şefliklerinde yayılış gösteren saf Anadolu Karaçamı meşcerelerden alınmış 408 adet örnek alan verisi kullanılmıştır. Çalışma alanı, 38° 16' 54.2028" Kuzey ve 31° 54' 50.2200" Doğu boylamları arasında yer almaktadır. Çalışma alanına ait yükselti; 600 ile 1200 metre arasında değişmekte olup, ortalama yükseklik ise, 1030 metredir. Envanter çalışmalarının gerçekleştirildiği planlama birimleri, Şekil 2.1'de verilmiştir. Çalışma alanının ilişkin ortalama aylık sıcaklıklar, -6.8 ile 28.6 C arasında değişmekte olup, en düşük ve en yüksek sıcaklıklar; -12.3 C ve 30.8 C arasındadır. İlgili planlama birimlerinde yayılış yapan asli ağaç türü Anadolu Karaçam (*Pinus nigra* Arnold. *subsp. pallasiana* (Lamb.) *Holmboe*)'dır.

Çalışma kapsamında değerlendirilen veriler, 2016 yılında Ilgın, Akşehir ve Aşağıçığıl Orman İşletme Şefliklerinde ait orman amenajman planlarının yenilenmesi kapsamında yapılan orman envanteri çalışmalarında alınmış 408 adet örnek alana ait envanter karnesinden elde edilmiştir. Örnek alanların farklı meşcere tiplerine göre dağılımları ile çeşitli meşcere tiplerinde bulunan örnek alanlarda ölçülen çap değerlerine ilişkin çeşitli istatistiksel değerler, Çizelge 2.1'de verilmiştir.



Şekil 2.1 Çalışma alanı Orman İşletme Şefliklerinin coğrafik konumları

Çizelge 2.1 Farklı meşcere tiplerinde alınan örnek alanlarda ölçülen ağaçların göğüs çaplarına (cm) ilişkin tanımlayıcı istatistiki bilgiler

Meşcere Tipi	Örnek Ağaç Sayısı	Aritmetik Ortalama	Standart Sapma	Varyasyon Katsayısı (%)
Çkb1	16	11.56	4.289	37.10
Çkb2	317	14.17	3.183	22.46
Çkb3	764	13.82	3.93	28.44
Çkbc1	227	17.34	6.644	38.32
Çkbc2	1201	16.92	5.922	35.00
Çkbc3	3430	17.88	6.871	38.43
Çkc1	260	22.27	7.327	32.90
Çkc2	1430	22.5	7.597	33.76
Çkc3	3127	22.33	7.015	31.42
Çkcd/a0	31	22.87	11.459	50.10
Çkcd1	303	27.91	11.735	42.05
Çkcd1/a	10	29.4	12.963	44.09
Çkcd2	1281	26.44	11.36	42.97
Çkcd3	407	27.14	11.514	42.42
Çkd1	185	39.84	13.313	33.42
Çkd1/0a	13	33.54	4.926	14.69
Çkd1/a	30	38.03	10.717	28.18
Çkd2	264	38.43	11.817	30.75
Çkd2/a	9	46.22	6.815	14.74
Çkd3	19	34.37	10.095	29.37

Orman amenajman planlarının düzenlenmesinde ilişkin standart orman envanteri çalışması kapsamında, daire biçiminde alınan örnek alanlarda, kapalılık dikkate alınarak örnek alan büyüklükleri 400 m², 600 m² veya 800 m² olarak belirlenmiştir. Örnek alanlarda göğüs çapı (d1,3) 8 cm’ den büyük tüm ağaçların çapı, bunun yanında orta çapa yakın 4–5 adet ağaçta yaş ve boyu ölçülmüştür. Ayrıca örnek alanlarda kapalılık ve gelişim çağları da belirlenmiştir. Gelişim çağları, meşcere orta çapları 7.9 cm’ye kadar olan meşcereler için; gençlik ve sıklık olarak tanımlanmış olup, “a” rumuzu ile gösterilmiştir. Meşcere orta çapları 8 ile 19.9 cm arasında olan meşcereler; sırlıklık ve direklik meşcere tipi olarak tanımlanmış ve “b” rumuzu ile gösterilmiştir. Meşcere orta çapları 20 ile 35.9 cm olan meşcereler; ince ağaçlık, 36–51.9 cm olanlar orta ağaçlık ve 51.9’den daha büyük olan meşcereler ise; kalın ağaçlık çağı olarak nitelenmiş ve rumuzları da; “c”, “d” ve “d+” olarak gösterilmiştir. Meşcere kapalılığı ise; ağaçların tepe izdüşümlerinin toplam meşcere alanına oranı; %10’dan daha az ise “Boşluklu Kapalı = 0”, %11-%40

arası ise “Gevşek Kapalı = 1”, %41-%70 arası ise “Orta Kapalı = 2”, %71-%100 arası ise “Kapalı ve Tam Kapalı =3” olarak belirlenmiştir.

Bu çalışmada alınmış 408 adet örnek alandan, yapay zeka modellerinin bir uygulaması olarak DÖA modellerinin eğitiminde kullanılacak veriler ve bu DÖA modellerin denetiminde kullanılacak veriler olmak üzere iki guruba rastgele olarak ayrılmıştır. İlk veri sınıfı, mevcut toplam verinin %75'ini (n=306 örnek alan) temsil ederken, ikinci veri sınıfı ise mevcut toplam verinin %25'ini (n=102 örnek alan) oluşturmaktadır.

2.2 Yöntem

2.2.1 Olasılık Yoğunluk Fonksiyonları

Ormancılık çalışmalarında, ağaçların çaplarının dağılımını modellemek ve çap basamaklarına ya da sınıflarına dayalı olarak ağaç sayısı olarak sayısallaştırılan dağılımları tahmin etmek için, istatistiksel analizlerin temel unsurlarından biri olan "olasılık yoğunluk fonksiyonları" (probability density functions, pdf) kullanılmaktadır. Bu fonksiyonlar, belirli çap aralıklarındaki ağaç sayılarının belirli bir çap basamağı ya da sınıfında olabilecek sayısını tahmin ederek, ormancılık alanında meşcere yapılarının daha ayrıntılı ortaya koyulmasına olanak tanımaktadır. Olasılık yoğunluk fonksiyonları, belirli bir çap değeri (x) veya çap aralığında yer alan bireylerin (f , frekans) sayısının, toplam meşceredeki birey sayısına oranını, 0 ile 1 arasında bir değerle ifade eden fonksiyonlar olarak matematiksel araçlardır (Bailey and Dell 1973). Bu fonksiyonlar aynı zamanda, belirli bir çap değerine kadar olan bireylerin kümülatif toplamının, meşceredeki toplam birey sayısına oranını da hesaplama imkânı sunmaktadır. Bu fonksiyonlar, bağımsız değişken olarak girilen çap değerindeki veri sayısının, o meşceredeki toplam ağaç sayısına oranını tahmin ederler ve bu bakımdan da yaptıkları tahminlerin değeri 0 ile 1 arasında değişen değerler almaktadır. Bu şekilde, olasılık yoğunluk fonksiyonları kullanılarak belirli bir çap değeri veya çap aralığında bulunan birey sayısı tahmin edilebilir.

Ormancılık literatüründe, çeşitli olasılık yoğunluk fonksiyonlarının karşılaştırılması üzerine çeşitli çalışmalar gerçekleştirilmiştir. Bu çalışmalarda, özellikle esneklikleri ve farklı dağılımları temsil etme yetenekleri nedeniyle, 3 parametrelili Weibull ve 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonları, çap dağılımlarının modellenmesinde başarılı sonuçlar elde eden yöntemler olarak dikkat çekmektedir (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 çalışmada, ağaçların çap basamaklarındaki dağılımlarının tahmin edilmesi ve çap dağılım modellerinin

geliştirilmesi amacıyla, daha önce farklı meşcere yapılarının modellenmesinde başarılı sonuçlar elde eden 3 parametrelili Weibull ve 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonları tercih edilmiştir. Bu dağılım fonksiyonlarına ilişkin formüller, Denklem (2.1) ve (2.2)'de verilmiştir:

3 parametrelili Weibull olasılık yoğunluk fonksiyonu (Bailey ve Dell 1973):

$$F(x, \alpha, \beta, \gamma) = \frac{\gamma}{\beta} \cdot \left(\frac{x-a}{\beta}\right)^{\gamma-1} \cdot \exp\left(-\left(\frac{x-a}{\beta}\right)^{\gamma}\right) \quad (2.1)$$

Burada;

- x : çap değeri
- α : konum parametresi
- β : ölçek parametresi
- γ : biçim parametresini göstermektedir.

4 parametrelili Johnson S_B Olasılık Yoğunluk Fonksiyonu (Johnson 1949):

$$F(x, \delta, \lambda, \gamma, \xi) = \frac{\delta}{\lambda \cdot \sqrt{2 \cdot \pi \cdot z \cdot (1-z)}} \cdot \exp\left(-\frac{1}{2} \cdot \left(\gamma + \delta \cdot \ln\left(\frac{z}{1-z}\right)\right)^2\right) \quad (2.2)$$

$$z = \frac{x-\xi}{\lambda} \text{ dir}$$

Burada;

- x : çap değeri
- λ : ölçek parametresi
- ξ : alt sınır değeri olarak konum parametresi
- γ : 1. biçim parametresi
- δ : 2. biçim parametresini göstermektedir.

2.2.2 Olasılık yoğunluk fonksiyonlarının parametrelerinin tahmin edilmesi

3 parametrelili Weibull ve 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonlarının parametrelerinin tahmin edilmesinde, Doğrusal Olmayan Regresyon Analizi (Nonlinear Regression), Maksimum Olabilirlik Yöntemi (Maximum Likelihood Estimation), Dağılım Momentlerini esas alan eşitlikler (Moment-Based Parameter Recovery) ve

Dağılım yüzdelerini esas alan eşitlikler (Percentile-Based Parameter Recovery) olmak üzere çeşitli yöntemler kullanılabilmektedir (Bolat 2014).

Bu çalışmada, maksimum olabilirlik yöntemi ile 3 parametrelili Weibull fonksiyonun ve 4 parametrelili Johnson SB fonksiyonun parametrelerinin tahmin edilmesinde, hızlı ve etkin sonuçlar verebilen (Ogana *et. al.* 2020) Nelder-Mead optimizasyon algoritmasına (Nelder and Mead 1965) dayanan R yazılım dili ile kodlanmış “*optim*” kütüphanesi kullanılmıştır (R Core Team 2024). Ayrıca, olasılık yoğunluk fonksiyonlarının parametre tahminlerinin elde edilmesinde, örnek alan büyüklüklerinin farklı olması nedeniyle çap basamaklarındaki ağaç sayıları hektara çevrilmiş ve ağırlıklandırılmıştır.

Olasılık yoğunluk fonksiyonlarının parametrelerinin tahmin edilmesinde kullanılan diğer yöntemler olan çap dağılımının momentlerini ve yüzdelerini esas alan eşitlikler konusunda, 3 parametrelili Weibull fonksiyonu için Cao (2004) ve Poudel and Cao (2013) çalışmaları öne çıkmaktadır. Bu çalışmalarda, çap dağılımının momentlerini esas alan eşitliklerde, çap değerlerinin minimum değeri, varyans değeri, aritmetik ortalaması ($\bar{D}$) ile göğüs yüzeyi orta ağacının çapı şeklinde hesaplanan orta çapı (D_g) kullanılırken; yüzdeleri esas alan eşitliklerde ise, çap değerlerinin küçükten büyüğe doğru sıralandığında %31, %50, %63 ve %95’lik sırasına karşılık çap değerleri kullanılmaktadır. Hibrid olarak adlandırılan eşitliklerde, çap değerlerinin aritmetik ortalama ve orta çap değerleri yanında %25, %31, %50, %63 ve %95’lik yüzdelik değerlerinin birlikte kullanıldığı bir yaklaşımın olduğu görülmektedir. 3 parametrelili Weibull fonksiyonun parametrelerini tahmin etmede kullanılan yöntemler olarak şöyle ifade edilebilir; Yöntem (1): Nelder-Mead optimizasyon algoritmasına dayanan maksimum olabilirlik yöntemi, Yöntem (2): çap dağılımının moment değerleri olan çapların varyans değeri ve aritmetik ortalaması ($\bar{D}$) değerlerini kullanan eşitlikler, Yöntem (3): diğer moment değerleri olan aritmetik ortalaması ($\bar{D}$) ve göğüs yüzeyi orta ağacının çapı şeklinde hesaplanan orta çapı (D_g) değerlerini kullanan eşitlikler, Yöntem (4): çap değerlerinin küçükten büyüğe doğru sıralandığında %31 ve %63’lük yüzdelik değerlerine karşılık gelen çap değerlerini kullanan eşitlikler, Yöntem (5): yüzdelik yöntemin diğer bir uygulaması olarak %50 ve %95’lik yüzdelik değerine karşılık gelen çap değerlerini kullanan eşitlikler, Yöntem (6): çap dağılımının moment ve yüzdelik

değerlerini birlikte içeren ve hibrit yöntem olarak adlandırılan (Poudel and Cao 2013) yöntem olarak orta çapı (D_g), %25 ve %95'lik yüzdelik değerlerine karşılık gelen çap değerlerini kullanan eşitlikler, Yöntem (7): hibrit yöntemin diğer bir uygulaması olarak orta çapı (D_g), %31 ve %63'lük yüzdelik değerlerine karşılık gelen çap değerlerini kullanan eşitlikler ve Yöntem (8): hibrit yöntemin diğer bir uygulaması olarak orta çapı (D_g), %25, %50 ve %95'lik yüzdelik değerlerine karşılık gelen çap değerlerini kullanan eşitlikler olmak üzere sekiz farklı yöntem kullanılmıştır. Cao (2004) ve Poudel and Cao (2013) çalışmalarında ifade edilen 3 parametrelili Weibull fonksiyonuna ilişkin bu yöntemlere ilişkin formüller, Çizelge 2.2'de verilmiştir. 3 parametrelili Weibull fonksiyonu için bu yöntemlerin uygulanmasında, “*tidyverse*”, “*mass*” ve “*actuar*” kütüphaneleri kullanılmış ve ilgili kodlamalar yapılmıştır.

Johnson SB fonksiyonun parametrelerinin çap dağılımının momentlerini ve yüzdeliklerini esas alan eşitlikler ile tahmininde, Scolforo *et al.* (2003) ve Gorgoso *et al.* (2012) tarafından ifade edilen Conditional Maximum Likelihood (CML), Knoebel and Burkhart (1991), Mode ve Moment yöntemleri kullanılmıştır. Bu yöntemler ile 4 parametrelili Johnson SB fonksiyonun parametrelerinin tahmin edilmesinde, çap değerlerinin minimum ve maksimum değerleri ile %50 ve %95'lik yüzdelik değerleri kullanılmaktadır. 4 parametrelili Johnson SB fonksiyonun parametrelerini tahmin etmede kullanılan yöntemler olarak şöyle ifade edilebilir; Yöntem (1): Nedler-Mead optimizasyon algoritmasına dayanan maksimum olabilirlik yöntemi, Yöntem (2): Koşullu Maksimum Olabilirlik Yöntemi, Yöntem (3): Knoebel and Burkhart Yöntemi, Yöntem (4): Mode Yöntemi ve Yöntem (5): Moments Yöntemi olmak üzere beş farklı yöntem kullanılmıştır. Scolforo *et al.* (2003) ve Gorgoso *et al.* (2012) çalışmalarında verilen 4 parametrelili Johnson SB fonksiyonuna ilişkin bu yöntemlere ilişkin formüller, Çizelge 2.3'de verilmiştir. Johnson SB fonksiyonu için bu yöntemlerin uygulanmasında, “*dplyr*”, “*tidyr*”, “*SuppDists*”, “*moments*” ve “*optimx*” kütüphaneleri kullanılmış ve ilgili kodlamalar yapılmıştır.

Çizelge 2.2 3 parametreleri Weibull fonksiyonun parametrelerinin moment ve yüzdelikleri esas alan yöntemlerle hesaplanmasına ilişkin eşitlikler (Cao 2004 ve Poudel and Cao 2013)

Parametre tahmin Yöntemi	Eşitlikler
Yöntem (1): Maksimum Olabilirlik Yöntemi	$\frac{\sum_{i=1}^n (x_i)^\gamma \ln(x_i)}{\sum_{i=1}^n (x_i)^\gamma} - \frac{1}{\gamma} = \frac{1}{n} \sum_{i=1}^n (x_i)^{\frac{1}{\gamma}}$ $\beta = \left(\frac{1}{n} \sum_{i=1}^n (x_i)^\gamma \right)^{\frac{1}{\gamma}}$
Yöntem (2): Çapların varyans değeri ve aritmetik ortalaması ($\bar{D}$) değerlerini içeren Moment yöntemi	$\alpha = 0.5 \cdot d_{min} \quad \beta = \frac{\bar{D} - \alpha}{G_1}$ γ parametresi $\beta^2(G_2 - G_1^2) - d_{var} = 0$ çözümünden elde edilir.
Yöntem (3): Aritmetik ortalaması ($\bar{D}$) ve orta çapı (D_g) değerlerini içeren Moment yöntemi	$\alpha = 0.5 \cdot d_{min}$ $\beta = -\alpha \cdot \left(\frac{G_1}{G_2} \right) + \left[\left(\frac{\alpha}{G_2} \right)^2 \cdot (G_1^2 - G_2) + \frac{D_g^2}{G_2} \right]^{0.5}$ γ parametresi $\beta^2(G_2 - G_1^2) - d_{var} = 0$ çözümünden elde edilir.
Yöntem (4): %31 ve %63'lük yüzdelik değerlerine karşılık gelen çap değerlerini içeren Yüzdelik yöntemi	$\alpha = 0.5 \cdot d_{min} \quad \gamma = \frac{\ln\left(\frac{\ln(1-0.63)}{\ln(1-0.31)}\right)}{\ln(d_{\%63} - \alpha) - \ln(d_{\%31} - \alpha)}$ $\beta = \frac{d_{\%63} - \alpha}{(-\ln(1 - 0.63))^{\frac{1}{\gamma}}}$
Yöntem (5): %50 ve %95'lik yüzdelik değerlerine karşılık gelen çap değerlerini içeren Yüzdelik yöntemi	$\alpha = 0.5 \cdot d_{min} \quad \gamma = \frac{\ln\left(\frac{\ln(1-0.95)}{\ln(1-0.50)}\right)}{\ln(d_{\%95} - \alpha) - \ln(d_{\%50} - \alpha)}$ $\beta = \frac{d_{\%50} - \alpha}{(-\ln(1 - 0.50))^{\frac{1}{\gamma}}}$
Yöntem (6): Orta çap (D_g), %25 ve %95'lik yüzdelik değerlerine karşılık gelen çap değerlerini içeren Hibrid yöntemi	$\alpha = 0.5 \cdot d_{min} \quad \gamma = \frac{\ln\left(\frac{\ln(1-0.95)}{\ln(1-0.25)}\right)}{\ln(d_{\%95} - \alpha) - \ln(d_{\%25} - \alpha)}$ $\beta = -\alpha \cdot \left(\frac{G_1}{G_2} \right) + \left[\left(\frac{\alpha}{G_2} \right)^2 \cdot (G_1^2 - G_2) + \frac{D_g^2}{G_2} \right]^{0.5}$
Yöntem (7): Orta çap (D_g), %31 ve %63'lük yüzdelik değerlerine karşılık gelen çap değerlerini içeren Hibrid yöntemi	$\alpha = 0.5 \cdot d_{min} \quad \gamma = \frac{\ln\left(\frac{\ln(1-0.63)}{\ln(1-0.31)}\right)}{\ln(d_{\%63} - \alpha) - \ln(d_{\%31} - \alpha)}$ $\beta = -\alpha \cdot \left(\frac{G_1}{G_2} \right) + \left[\left(\frac{\alpha}{G_2} \right)^2 \cdot (G_1^2 - G_2) + \frac{D_g^2}{G_2} \right]^{0.5}$
Yöntem (8): Orta çap (D_g), %25, %50 ve %95'lik yüzdelik değerlerine karşılık gelen çap değerlerini içeren Hibrid yöntemi	$\alpha = \frac{n^{0.3333} \cdot d_{min} - d_{\%50}}{n^{0.3333} - 1}$ $\gamma = \frac{\ln\left(\frac{\ln(1-0.95)}{\ln(1-0.50)}\right)}{\ln(d_{\%95} - \alpha) - \ln(d_{\%50} - \alpha)}$ $\beta = -\alpha \cdot \left(\frac{G_1}{G_2} \right) + \left[\left(\frac{\alpha}{G_2} \right)^2 \cdot (G_1^2 - G_2) + \frac{D_g^2}{G_2} \right]^{0.5}$

Eşitliklerde; n ; örnek alandaki ağaç sayısını, d_{min} ; örnek alandaki minimum çapı, d_{var} ; çap değerlerinin varyansını, $d_{\%25}$, $d_{\%31}$, $d_{\%50}$, $d_{\%63}$, $d_{\%95}$; çap dağılımında verileri küçükten büyüğe doğru sıralandığında %25'lik, %31'lik, %50'lik, %63'lik ve %95'lik veriye karşılık gelen çap değerini, d_g ; örnek alan için hesaplanan göğüs yüzeyi orta ağacının çapını ve G_1 ve G_2 ; Gamma fonksiyonuna karşılık gelen değeri göstermektedir.

Çizelge 2.3 4 parametreleri Johnson SB fonksiyonun parametrelerinin hesaplanmasına ilişkin eşitlikler (Scolforo *et. al.* 2003 ve Gorgoso *et al.* 2012)

Parametre tahmin Yöntemi	Eşitlikler
Yöntem (1): Maksimum Olabilirlik Yöntemi	$\xi: \%d_{min} \quad \lambda: d_{maks} - d_{min} \quad \delta: \frac{1}{S_f} \quad \gamma: \frac{-\bar{f}}{S_f}$
Yöntem (2): Koşullu Maksimum Olabilirlik Yöntemi	$\xi: d_{min} - 1.3 \quad \lambda: d_{maks} - \xi + 3.8$ $\delta: \frac{1}{S_f} \quad \gamma: \frac{-\bar{f}}{S_f}$
Yöntem (3): Knoebel and Burkhart Yöntemi	$\xi: d_{min} - 1.3 \quad \lambda: d_{maks} - \xi + 3.8$ $\delta: \frac{Z_{95}}{\ln\left(\frac{d_{\%95}-\xi}{\xi+\lambda-d_{\%95}}\right) - \ln\left(\frac{d_{\%50}-\xi}{\xi+\lambda-d_{\%50}}\right)}$ $\gamma: -\delta \cdot \left(\frac{d_{\%50} - \xi}{\xi + \lambda - d_{\%50}}\right)$
Yöntem (4): Mode Yöntemi	$\xi: d_{min} - 1.3 \quad \lambda: d_{maks} - \xi + 3.8$ $\delta: \frac{4}{4 \cdot \sigma_x}$ $\gamma: \frac{2 \cdot x_m - 2 \cdot \xi - \lambda}{\lambda \cdot \delta} - \delta \cdot \ln\left(\frac{x_m - \xi}{\lambda + \xi - x_m}\right)$
Yöntem (5): Moments Yöntemi	$\xi: \%d_{min} \quad \lambda: d_{maks} - d_{min}$ $\delta: \frac{\mu(1-\mu)}{Sd(x)} + \frac{Sd(x)}{4} \left[\frac{1}{\mu(1-\mu)} - 8 \right]$ $\gamma: \delta \cdot \ln\left(\frac{1-\mu}{\mu}\right) + \left(\frac{0.5-\mu}{\delta}\right)$

Eşitliklerde, $\bar{f}$ değeri; $f = \ln[(d_i - \xi)/(\xi - \lambda - d_i)]$ fonksiyonun ortalaması, d_i ; ağaçların ait olduğu çap sınıfı orta değeri, S_f ; f fonksiyonun standart sapması, μ değeri; $\mu = (\bar{d} - \xi)/\lambda$ olup, $\bar{d}$ çap değerlerinin ortalaması, $Sd(x)$; düzeltilmiş standart sapma olup, formülü; σ_x/λ 'dir, σ_x ; örnek alanlardaki çapın standart sapması, $d_{\%25}$, $d_{\%31}$, $d_{\%50}$, $d_{\%63}$, $d_{\%95}$; çap dağılımında verileri küçükten büyüğe doğru sıralandığında %25'lik, %31'lik, %50'lik, %63'lik ve %95'lik veriye karşılık gelen çap değerini, Z_{95} ; standart normal dağılım tablosundan $d_{\%95}$ değerine karşılık gelen değer, x_m ; örnek alandaki çapın mod değeri, d_{maks} ; örnek alandaki maksimum çap değeri ve d_{min} ; örnek alandaki minimum çap değerini göstermektedir.

2.2.3 Derin Öğrenme Algoritmaları


Bu çalışmada, çap dağılımlarının modellenmesinde geleneksel olasılık yoğunluk fonksiyonlarının yanı sıra, günümüzün yenilikçi yapay zeka tekniklerinden biri olan çok katmanlı Yapay Sinir Ağı Modeli (DÖA) türündeki Derin Öğrenme Algoritmaları (DÖA) da kullanılmıştır. Ormancılık alanında çap dağılımlarının modellenmesi, 1940'lı yıllardan itibaren yoğun bir şekilde kullanılmaya başlanmış ve bu modeller genellikle çeşitli olasılık yoğunluk fonksiyonlarına dayanmaktadır. Bu fonksiyonlar arasında Normal, Gamma, Beta, Weibull ve Johnson gibi türler bulunmakta olup, kullanılan fonksiyon tipinin seçimi, çap dağılımlarının doğru bir şekilde modellenmesinde büyük bir başarı faktörü olarak karşımıza çıkmaktadır. Çap dağılımı modellemesi üzerine yapılan literatür incelemeleri, pek çok farklı olasılık yoğunluk fonksiyonunun kullanıldığını ve bu fonksiyonların başarı düzeylerinin karşılaştırıldığını ortaya koymaktadır. Bununla birlikte, son yıllarda ormancılık alanında, fonksiyonel tanımlamalar yapılmaksızın karmaşık ilişkilerin modellenmesinde yüksek doğrulukla tahminler yapabilen Yapay Sinir Ağları (YSA), alternatif bir modelleme yöntemi olarak dikkat çekmektedir (Esteban *et al.* 2009, Atkinson and Tatnall 1997, Ashraf *et al.* 2013). Bu bakımdan, olasılık yoğunluk fonksiyonlarının kullanımında çap dağılımı modellemesinde, istatistiksel modelleme süreçlerinde önemli bir adım olan fonksiyon tipinin belirlenmesi gerekliliğini ortadan kaldıran Yapay Sinir Ağı (YSA) modelleri, ormancılık artım ve büyüme modellemelerinde regresyon modellerine alternatif bir tahmin yöntemi olarak önerilmektedir. YSA'nın bu avantajı, daha esnek ve fonksiyonel tanımlama gerektirmeyen yapısı ile dikkat çekmektedir (Özçelik vd. 2010, Ashraf *et al.* 2013, Diamantopoulou *et al.* 2015).

Yapay Sinir Ağı (YSA) modelleri, insan sinir hücrelerinin işleyişini ve bu hücrelerdeki veri aktarım süreçlerini temel alarak geliştirilmiştir. Bu modeller, giriş katmanı (Input layer), gizli ya da ara katman (Hidden layer) ve çıktı katmanı (Output layer) olmak üzere üç ana katmandan oluşan bir yapı sergiler (Freeman ve Skapura 1991). Yapay zekanın ilk geliştirilen ve en yaygın kullanılan örneklerinden biri olan Yapay Sinir Ağları, genellikle giriş (input layer), gizli (hidden layer) ve çıktı (output layer) katmanlarından oluşan sınırlı sayıda katmandan meydana gelirken, Derin Öğrenme

Algoritmaları (DÖA), çok daha karmaşık bir yapıdadır. DÖA'lar, çok sayıda katman (örneğin, 5, 10 veya hatta onlarca katman) içerecek şekilde tasarlanmış olup, bu sayede daha derin ve daha sofistike öğrenme süreçlerini mümkün kılmaktadır. Derin öğrenme kavramı, 2010'lu yıllarda yaygın olarak kullanılmaya başlanmış olup, özellikle büyük veri setlerinin (milyonlarca hatta milyarlarca veri) çok katmanlı bir yapıda analiz edilmesi, bu yöntemlerin etkin ve başarılı sonuçlar elde etmesine olanak sağlamıştır. Derin öğrenme, yapısal olarak Yapay Sinir Ağları (YSA) ile benzerlik gösterse de, YSA'lar genellikle sadece 1-2 katman ve 20-30 nöron ile sınırlı bir yapıya sahipken, derin öğrenme modelleri 5-10 katman ve yüzlerce hatta binlerce nöron içerebilen oldukça karmaşık bir yapıdadır. Bu karmaşıklık, derin öğrenme ve diğer yapay zeka tekniklerinin, insan beyninin öğrenme ve karar verme süreçlerinden esinlenerek geliştirilmiş olmasından kaynaklanmaktadır. Güncel literatürde, orman büyüme tahminleri için Yapay Sinir Ağları (YSA) kullanımına dair bir dizi çalışma yapılmış olsa da, Derin Öğrenme Algoritmalarını (DÖA) kullanan bilimsel çalışmalar henüz erken aşamalarda. Bu alandaki araştırmalar, Derin Öğrenme tekniklerinin potansiyelini keşfetmeye yönelik ilk adımları atmaktadır.

Derin Öğrenme Algoritmaları (DÖA), yapısal olarak Yapay Sinir Ağı (YSA) modellerinin katmanlı yapısını temel alır ve genellikle beş ana bileşenden oluşur: girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar (Öztemel, 2006). DÖA modellerinde öğrenme süreçleri, geri yayılım (backpropagation) ve ileri besleme (feed-forward) ağları kullanılarak gerçekleştirilir. Bu yöntem, ağın her bir katmanında öğrenilen bilgilerin bir sonraki katmana iletilmesini sağlayarak modelin doğru tahminler yapmasına olanak tanır. Bu çalışmada kullanılan ağ yapılarına bir örnek olarak, 3 ara katmanlı Derin Öğrenme Algoritması (DÖA) modelinin yapısı Şekil 2.2'de sunulmaktadır (Ercanlı vd. 2023b). Modelin yapısını incelediğimizde, ilk aşamada tahmin yapılacak sistemdeki girdi değişkenleri (input variables) ve çıktı değişkeni (output, target variable) tanımlanmakta, ardından DÖA modeli, bu değişkenler arasındaki ilişkileri analiz ederek, tahmin başarısını en üst düzeye çıkaracak ve hata oranını minimize edecek şekilde ağırlıkları öğrenmektedir (Fırat 2002). Yapay zeka literatüründe "ağ öğrenmesi" (network training) olarak tanımlanan bu süreçte, DÖA ile çok sayıda farklı ağırlık değeri türetilir ve bu ağırlıklar, toplam ve aktivasyon

fonksiyonları kullanılarak çıktı tahminlerine dönüştürülür. DÖA ile elde edilen tahminler, başlangıçta tanımlanan çıktı değişkenine ilişkin gözlem değerleriyle karşılaştırılarak, hata değerleri hesaplanır. Bu hataların zaman içindeki değişimi analiz edilerek, hataların minimuma indirildiği ve değişimlerin sabitlendiği noktada öğrenme süreci tamamlanır (Fırat 2002, Fırat ve Güngör 2004).



Şekil 2.2 3 ara katmanlı DÖA modeline ilişkin model yapısı (Ercanlı vd. 2023b)

Derin Öğrenme Algoritmaları (DÖA) ve genel olarak tüm yapay zeka modellerinde eğitim süreci sırasında, ağ yapısında tahmin edilecek çıktı değişkeni (target variable) ile bu tahminlerin elde edilmesinde kullanılacak girdi değişkenlerine karar verme süreci oldukça önemlidir. Çap dağılım modellerinde, örneğin, çıktı değişkeni olarak çap kademesindeki hektardaki ağaç sayısı belirlenirken, girdi değişkenleri genellikle olasılık yoğunluk fonksiyonlarının parametrelerinin hesaplanmasında kullanılan moment ve yüzdelik değerleridir. Bu çalışmada, örnek alanlarda, 4 cm'lik çap kademelerindeki hektardaki ağaç sayılarının toplam ağaç sayılarına oranları çıktı değişkeni olarak alınarak eğitimler gerçekleştirilmiştir. DÖA modellerinde giriş değişkenleri olarak ise, farklı parametre tahmin yöntemlerinden en başarılı sonuçları veren 3 parametrelili Weibull ve 4 parametrelili Johnson SB fonksiyonlarının parametrelerini tahmin etmek yerine, çap dağılımlarına ilişkin moment ve yüzdelik değerleri esas alınmıştır.

Bir DÖA modelinde, katman sayısı, nöron sayısı ve aktivasyon fonksiyonu gibi algoritma parametrelerinin belirlenmesi, tahmin sonuçlarının doğruluğunu ve başarısını

etkileyen kritik faktörlerdir. Bunun yanı sıra, özellikle derin öğrenme ile tahmin edilecek çıktı değişkeni (target variable) ile tahminde kullanılacak girdi değişkenlerinin belirlenmesi de ağın performansını doğrudan etkileyen önemli bir süreçtir. Bu parametrelerden, katmanlar arasındaki bağlantıyı sağlayan ve eşleşmeyi yönlendiren aktivasyon fonksiyonu, DÖA modellerinin birçok tek ağaç ve meşcere özelliğindeki eğrisel gelişimleri (nonlinear trend) başarıyla modellemesine olanak tanır. Bu özellik, derin öğrenme yöntemlerinin doğrusal olmayan (nonlinear) ilişki ve yapıların öngörülmesindeki etkinliğini artırmaktadır. Derin Öğrenme Algoritmaları (DÖA), oldukça ileri düzeyde eğrisel (nonlinear) gelişim gösterebilen modellerdir ve bu özellikleri sayesinde tek ağaç ve meşcere özelliklerini tahmin etmede yüksek başarılar elde edebilirler. Ancak, bu güçlü eğrisel modelleme kapasitesi, DÖA modellerinde aşırı uyum (overfitting) problemine yol açabilmektedir. Özellikle 3 veya daha fazla ara katman ve yüzlerce nöron içeren DÖA yapıları, genellikle genel eğrisel trendlerin ötesine geçerek, neredeyse her bir veriyi tam olarak temsil eden bir model oluşturabilmektedirler (Hawkins 2004, Cosenza *et al.* 2021). Bu durum, modelin eğitildiği verilere aşırı derecede uyum sağlayarak, yeni ve daha genel verilerle tahmin yapma yeteneğini zayıflatabilir. Ara katman sayısının ve her katmandaki nöron sayısının artması, aşırı uyum sorununun şiddetini artırmakta ve modelin daha dar bir veri setine odaklanarak genel geçer tahminler üretme yeteneğini sınırlamaktadır (Hawkins 2004). Bu sebeple, DÖA modellerinin parametrelerini dikkatlice seçmek ve modelin doğruluğunu test etmek, aşırı uyum riskini minimize etmek açısından oldukça önemlidir.

Derin Öğrenme Algoritmaları (DÖA) modellerinde aşırı uyum sorununu azaltmaya yönelik çeşitli çözüm önerileri bulunmaktadır. Diamantopoulou (2006), Özçelik vd. (2008), Özçelik vd. (2013), Diamantopoulou *et al.* (2015), Diamantopoulou and Özçelik (2012) ve Nunes and Görgens (2016) gibi araştırmacılar, K tekrarlı çapraz validasyon (K-Cross-Validation resampling procedure) yöntemini aşırı uyum sorununu engellemek için önermişlerdir. Ancak, bu yöntemin aşırı uyum problemini tamamen ortadan kaldırmada etkisinin sınırlı kaldığı gözlemlenmiştir. K-Cross-Validation, modelin genel performansını değerlendirirken bazı düzeyde aşırı uyumu azaltabilse de, özellikle derin öğrenme gibi kompleks model yapılarında, modelin veriye aşırı uyum sağlaması ve bu

uyumu engelleme konusundaki etkisi genellikle yetersiz kalabilmektedir. Yapay zeka literatüründe, ağ eğitimi süreçlerini yöneten etkili parametrelerin dikkatlice seçilmesi ve özelleştirilmesi, aşırı uyum (overfitting) sorununa çözüm olarak önerilmektedir. Bu parametreler, "hiper parametreler" (hyper-parameters) olarak adlandırılmakta ve bu parametrelerin özelleştirildiği DÖA modelleri, "hiper parametrize edilmiş Derin Öğrenme Algoritmaları" (hyper-parameterized Deep Learning Algorithms models) olarak tanımlanmaktadır (Brynjolfsson and Mitchell 2015, McCorduck 2004, Bengio 2012). Hiper parametrelerin özelleştirilmesi, modelin genel performansını iyileştirerek aşırı uyumu azaltabilir. Bu bağlamda, ilk değerlendirilebilecek hiper parametreler arasında öğrenme oranı (learning rate) ve momentum oranı (moment rate) gibi parametreler yer almaktadır. Bu parametrelerin doğru bir şekilde ayarlanması, ağın öğrenme sürecini optimize ederek daha sağlam ve genelleştirilmiş bir model elde edilmesini sağlayabilir.

Yapay zeka modellerinin eğitim süreçlerinin genel bir özelliği olarak, DÖA'ların ağırlık değerleri, ilk aşamada rasgele olarak atanıp, ilk tahmin değerleri ise, gözlemlerle karşılaştırılarak, tahmin değerleri ile gözlem değerleri arasındaki farktan (hata) bir hata hesaplanır. Bu hata, geri yayılım (back-propagation) yöntemiyle ağın önceki katmanlarına iletilir. Böylece, ağırlıkların güncellenmesi sağlanır. Bu süreç, modelin öğrenme kapasitesini artırmak amacıyla birden fazla kez (epoch) tekrarlanır ve bu tekrarlamalar sonucunda modelin tahmin yeteneği optimize edilir (Khandetsky *et al.* 2002). Bu iteratif öğrenme sürecinde, hata her adımda minimize edilmeye çalışılır ve öğrenme oranı, ağırlık güncellemelerinin hızını belirleyen önemli bir parametre olarak etkisini gösterir. Öğrenme oranının bu süreçteki rolü, aşağıdaki Denklem (2.3) ve (2.4) ile matematiksel olarak ifade edilmiştir (Jacobs 1988).

$$\omega_j := \omega + \Delta\omega_j \quad (2.3)$$


$$\Delta\omega_j = \eta \cdot \sum_i hata(gözlem^i - tahmin^i) \quad (2.4)$$

Bu formüllerde, ω_j ; belirli bir aşamadaki ağırlık değerini, $\Delta\omega_j$; ağırlık değerindeki değişimi, gözlem¹: eğitimde kullanılan hedef değişkenin ölçülmüş değerini ve tahmin¹: ağırlık değerinin değiştirilmesi ile ağ modelinin tahmin ettiği değeri ve η ; öğrenme oranı değerini göstermektedir. Öğrenme oranı (η), 0 ile 1 arasında değerlere sahiptir. Bu formülde, öğrenme oranı, hatanın bir sonraki aşamadaki ağırlık güncellemelerine ne kadar yansıtacağını belirleyen bir parametre olarak karşımıza çıkmaktadır. Öğrenme oranının büyüklüğü, öğrenme sürecinin hızını ve etkinliğini önemli ölçüde etkileyen bir faktördür. Eğer öğrenme oranı çok küçük seçilirse, eğitim süreci yavaş ilerler ve çoğu donanım altyapısı (özellikle bilgisayar belleği) bu süreci tamamlamakta zorlanabilir. Öte yandan, öğrenme oranı çok büyük seçildiğinde, ağ hızlı bir şekilde öğrenmeye çalışırken, bu durum modelin başarısız sonuçlar üretmesine yol açabilir (Peace *et al.* 2015). Bu nedenle, öğrenme oranının doğru bir şekilde ayarlanması, etkili ve verimli bir eğitim süreci için kritik öneme sahiptir. Öte yandan, öğrenme oranı çok büyük bir değerde seçildiğinde, ağ modellerinde dengesiz ve aşırı değişken bir öğrenme süreci ortaya çıkabilir, bu da osilasyon (dalgalanma) sorununa yol açar (Yu *et al.* 1995). Bu nedenle, öğrenme oranının doğru ve etkin bir şekilde seçilmesi, hem başarılı tahminlerin elde edilmesini hem de aşırı uyum (overfitting) sorunundan kaçınılması için daha genel geçer ve verimli ağ eğitimlerinin gerçekleştirilmesini sağlar.

Öğrenme oranının yanı sıra, diğer önemli bir hiperparametre de moment oranıdır. Bu parametre, önceki aşamalardaki ağırlık değerlerinin üssel ağırlıklandırılmış ortalaması olarak hesaplanır. Moment oranının yeni ağırlık değerlerinin hesaplanmasında kullanılması, ağ eğitiminin başarısına önemli katkılarda bulunur (Sutskever *et al.* 2013). Öğrenme oranı gibi 0 ile 1 arasında bir değer alabilen moment oranı, bir anlamda önceki ağırlık değerlerindeki değişimlerin, bir sonraki ağırlık hesaplamalarında eğitim başarısını artıracak şekilde dikkate alınmasıdır (Qian 1999). Bu, modelin daha hızlı ve daha kararlı bir şekilde öğrenmesini sağlar, çünkü geçmişteki öğrenme süreçlerinden elde edilen bilgiler, ağırlık güncellemelerinde etkin bir şekilde kullanılır.

Bu çalışmada, Derin Öğrenme Algoritmaları (DÖA) modellerinin eğitiminde aşırı uyum sorununu çözmeye yönelik olarak, öğrenme oranı ve moment oranı gibi iki önemli hiperparametrenin özelleştirildiği eğitim stratejilerinin yanı sıra, "Erken Durdurma

(Early Stopping with RMSE)" gibi yapay zeka literatüründe aşırı uyum sorununa çözüm olarak geliştirilmiş bir eğitim stratejisi de kullanılmıştır. DÖA modellerinin eğitim süreçlerinde her bir döngü (epoch) boyunca, ağırlıkların güncellendiği aşamalarda, hem eğitim verisinin hem de test verisinin hata değerleri izlenmiştir. Özellikle, eğitim ve test verisi hata değerleri arasındaki farkın artmaya başlaması, aşırı uyum probleminin oluştuğunu gösteren bir işaret olup, bu durumda ağırlık eğitimi süreci durdurulmaktadır. Bu yaklaşım, "Erken Durdurma" (Early Stopping with RMSE) stratejisi olarak adlandırılır ve modelin, eğitim verisini ezberlemek yerine, daha genellenebilir sonuçlar üretmesini sağlamayı amaçlar (Thike *et al.* 2020). Şekil 2.3'te bu stratejiye ilişkin grafiksel bir gösterim sunulmuştur (Ercanlı *et al.* 2023b). Bu stratejiye göre, belli bir epoch sayısından sonra eğitim ve test verisi hata değerleri arasındaki farkın artması, aşırı uyumun en belirgin göstergesi olup, eğitim verisinde başarılı olan ancak test verisinde başarısız olan bir modelin ortaya çıkmasına yol açmaktadır. Bu durumda, ağırlık verileri ezberlememesi için eğitim, en son hesaplanan ağırlık değerleri ile sonlandırılır (Shao *et al.* 2011).



Şekil 2.3 Erken Durdurma Stratejisinin şekilsel gösterimi (Ercanlı vd. 2023b)

Bu çalışmada, çap kademelerindeki hektardaki ağaç sayısını (çıktı değişkeni) belirli girdi değişkenlerine (input variables) göre tahmin etmek amacıyla, İleri Beslemeli-Geri Yayımlı (feed-forward backprop artificial neural network) Derin Öğrenme Algoritmaları (DÖA) kullanılmıştır. Bu eğitim süreçleri, R yazılım diliyle oluşturulmuş ve kodlanmış H20 paketi ile gerçekleştirilmiştir (H20.ai Team 2018). H20, açık kaynak

kodlu bir yapay zeka platformu olup, birçok yapay zeka uygulamasını içermektedir. Özellikle, R yazılımı ile kodlanmış olan H2O paketi, çok sayıda veri ve değişken içeren sistemlerin analizinde oldukça etkin, hızlı ve başarılı sonuçlar elde edilmesini sağlamaktadır. Bu platform, karmaşık derin öğrenme algoritmalarını çözme ve tahmin yapma kapasitesine sahip olup, bu yönüyle derin öğrenme modelleri için güçlü bir araç sunmaktadır (H2O.ai Team 2018).

Bu çalışmada, DÖA modellerinin eğitiminde önemli parametrelerden biri olan aktivasyon fonksiyonu, daha önceki çalışmalarda başarılı tahminler sağladığı belirlenen hiperbolik tanjant sigmoid (hyperbolic tangent sigmoid) fonksiyonu olarak seçilmiştir. Ayrıca, DÖA modellerindeki diğer önemli bir parametre olan gizli katman sayısı, özellikle bu çalışmada eğitilen yapay zeka modellerinin Derin Öğrenme Algoritmaları (DÖA) olarak adlandırılması nedeniyle, farklı sayılarda gizli katman seçenekleriyle değerlendirilmiştir. Yapay sinir ağları 3 veya daha fazla gizli katmana sahip olduğunda Derin Öğrenme Algoritması olarak kabul edildikleri için, eğitim süreçlerinde 3 gizli katmandan başlayarak 10 gizli katmana kadar farklı yapılandırmalar kullanılmıştır. Bu bağlamda, 3, 5, 7 ve 10 gizli katmanlı yapı seçenekleri (toplamda 4 farklı alternatif) ile DÖA modellerinin eğitimleri gerçekleştirilmiştir. Nöron sayısı olarak ise, ön analizlerde başarılı tahminler verdiği belirlenen 100 nöron seçeneği esas alınmış ve eğitimler bu nöron sayısı ile yapılmıştır.

Bu çalışmada, aktivasyon tipi ve nöron sayısı sabit tutulmuş ve 4 farklı gizli (ara) katman sayısı seçeneğiyle birlikte 3 farklı hiperparametre (öğrenme oranı, moment oranı ve erken durdurma) değerlerinin özelleştirilmesi sağlanarak DÖA modellerinin eğitimleri gerçekleştirilmiştir. Hiperparametrelerden öğrenme oranı ve moment oranı için, 0.000001, 0.000005, 0.00001, 0.00005, 0.0001, 0.0005, 0.001, 0.005, 0.003, 0.01, 0.02, 0.03, 0.04, 0.05, 0.06, 0.07, 0.08, 0.09, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9 ve 0.99 gibi 28 farklı seçenek ile, H2O paketindeki h2o.deeplearning fonksiyonunun "rate" ve "momentum_start" argümanları özelleştirilmiştir. Diğer bir hiperparametre olan erken durdurma (Early Stopping with RMSE) için ise; 0.000001, 0.000005, 0.00001, 0.00005, 0.0001, 0.0005, 0.001, 0.005, 0.003, 0.01, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8 ve 0.9 gibi 19 farklı değer, h2o.deeplearning fonksiyonunun "stopping_metric = RMSE"

argümanı ile özelleştirilerek DÖA modellerinin eğitimleri yapılmıştır (H20.ai Team, 2018). Bu düzenleme ile, öğrenme oranı için 28, moment oranı için 28, erken durdurma için 19 seçenek olmak üzere toplam 75 farklı hiperparametre kombinasyonu oluşturulmuş ve 4 farklı gizli katman sayısı alternatifi ile birlikte (toplamda 300 seçenek = 75 X 4), 3 farklı hiperparametre seçeneği de hesaba katıldığında, toplam 900 (300 X 3) DÖA modeli eğitimi gerçekleştirilmiştir. Bu eğitimler, örnek alanın %75'ini oluşturan 306 adet örnek alan verisiyle yapılmış ve geri kalan %25'lik veri dilimi olan 102 örnek alan verisi (test verisi, validation data set) kullanılarak eğitimlerin özellikle aşırı uyum (overfitting) açısından değerlendirilmiştir. Eğitim süreçleri, R yazılım dilindeki H20 paketinin "For Next" döngüsü (loop) kullanılarak çok sayıda farklı ağ alternatifi için gerçekleştirilmiştir (H20.ai Team 2018).

2.2.4 Modellerin değerlendirme süreçleri ve başarı ölçütleri

Bu çalışmada, çap dağılımlarının modellemesinde kullanılan 3 parametrelili Weibull ile 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonlarının parametrelerinin tahminine ilişkin maksimum olabilirlik yöntemi, moment ve yüzdelik değerlerini esas alan yöntemler ile yapay zeka modeli olan DÖA modellerin başarı durumlarını karşılaştırmak üzere sekiz farklı başarı ölçütü kullanılmıştır. Bu ölçütler: (1) Ortalama Mutlak Hata (OMH), (2) Hata Kareler Ortalamasının Karekökü (HKOK), (3) Yüzde Hata Kareler Ortalamasının Karekökü (HKOK%), (4) Ortalama Hata (Bias), (5) Ortalama Hata Yüzdesi (Bias%), (6) Belirtme Katsayısı (R^2), (7) Akaike Bilgi Ölçütü (AIC) ve (8) Bayesian Bilgi Ölçütü (BIC) değerleridir. Bu ölçütler kullanılarak yapılan değerlendirmede, OMH, HKOK, HKOK%, Bias, Bias%, AIC ve BIC değerlerinin olabildiğince düşük olması ve Belirtme Katsayısı (R^2) değerinin ise 1'e yakın olması durumunda modelin başarılı olduğu esas alınmıştır. Kullanılan başarı ölçüt değerlerinin formülleri, Denklem (2.5)-(2.12)'de verilmiştir.

$$OMH = \sum_{i=1}^n |Y_i - \hat{Y}_i| / n \quad (2.5)$$

$$HKOK = \sqrt{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 / (n - k)} \quad (2.6)$$

$$HKOK\% = \left(\left[\sqrt{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 / (n - k)} \right] / \bar{Y}_i \right) \cdot 100 \quad (2.7)$$

$$Bias = \sum_{i=1}^n (Y_i - \hat{Y}_i) / n \quad (2.8)$$

$$Bias\% = \left(\left[\sum_{i=1}^n (Y_i - \hat{Y}_i) / n \right] / \bar{Y}_i \right) \cdot 100 \quad (2.9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)}{\sum_{i=1}^n (Y_i - \bar{Y}_i)} \quad (2.10)$$

$$AIC = n \cdot \ln(HKOK) + 2 \cdot k \quad (2.11)$$

$$BIC = n \cdot \ln(HKOK) + n \cdot \ln(k) \quad (2.12)$$

Burada, n: veri sayısını, k: parametre sayısını, $\hat{Y}_i$: tahmin yöntemleri ile tahmin edilen örnek alandaki çap kademlerindeki hektardaki ağaç sayısı değerini, Y_i : ölçülen örnek alanların çap kademlerindeki hektardaki ağaç sayısı değerini, $\bar{Y}$: ölçülen çap kademlerindeki hektardaki ağaç sayısı değerlerini göstermektedir.

Bu çalışmada, 3 parametrelili Weibull ve 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonlarının parametrelerinin hesaplanmasında kullanılan yöntemlerin başarı durumlarının karşılaştırılmasında, tüm başarı kriterlerini içeren kapsamlı bir başarı değerlendirmesi temel alınmıştır. Bu değerlendirme, her bir yöntemle elde edilen sonuçların doğruluğu, güvenilirliği ve genel performansını kapsamlı bir şekilde analiz etmek amacıyla yapılmıştır. Bu değerlendirmede, rölatif sıralama yöntemi (Poudel ve Cao 2013) kullanılmıştır. Önceki çalışmalarda kullanılan standart karşılaştırma yönteminde, belirli bir başarı kriterine göre başarılı kabul edilen tahmin modeli 1 numara ile, başarısız olanlar ise 2 ve devamındaki numaralarla sıralanmıştır. Ancak, rölatif sıralama yöntemi, başarı kriterlerinin birbirine olan farklarını dikkate alarak daha etkin ve doğru bir değerlendirme sunmaktadır. Bu yaklaşım, her bir kriterin önem derecesini ve birbirleriyle olan ilişkilerini göz önünde bulundurarak, daha ayrıntılı ve adil bir sıralama yapmaktadır (Özçelik ve Çevlik 2017, Özdemir 2018). Bu yöntemle elde edilen rölatif sıra değeri, Poudel and Cao (2013) tarafından önerilen aşağıdaki Denklem (2.13) ile hesaplanmıştır.

$$R_i = 1 + \frac{(m-1) \cdot (S_i - S_{min.})}{(S_{max.} - S_{min.})} \quad (2.13)$$

Bu formülde, R_i : i. yöntemin rölatif sırasını, S_i : i. yönteme ilişkin başarı ölçüt değerini, $S_{min.}$: en düşük başarı ölçüt değerini, $S_{max.}$: en yüksek başarı ölçüt değerini ifade etmektedir. Özellikle, rölatif sıra değerleri hesaplandıktan sonra, toplam rölatif sıra değeri en küçük olan parametre tahmin modeli ise; en başarılı şekilde ağaçların çap dağılımlarını tahmin eden yöntem olarak belirlenmiştir.

En başarılı olarak belirlenen parametre tahmin yöntemi ile parametreleri hesaplanan olasılık yoğunluk fonksiyonun ve derin öğrenme algoritmasının tahminlerinin verilerin elde edildiği örnek alanlara istatistiksel olarak uygunluğu, Kolmogorov-Simirnov testi ile analiz edilmiştir. Bu testin gerçekleştirilmesinde, R dilindeki “*ks.test*” temel fonksiyonu kullanılmış (R Core Team 2024), ayrıca daha tutarlı tahminler elde etmek üzere de, Bootstrap yöntemi ile p-değerleri hesaplanmıştır.

3. BULGULAR VE TARTIŞMA

3.1. Olasılık Yoğunluk Fonksiyonlarına ilişkin sonuçlar

Bu çalışma kapsamında, çap dağılımlarının modellenmesine ilişkin kullanılan 3 parametrelili Weibull ve 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonlarının parametrelerinin tahmin edilmesinde kullanılan maksimum olabilirlik yöntemi, dağılım momentlerini ve yüzdeliklerini esas alan eşitlikler ve bu iki yöntemin birlikte kullanıldığı hibrit yöntemine ilişkin eşitlikler ile parametre değerleri hesaplanmıştır. Olasılık yoğunluk fonksiyonlarının parametrelerini hesaplamada kullanılan yöntemlere ilişkin hesaplanan başarı ölçütleri, Çizelge 3.1’de ve rölatif başarı sıraları ise Çizelge 3.2’de verilmiştir.

3 parametrelili Weibull ve 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonlarına ilişkin 8 farklı başarı ölçütünün birlikte değerlendirmesini ortaya koyan rölatif sıra numaralarının toplamaları dikkate alındığında (Çizelge 3.2.), 23.328’lik rölatif başarı sırası toplamına sahip olan ve göğüs çaplarının küçükten büyüğe doğru sıralandığında %31 ve %63’lik sırasına karşılık çap değerlerini esas alan yüzdelik yöntemi ile parametreleri hesaplanan 3 parametrelili Weibull olasılık yoğunluk fonksiyonu, çap dağılımlarını tahmin etmede en başarılı yöntem olarak belirlenmiştir. Bu modele ilişkin başarı ölçütleri ise, Ortalama Mutlak Hata (OMH) değeri, 41.701 adet/ha; Hata Karelerin Ortalamasının Karekökü (HKOK), 57.486 adet/ha; Yüzde Hata Kareler Ortalamasının Karekökü (HKOK%), % 55.481; Ortalama Hata (Bias), -8.931 adet/ha; Yüzde Ortalama Hata (Bias%), % -8.619; Belirtme Katsayısı (R^2), 0.701; Akaike Bilgi Ölçütü (AIC); 9590 ve Bayesian Bilgi Ölçütü (BIC); 11226 olarak elde edilmiştir.

En başarılı olarak belirlenen çap dağılımındaki ağaçların küçükten büyüğe sıralandığında %31 ve %63’lik sırasına karşılık çap değerlerini esas alan yüzdelik yöntemi ile parametreleri hesaplanan 3 parametrelili Weibull olasılık yoğunluk fonksiyonu ile tahmin edilen ağaç sayılarının istatistiksel olarak çalışma alanındaki verilere uygunluğu, Kolmogorov-Smirnov analizi ile test edilmiştir. Weibull olasılık yoğunluk fonksiyonun parametreleri ile çap sınıflarındaki ağaç sayıları tahmin edilen

306 örnek alandan 297 adeti (%97.05) 0.05 önem düzeyi ile çalışma alanındaki meşcereler uygun iken, 9 adetinin ise uygun olmadığı (%2.50) sonucuna varılmıştır.


Çizelge 3.1 Olasılık yoğunluk fonksiyonlarının parametrelerini hesaplamada kullanılan yöntemlere ilişkin hesaplanan başarı ölçütleri

Olasılık Yoğunluk Fonksiyonu ve Tahmin Yöntemi	OMH	HKOK	HKOK %	Bias	Bias%	R ²	AIC	BIC
Weibull-Maksimum Olabilirlik Yöntemi	48.122	65.695	64.529	-9.158	-8.996	0.576	9730	11337
Weibull- $\bar{d}$ ve d_{varyans} değerlerini esas alan moment yöntemi	40.400	57.114	54.390	-5.747	-5.473	0.719	9595	11234
Weibull- d_g ve d_{varyans} değerlerini esas alan moment yöntemi	40.328	57.021	54.302	-5.745	-5.471	0.720	9591	11230
Weibull-d31% ve d63% değerlerini esas alan yüzdelik yöntemi	41.701	57.486	55.481	-8.931	-8.619	0.701	9590	11226
Weibull-d50% ve d95% değerlerini esas alan yüzdelik yöntemi	42.825	59.220	56.327	-4.598	-4.373	0.697	9656	11291
Weibull- d_g , d25% ve d95% değerlerini esas alan hibrid yöntemi	40.590	56.637	54.236	-4.850	-4.645	0.708	9579	11219
Weibull- d_g , d31% ve d63% değerlerini esas alan hibrid yöntemi	42.632	59.297	57.125	-6.533	-6.294	0.683	9635	11266
Weibull- d_g , d25%, d50% ve d95% değerlerini esas alan hibrid yöntemi	41.520	57.544	54.575	-7.997	-7.585	0.718	9633	11276
Johnson SB- Maksimum Olabilirlik Yöntemi	55.631	74.591	74.990	-8.183	-8.227	0.398	9779	11347
Johnson SB- Koşullu Maksimum Olabilirlik Yöntemi	48.234	65.172	63.385	-7.063	-6.869	0.580	9824	11450
Johnson SB- Knoebel and Burkhart Yöntemi	43.998	59.868	56.806	-5.127	-4.865	0.697	9690	11327
Johnson SB- Mode Yöntemi	81.833	155.581	128.573	-16.492	-13.629	0.121	11481	13053
Johnson SB- Moments Yöntemi	47.962	64.972	63.166	-6.832	-6.642	0.589	9821	11447


Çizelge 3.2 Olasılık yoğunluk fonksiyonlarının parametrelerini hesaplamada kullanılan yöntemlere ilişkin hesaplanan rölatif sıra numaraları

Olasılık Yoğunluk Fonksiyonu ve Tahmin Yöntemi	OMH	HKOK	HKOK %	Bias	Bias%	R ²	AIC	BIC	Σ
Weibull-Maksimum Olabilirlik Yöntemi	3.253	2.099	2.662	8.399	7.007	3.886	1.953	1.770	31.029
Weibull- $\bar{d}$ ve d_{varyans} değerlerini esas alan moment yöntemi	1.021	1.058	1.025	11.840	11.574	1.018	1.100	1.099	29.734
Weibull- d_g ve d_{varyans} değerlerini esas alan moment yöntemi	1.000	1.046	1.011	11.843	11.577	1.000	1.075	1.074	29.626
Weibull-d31% ve d63% değerlerini esas alan yüzdelik yöntemi	1.397	1.103	1.201	8.629	7.495	1.389	1.069	1.044	23.328
Weibull-d50% ve d95% değerlerini esas alan yüzdelik yöntemi	1.722	1.313	1.338	13.000	13.000	1.472	1.487	1.473	34.805
Weibull- d_g , d25% ve d95% değerlerini esas alan hibrid yöntemi	1.076	1.000	1.000	12.745	12.648	1.238	1.000	1.000	31.706
Weibull- d_g , d31% ve d63% değerlerini esas alan hibrid yöntemi	1.666	1.323	1.466	11.047	10.510	1.737	1.352	1.306	30.408
Weibull- d_g , d25%, d50% ve d95% değerlerini esas alan hibrid yöntemi	1.345	1.110	1.055	9.570	8.836	1.036	1.340	1.371	25.662
Johnson SB-Maksimum Olabilirlik Yöntemi	5.424	3.177	4.350	9.382	8.003	7.464	2.264	1.835	41.901
Johnson SB- Koşullu Maksimum Olabilirlik Yöntemi	3.286	2.035	2.477	10.513	9.764	3.815	2.547	2.509	36.946
Johnson SB- Knoebel and Burkhart Yöntemi	2.061	1.392	1.415	12.466	12.362	1.471	1.701	1.704	34.572
Johnson SB- Mode Yöntemi	13.000	13.000	13.000	1.000	1.000	13.00	13.00	13.00	80.000
Johnson SB- Moments Yöntemi	3.207	2.011	2.442	10.746	10.058	3.621	2.528	2.494	37.105

Şekil 3.1’de, 2 farklı örnek alanın (1. ve 150. örnek alanlar) %31 ve %63’lik yüzdelik değerleri ile parametreleri hesaplanan 3 parametreli Weibull olasılık yoğunluk fonksiyonu ile çap basamaklarında tahmin edilen ağaç sayılarının, gözlemlenen çap basamaklarına ağaç sayısı dağılımlarına göre değişimleri verilmiştir. Şekil 3.2’de ise, söz konusu örnek alanların Knoebel and Burkhart Yöntemi ile parametreleri tahmin edilen Johnson SB fonksiyonu ile tahmin edilen ağaç sayılarının, gözlemlenen çap basamaklarına ağaç sayısı dağılımlarına göre değişimleri verilmiştir.





■ Gözlemlenen Ağaç Sayısı (Adet/ha) ▣ Weibull Fonskiyonu ile Tahmini Ağaç Sayısı (Adet/ha)



■ Gözlemlenen Ağaç Sayısı (Adet/ha) + Weibull Fonskiyonu ile Tahmini Ağaç Sayısı (Adet/ha)

Şekil 3.1 1 ve 150 numaralı örnek alanların gözlemlenen çap basamaklarına ağaç sayısı dağılımı ile 3 parametrelili Weibull fonksiyonu ile tahmin edilen ağaç sayısı dağılımı



Şekil 3.2 1. ve 150. numaralı örnek alanların gözlemlenen çap basamaklarına ağaç sayısı dağılımı ile 4 parametrelili Johnson SB fonksiyonu ile tahmin edilen ağaç sayısı dağılımı

3.2. Derin Öğrenme Algoritmalarına ilişkin sonuçlar

Bu çalışmada, “Olasılık Yoğunluk Fonksiyonlarına ilişkin sonuçlar” adlı bölümde gösterildiği gibi, 3 parametreleri Weibull fonksiyonunun parametrelerini d31% ve d63% değerlerini esas alan eşitliklerle tahmin eden yüzdelik yönteminin en başarılı yöntem olarak belirlenmesi nedeniyle, DÖA modelleri ile çap basamaklarındaki ağaç sayılarının tahmin edilmesinde, çap dağılımlarına ilişkin bir çok yüzdelik değerinden, %31 ve %63’lik sırasına karşılık çap değerleri (cm) esas alınmıştır. Böylece, DÖA modellerinin eğitiminde önemli bir konu olan ağ yapısının girdi değişkenlerinin belirlenme süreçlerinde, %31 ve %63’lik sırasına karşılık çap değerleri (cm) ile çap sınıfı değeri (cm) ile meşcere toplam ağaç sayısı (adet/ha) ve orta çap (dg, cm) değerleri, DÖA eğitimlerinde girdi/input değişken olarak esas alınmıştır. Çıktı değişkeni olarak da, çap sınıflarındaki ağaç sayısının toplam ağaç sayısına oranı esas alınarak, DÖA eğitimleri gerçekleştirilmiştir.

DÖA modelleri ile çap sınıflarındaki ağaç sayılarını tahmin etmek üzere farklı ara katman sayıları ile öğrenme oranı, moment oranı ve erken durdurmaya ilişkin çeşitli hiper parametre özelleştirmelerine dayanarak gerçekleştirilen eğitimler ile elde edilen derin öğrenme algoritmalarına ilişkin başarı ölçüt değerleri Çizelge 3.3’te ve rölatif başarı sıraları ise Çizelge 3.4’te verilmiştir. Bu rölatif başarı sıraları değerlendirildiğinde, 21.539’lik rölatif başarı sırası toplamına sahip olan 7 ara katmana sahip 0.001 değeri ile Moment oranı (Moment rate) hiper parametre özelleştirmesini içeren DÖA model yapısının çap sınıflarındaki ağaç sayılarını modellemede en başarılı DÖA modeli olduğu görülmektedir. Bu modele ilişkin başarı ölçütleri ise, Ortalama Mutlak Hata (OMH) değeri, 26.952 adet/ha; Hata Karelerin Ortalamasının Karekökü (HKOK), 36.756 adet/ha; Yüzde Hata Kareler Ortalamasının Karekökü (HKOK%), % 41.610; Ortalama Hata (Bias), -1.595 adet/ha; Yüzde Ortalama Hata (Bias%), % -1.806; Belirtme Katsayısı (R^2), 0.807; Akaike Bilgi Ölçütü (AIC); 7724 ve Bayesian Bilgi Ölçütü (BIC); 9205 olarak elde edilmiştir.

Bir yapay zeka modeli olan DÖA modellerinde önemli bir konu da aşırı uyum sorunu bakımından bu yapay zeka modellerinin değerlendirilmesidir. Bu kapsamda, en başarılı

olarak elde edilmiş 7 ara katmana sahip 0.001 değeri ile Moment oranı (Moment rate) hiper parametre özelleştirmesini içeren DÖA model kullanılarak denetim için ayrılmış 102 örnek alanın çap sınıflarındaki ağaç sayıları tahmin edilerek, başarı ölçütleri hesaplanmıştır. Bu en başarılı DÖA modelinin denetim verisi için uygulanması durumunda başarı ölçüt değerleri ise, Ortalama Mutlak Hata (OMH) değeri, 34.966 adet/ha; Hata Karelerin Ortalamasının Karekökü (HKOK), 49.193 adet/ha; Yüzde Hata Kareler Ortalamasının Karekökü (HKOK%), % 47.628; Ortalama Hata (Bias), -8.182 adet/ha; Yüzde Ortalama Hata (Bias%), % -7.922; Belirtme Katsayısı (R²), 0.784; Akaike Bilgi Ölçütü (AIC); 1905 ve Bayesian Bilgi Ölçütü (BIC); 2239 olarak elde edilmiştir. Bu değerler değerlendirildiğinde, 306 adet örnek alandan oluşan eğitim verisi ile eğitimleri gerçekleştirilen ve en başarılı olarak belirlenen DÖA modelinin 102 örnek alandan oluşan denetim verisi için kullanımı ile elde edilen bu başarı ölçüt değerlerinde önemli oranda bir düşüş ve kötüleşme yaşanmadığı görülmektedir. Bu bakımdan, öğrenme oranı, moment oranı ve erken durdurma gibi hiper parametre özelleştirmeleri ile eğitilen DÖA modellerinde, yapay zeka modellerinde söz konusu olabilen aşırı uyum sorunu gibi durumun olumsuz etkisinin çok önemli olmadığı değerlendirilebilir.

En başarılı olarak belirlenen 7 ara katmana sahip 0.001 değeri ile Moment oranı (Moment rate) hiper parametre özelleştirmesini içeren DÖA modelinin başarı durumunun değerlendirmesinde ve bu DÖA modeli ile tahmin edilen ağaç sayılarının istatistiksel olarak çalışma alanındaki verilere uygunluğunun analiz edilmesinde, Kolmogorov-Smirnov testi gerçekleştirilmiştir. Eğitimde kullanılan veriler (306 adet örnek alan) ile denetimde kullanılan veriler (102 örnek alan) için ayrı ayrı olmak üzere, eğitim verileri için 306 örnek alandan 304 adeti (%99.35) 0.05 önem düzeyi ile çalışma alanındaki meşcereler uygun iken, 2 adetinin ise uygun olmadığı (%0.65); denetim verileri için 102 örnek alandan 97 adeti (%95.1) 0.05 önem düzeyi ile çalışma alanındaki meşcereler uygun iken, 5 adetinin ise uygun olmadığı (%4.9) sonucuna varılmıştır.



Çizelge 3.3 DÖA modellerine ilişkin hesaplanan başarı ölçütleri

DÖA	OMH	HKOK	HKOK %	Bias	Bias %	R ²	AIC	BIC
3 ara katmana sahip 0.01 değeri ile Öğrenme oranı	35.163	45.093	45.547	22.263	22.487	0.740	7732	9134
5 ara katmana sahip 0.005 değeri ile Öğrenme oranı	32.316	41.732	44.427	14.354	15.281	0.743	7944	9415
7 ara katmana sahip 0.001 değeri ile Öğrenme oranı	31.375	40.507	44.077	10.962	11.928	0.761	7966	9453
10 ara katmana sahip 0.0005 değeri ile Öğrenme oranı	28.120	38.039	41.109	3.676	3.972	0.801	7638	9088
3 ara katmana sahip 0.00005 değeri ile Moment oranı	31.354	40.392	42.231	14.680	15.349	0.798	7938	9420
5 ara katmana sahip 0.9 değeri ile Moment oranı	29.441	39.577	43.765	-5.474	-6.053	0.784	7607	9036
7 ara katmana sahip 0.001 değeri ile Moment oranı	26.952	36.756	41.610	-1.595	-1.806	0.807	7724	9205
10 ara katmana sahip 0.0001 değeri ile Moment oranı	28.309	38.540	44.629	-1.905	-2.206	0.749	7526	8950
3 ara katmana sahip 0.001 değeri ile Erken Durdurma	31.477	41.350	43.248	10.743	11.236	0.777	8036	9528
5 ara katmana sahip 0.00005 değeri ile Erken Durdurma	29.750	39.380	42.805	3.509	3.814	0.767	7913	9401
7 ara katmana sahip 0.001 değeri ile Erken Durdurma	33.053	42.531	43.858	19.844	20.463	0.770	7876	9327
10 ara katmana sahip 0.3 değeri ile Erken Durdurma	30.874	40.710	42.838	5.678	5.975	0.768	7828	9288

Çizelge 3.4 DÖA modellerine ilişkin hesaplanan rölatif sıra numaraları

Olasılık Yoğunluk Fonksiyonu ve Tahmin Yöntemi	OMH	HKOK	HKOK %	Bias	Bias %	R ²	AIC	BIC	Σ
3 ara katmana sahip 0.01 değeri ile Öğrenme oranı	12.000	12.000	12.000	12.000	12.000	12.000	5.433	4.503	81.936
5 ara katmana sahip 0.005 değeri ile Öğrenme oranı	8.187	7.566	9.225	8.864	9.223	11.491	10.013	9.851	74.420
7 ara katmana sahip 0.001 değeri ile Öğrenme oranı	6.926	5.950	8.357	7.518	7.930	8.584	10.482	10.568	66.316
10 ara katmana sahip 0.0005 değeri ile Öğrenme oranı	2.565	2.693	1.000	4.629	4.864	1.840	3.402	3.621	24.614
3 ara katmana sahip 0.00005 değeri ile Moment oranı	6.897	5.797	3.782	8.993	9.249	2.443	9.871	9.950	56.982
5 ara katmana sahip 0.9 değeri ile Moment oranı	4.335	4.722	7.583	1.000	1.000	4.807	2.736	2.624	28.808
7 ara katmana sahip 0.001 değeri ile Moment oranı	1.000	1.000	2.242	2.538	2.637	1.000	5.271	5.851	21.539
10 ara katmana sahip 0.0001 değeri ile Moment oranı	2.818	3.354	9.726	2.416	2.483	10.579	1.000	1.000	33.376
3 ara katmana sahip 0.001 değeri ile Erken Durdurma	7.062	7.061	6.301	7.431	7.663	5.850	12.000	12.000	65.369
5 ara katmana sahip 0.00005 değeri ile Erken Durdurma	4.749	4.462	5.205	4.562	4.803	7.510	9.330	9.578	50.200
7 ara katmana sahip 0.001 değeri ile Erken Durdurma	9.173	8.620	7.815	11.041	11.220	6.976	8.537	8.166	71.549
10 ara katmana sahip 0.3 değeri ile Erken Durdurma	6.254	6.217	5.286	5.423	5.636	7.344	7.515	7.422	51.097

Şekil 3.3'te, 2 farklı örnek alan (1. ve 150. örnek alanlar) 7 ara katmana sahip 0.001 değeri ile Moment oranı (Moment rate) hiper parametre özelleştirmesini içeren DÖA modelinin ile çap basamaklarında tahmin edilen ağaç sayılarının, gözlemlenen çap basamaklarına ağaç sayısı dağılımlarına göre değişimleri verilmiştir.



Şekil 3.3 1. ve 150. numaralı örnek alanların gözlemlenen çap basamaklarına ağaç sayısı dağılımı ile DÖA modeli ile tahmin edilen ağaç sayısı dağılımı

4. SONUÇ VE ÖNERİLER

Bu çalışmada, Konya Orman Bölge Müdürlüğü, Ilgın Orman İşletme Müdürlüğü sınırları içerisinde yer alan Ilgın, Akşehir ve Aşağıçığil Orman İşletme Şefliklerinde yayılış gösteren saf Anadolu Karaçamı meşcerelerinin çap dağılımlarının modellenmesinde, bir yapay zeka modeli çeşidi olan Derin Öğrenme Algoritmalarının (DÖA) uygulanabilirliğinin ve başarı durumunun ortaya konulması amaçlanmıştır. Bu çalışmada, ilgili orman işletme şefliklerine ilişkin orman amenajmanı düzenlemek amacıyla gerçekleştirilmiş orman envanteri çalışmalarında alınmış olan 408 örnek alan verisi kullanılmış, gerek klasik çap dağılım modelleme tekniği olan Olasılık Yoğunluk Fonksiyonları gerekse yenilikçi bir tahmin tekniği olan Derin Öğrenme Algoritmaları ile çap dağılımları modellenmiş ve başarı durumları ortaya konulmuştur.

Bu çalışmada, çap dağılımlarının modellenmesine ilişkin çalışmalarda sıklıkla kullanılan olasılık yoğunluk fonksiyonlarından 3 parametrelili Weibull ile 4 parametrelili Johnson SB Fonksiyonları bu çalışmada da kullanılmıştır. Bu fonksiyonların parametrelerinin hesaplanmasında maksimum olabilirlik yöntemi ile çap dağılımlarının çeşitli yüzdellik ve moment değerleri ile bu moment ve yüzdellikleri birlikte içeren hibrid yöntemleri esas alan eşitlikler kullanılmıştır. Bu konudaki literatür değerlendirildiğinde, 3 parametrelili Weibull Fonksiyonu için Cao (2004) ve Poudel and Cao (2013) ve 4 parametrelili Johnson SB fonksiyonu için Scolforo *et al.* (2003) ve Gorgoso *et al.* (2012) çalışmaları öne çıkmaktadır. 3 parametrelili Weibull Fonksiyonun parametrelerini tahmin etmek üzere maksimum olabilirlik yöntemi, çap dağılımının momentlerini esas alan yöntemler, yüzdellik değerlerini esas alan yöntemler ve bu moment ve yüzdellikleri birlikte içeren hibrid yöntemlerine ilişkin 8 farklı eşitlik kullanılmıştır. Bu yöntemlerden, Yöntem (1)'te: Nelder-Mead optimizasyon algoritmasına dayanan maksimum olabilirlik eşitlikleri, Yöntem (2)'te: çap dağılımının moment değerleri olan çapların varyans değeri ve aritmetik ortalaması ($\bar{D}$) değerlerini kullanan eşitlikleri, Yöntem (3)'te: diğer moment değerleri olan aritmetik ortalaması ($\bar{D}$) ve göğüs yüzeyi orta ağacının çapı şeklinde hesaplanan orta çapı (D_g) değerlerini kullanan eşitlikleri, Yöntem (4)'te: çap değerlerinin küçükten büyüğe doğru sıralandığında %31 ve %63'lük yüzdellik değerlerine karşılık gelen çap değerlerini kullanan eşitlikleri, Yöntem (5)'te:

yüzdelik yöntemin diğer bir uygulaması olarak %50 ve %95’lik yüzdelik değerine karşılık gelen çap değerlerini kullanan eşitlikleri, Yöntem (6)’da: çap dağılımının moment ve yüzdelik değerlerini birlikte içeren ve hibrit yöntem olarak adlandırılan (Poudel and Cao 2013) yöntem olarak orta çapı (D_g), %25 ve %95’lik yüzdelik değerlerine karşılık gelen çap değerlerini kullanan eşitlikleri, Yöntem (7)’te: hibrit yöntemin diğer bir uygulaması olarak orta çapı (D_g), %31 ve %63’lük yüzdelik değerlerine karşılık gelen çap değerlerini kullanan eşitlikleri ve Yöntem (8)’te: hibrit yöntemin diğer bir uygulaması olarak orta çapı (D_g), %25, %50 ve %95’lik yüzdelik değerlerine karşılık gelen çap değerlerini kullanan eşitlikleri içerilmektedir. 4 parametrelili Johnson SB fonksiyonun hesaplanmasında: Nelder-Mead optimizasyon algoritmasına dayanan Maksimum Olabilirlik Yöntemi (Yöntem 1), Koşullu Maksimum Olabilirlik Yöntemi (Yöntem 2): Knoebel and Burkhart Yöntemi (Yöntem 3): Mode Yöntemi (Yöntem 4) ve Moments Yöntemi (Yöntem 5) olmak üzere beş farklı yöntemle ilişkin eşitlikler kullanılmıştır.

3 parametrelili Weibull ile 4 parametrelili Johnson SB fonksiyonlarının parametrelerinin hesaplanmasında R diline ilişkin kütüphaneler kullanarak gerekli kodlamalar yapılmış ve bu kütüphaneler aktif bir şekilde kullanılmış, bu kapsamda maksimum olabilirlik yöntemlerin uygulanmasında “*optim*” kütüphanesi, Weibull fonksiyonu için yukarıda söz edilen yöntemlerin uygulanmasında, “*tidyverse*”, “*mass*” ve “*actuar*” kütüphaneleri ve Johnson SB fonksiyonu için de “*dplyr*”, “*tidyr*”, “*SuppDists*”, “*moments*” ve “*optimx*” kütüphaneleri ile parametre tahminleri elde edilmiştir.

3 parametrelili Weibull ile 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonları ile örnek alanlardaki çap kademelerine göre elde edilen ağaç sayısı tahminleri ile aktüel mevcut ağaç sayıları değerlerine dayanan çap dağılımlarını tahmin etmedeki başarı durumlarının değerlendirilmesinde, Ortalama Mutlak Hata (OMH), Hata Kareler Ortalamasının Karekökü (HKOK), Yüzde Hata Kareler Ortalamasının Karekökü (HKOK%), Ortalama Hata (Bias), Yüzde Ortalama Hata (Bias%), Belirtme Katsayısı (R^2), Akaike Bilgi Ölçütü (AIC) ve Bayesian Bilgi Ölçütü (BIC) değerlerinden oluşan sekiz farklı başarı ölçütü kullanılmıştır. Bu başarı ölçütlerinin birlikte değerlendirilmesinde ise, bu başarı kriterlerinin birbirine olan farklarını dikkate alan

rölatif sıralama yöntemi (Poudel and Cao 2013) kullanılmıştır. Ayrıca, en başarılı olarak belirlenen olasılık yoğunluk fonksiyonun ve derin öğrenme algoritmasının tahminlerinin verilerin elde edildiği örnek alanlara istatistiksel olarak uygunluğu da, Kolmogorov-Simironov analizi ile test edilmiştir.

Bu çalışmada hesaplanan sekiz farklı başarı ölçütü birlikte değerlendirildiğinde, 3 parametrelili Weibull ile 4 parametrelili Johnson SB olasılık yoğunluk fonksiyonlarına ilişkin parametre tahmin yöntemlerinden, %31 ve %63'lük sırasına karşılık çap değerlerini esas alan yüzdelik yöntemi (Weibull fonksiyonuna ilişkin Yöntem 4) ile parametreleri hesaplanan 3 parametreli Weibull olasılık yoğunluk fonksiyonu, çap dağılımlarını tahmin etmede en başarılı yöntem olarak belirlenmiştir. Lohrey and Bailey (1977), çap dağılımlarını modelleyen Weibull fonksiyonun parametrelerinin hesaplanmasında, %24 ve %93'lük değerlere karşılık gelen çapları kullanmışlardır. McTague ve Bailey (1987), %10, %63 ve %93'lük değerlere karşılık gelen çapları kullanarak Weibull fonksiyonun parametrelerini hesaplamışlardır. Bailey (1989), minimum çap, göğüs yüzeyi orta ağacının çapı (Dg) ve %25, %50 ve %95'lik değerlere karşılık gelen çaplar ile Weibull fonksiyonuna ilişkin parametre hesabı yapmıştır. Bullock ve Burkhart (2005), göğüs yüzeyi orta ağacının çapı (Dg) ve %25 ve %97'lik değerler ile Weibull parametrelerini elde etmişlerdir. Poudel (2011) ve Karakaş (2013), farklı yüzdelikleri kullanarak çap dağılımlarını modelleme başarılarını karşılaştırdığı çalışmada; göğüs yüzeyi orta ağacının çapı (dg) ve %25, %50 ve %95'lik değerlere karşılık gelen çaplar yapılan parametre hesabına ilişkin yöntem, en başarılı tahmin sonuçlarını vermiştir. Bolat (2014), %31 ve %63'lük yüzdelik değerlere karşılık gelen çap değerlerini kullanan parametre tahmin yöntemi, farklı tür ve meşcere tiplerinden oluşan meşcerelerin çap dağılımlarını temsil etmede en başarılı parametre tahmin yöntemi olarak belirlemiştir. Bunun gibi Weibull fonksiyonun parametrelerinin hesaplanmasında çeşitli yüzdelikleri kullanan çalışmalarda (Brooks *et al.* 1992, Knowe *et al.* 2005, Lee and Coble 2006, Coble and Lee 2008, Jiang and Brooks 2009) farklı yüzdelik değerler; çap dağılımlarının modellenmesinde başarılı sonuçlar vermişlerdir. Ercanlı vd. (2013), 3-parametrelili Weibull fonksiyonunun parametrelerini çap dağılımının bazı yüzdelik ve moment değerleri ile tahmin etmiş ve en başarılı yöntemin %25, %50 ve %63'lük yüzdelik değerlerini kullanan yöntem olduğunu tespit etmiştir.

Ercanlı vd. (2016), %31, %50 ve %63'lük değerleri esas alan eşitliklere dayanan parametre tahmin yöntemi; çalışma alanındaki meşcerelerinin çap dağılımını modellemede en başarılı parametre tahmin yöntemi olarak belirlenmiştir.

3 parametrelili Weibull fonksiyonun bu parametre tahmin yöntemine ilişkin başarı ölçütleri ise, Ortalama Mutlak Hata (OMH) değeri, 41.701 adet/ha; Hata Karelerin Ortalamasının Karekökü (HKOK), 57.486 adet/ha; Yüzde Hata Kareler Ortalamasının Karekökü (HKOK%), % 55.481; Ortalama Hata (Bias), -8.931 adet/ha; Yüzde Ortalama Hata (Bias%), % -8.619; Belirtme Katsayısı (R^2), 0.701; Akaike Bilgi Ölçütü (AIC); 9590 ve Bayesian Bilgi Ölçütü (BIC); 11226 olarak elde edilmiştir. 3 parametrelili Weibull fonksiyonun bu parametre tahmin yöntemi ile elde edile tahminlerinin çalışma alanına uygunluğu için yapılan Kolmogorov-Smirnov analizi ile 306 örnek alandan 297 adeti (%97.05) 0.05 önem düzeyi ile çalışma alanındaki meşcereler uygun iken, 9 adetinin ise uygun olmadığı (%2.50) sonucuna varılmıştır.

Bu çalışmada, çap dağılımlarının modellenmesinde olasılık yoğunluk fonksiyonları yanında kullanılan diğer bir alternatif tahmin yöntemi de, bir çeşit yapay zeka modeli çeşidi olan Derin Öğrenme Algoritmaları (DÖA)'dır. DÖA ile çap dağılımlarının modellenmesinde, çap kademelerindeki ağaç sayılarının toplam ağaç sayısına oranı çıktı ya da hedef değişkeni (output ya da target variable) olarak eğitimler gerçekleştirilmiştir. Girdi değişkeni (input variable) olarak da, olasılık yoğunluk fonksiyonlarına ilişkin sonuçlarda çap dağılımlarının temsil edilmesinde ve modellenmesinde diğer yüzdelik değerlerden daha başarılı sonuçlar veren %31 ve %63'lük sırasına karşılık çap değerleri (cm) ile birlikte çap sınıfı değeri (cm), meşcere toplam ağaç sayısı (adet/ha) ve orta çap (Dg, cm) değerleri DÖA eğitimlerinde girdi/input değişken olarak esas alınmıştır. R yazılım dilinde oluşturulmuş (kodlanmış) H20 paketi kullanılarak yapılan eğitimlerde, daha önceki çalışmalarda da başarılı tahminler veren hiperbolik tanjant sigmoid (hyperbolic tangent sigmoid) fonksiyonu esas alınmış ve ayrıca nöron sayısı da 100 olarak sabit tutulmuştur. Yapay zeka literatüründe, 3 ve daha fazla ara katmana sahip çok katmanlı yapay sinir ağları derin öğrenme algoritması olarak adlandırıldığından, 3 gizli katmanlı yapıdan başlayıp 10 gizli katmana kadar ki, 3, 5, 7 ve 10 gizli katman

seenekleri (4 farklı gizli katman sayısı alternatifi) için DÖA modellerinin eğitimi gerçekleştirilmiştir.

Yapay zeka modellerinde söz konusu olan bir problem aşırı uyum sorunu, bu çalışmada da dikkate alınmış, DÖA eğitim süreçlerini yöneten ve yönlendiren parametreler olan öğrenme oranı “learning rate” ve moment oranı “moment rate” parametrelerin özelleştirildiği ve bir bakıma da hiper parametrize edilmiş DÖA modelleri “hyper-parameterized Deep Learning Algorithms models” olarak adlandırılan (McCorduck 2004, Bengio 2012) ağ eğitimleri gerçekleştirilmiştir. Ayrıca, aşırı uyum sorununun çözümüne katkı sağlaması için de, “Erken Durdurma (Early Stopping with RMSE)” adlı eğitim stratejisi içeren eğitimler gerçekleştirilmiştir. Böylece, 4 farklı gizli (ara) katman sayısı seçeneği ile birlikte 3 farklı hiper parametre (öğrenme oranı, moment oranı ve erken durdurma) çeşidi değerlerinin özelleştirilmesini içerecek şekilde toplam 900 (300 x 3) DÖA modeli eğitimleri, toplam örnek alanın %75’ine denk gelecek şekilde eğitim verisi olarak ayrılmış 306 adet örnek alan verisi için gerçekleştirilmiştir. Eğitilen DÖA modellerinin aşırı uyum sorunu bakımından değerlendirilmesinde, toplam verinin %25’ine denk gelen 102 örnek alan verisi (test verisi, validation data set) kullanılmıştır.

Bu çalışmada sekiz farklı başarı ölçütünün birlikte değerlendirildiği rölatif başarı sırasına göre, 7 ara katmana sahip 0.001 değeri ile Moment oranı (Moment rate) hiper parametre özelleştirmesini içeren DÖA model yapısının ap sınıflarındaki ağ ayılarını modellemede en başarılı DÖA modeli olduğu belirlenmiş olup; bu DÖA modeli için Ortalama Mutlak Hata (OMH) değeri, 26.952 adet/ha; Hata Karelerin Ortalamasının Karekökü (HKOK), 36.756 adet/ha; Yüzde Hata Kareler Ortalamasının Karekökü (HKOK%), % 41.610; Ortalama Hata (Bias), -1.595 adet/ha; Yüzde Ortalama Hata (Bias%), % -1.806; Belirtme Katsayısı (R^2), 0.807; Akaike Bilgi Ölçütü (AIC); 7724 ve Bayesian Bilgi Ölçütü (BIC); 9205 olarak elde edilmiştir. Eğitildiği veriler için bu başarı ölçüt değeri elde edilen en başarılı DÖA modelinin eğitiminde kullanılmayan bağımsız veriler için (102 örnek alan verisinden oluşan bağımsız veriler) de bu başarı ölçütleri, Ortalama Mutlak Hata (OMH) değeri, 34.966 adet/ha; Hata Karelerin Ortalamasının Karekökü (HKOK), 49.193 adet/ha; Yüzde Hata Kareler

Ortalamasının Karekökü (HKOK%), % 47.628; Ortalama Hata (Bias), -8.182 adet/ha; Yüzde Ortalama Hata (Bias%), % -7.922; Belirtme Katsayısı (R^2), 0,784; Akaike Bilgi Ölçütü (AIC); 1905 ve Bayesian Bilgi Ölçütü (BIC); 2239 olarak elde edilmiştir. DÖA modellerinin hem eğitildikleri hem de eğitiminde kullanılmayan bağımsız veriler için elde edilen tahmin başarıları yanında, tahmin edilen ağaç sayılarının istatistiksel olarak çalışma alanındaki verilere uygunluğu, Komogorov-Simirnov testi ile analiz edilmiş ve eğitim verileri için 306 örnek alandan 304 adeti (%99.35) 0.05 önem düzeyi ile çalışma alanındaki meşcerelere uygun iken, denetim verileri için 102 örnek alandan 97 adeti (%95.1) 0.05 önem düzeyi ile çalışma alanındaki meşcereler uygun olduğu belirlenmiştir.

Bu çalışmanın temel amacı olan yapay zeka tekniği DÖA modellerinin çap dağılımlarında kullanımı değerlendirildiğinde; en başarılı olarak belirlenen %31 ve %63'lük yüzdelik değerleri ile parametreleri hesaplanan 3 parametreli Weibull olasılık yoğunluk fonksiyonunun OMH değerinin, 41.701 adet/ha; HKOK değerinin, 57.486 adet/ha; HKOK% değerinin, % 55.481; Bias değerinin, -8.931 adet/ha; Bias% değerinin, % -8.619; R^2 değerinin, 0.701; AIC değerinin; 9590 ve BIC değerinin; 11226 olarak elde edilmişken; en başarılı 7 ara katmana sahip 0.001 değeri ile Moment oranı (Moment rate) hiper parametre özelleştirmesini içeren DÖA modelinin HKOK değerinin, 49.193 adet/ha; HKOK% değerinin, % 47.628; Bias değerinin, -8.182 adet/ha; Bias% değerinin, % -7.922; R^2 , 0,784; AI değerinin; 1905 ve BIC değerinin; 2239 olarak elde edildiği görülmektedir. Bu bakımdan, DÖA modelinin 3 parametrelili Weibull olasılık yoğunluk fonksiyonuna göre çap dağılımlarını modellemede daha başarılı sonuçlar verdiği değerlendirilebilir. DÖA modelinin çap dağılımında başarısı, ayrıca elde edilen tahminlerin çalışma alanına uygunluğunun denetimi için yapılan Kolmogorov-Simirnov test sonuçlarında görülebilir. 3 parametrelili Weibull fonksiyonunun tahminleri 306 örnek alandan 297 adeti (%97.05) 0.05 önem düzeyi ile çalışma alanındaki meşcereler uygun iken, 9 adetinin ise uygun olmadığı (%2.50) ve DÖA modelleri elde edilen tahminlerin eğitim verileri için 306 örnek alandan 304 adeti (%99.35) 0.05 önem düzeyi ile çalışma alanındaki meşcerelere uygun iken, 2 adetinin ise uygun olmadığı (%0.65); denetim verileri için 102 örnek alandan 97 adeti (%95.1) 0.05 önem düzeyi ile çalışma alanındaki meşcerelere uygun iken, 5 adetinin ise uygun

olmadığı (%4.9) sonucuna varılmıştır. Kolmogorov-Simirnov test sonuçlarına dayanan tahminlerin çalışma alanındaki meşcere uygunluğunda da, DÖA modelinin 3 parametrelili Weibull fonksiyonuna göre daha başarılı olduğu görülmektedir. Ercanlı vd. (2018), Trabzon ve Giresun Orman Bölge Müdürlükleri sınırları içerisinde yer alan eşityaşlı Doğu Ladini-Sarıçam karışık meşcereleri (LCs veya CsL) için yaptığı bir çalışmada, 5 katmanlı DÖA modeli, %25, %50 ve %95’lik değerleri esas alan eşitlikler ile 3 parametrelili Weibull fonksiyonunun göre daha başarılı sonuçlar elde etmiştir. Ercanlı vd. (2023), 3 parametrelili Weibull fonksiyonun parametrelerini tahmin etmek üzere %25-%50-%95 yüzdelik değerlerini kullanan yöntem ile farklı çap basamaklarındaki ağaç sayılarına ilişkin çap dağılımındaki değişimin %86.68’i tahmin ederken, moment oranı hiper parametre çeşidini ve 0.0001 değerini içeren DÖA modeli ile çap basamaklarındaki ağaç sayılarındaki değişimde %90.89’luk bir tahmin açıklayıcılığı elde etmiştir.

Çap dağılım modelleri, meşcere modelleri ve hasılat tabloları, ormancılık faaliyetlerinde meşcere yapılarının daha ayrıntılı tahminlerinin elde edilmesine olanak tanır. Bu modeller, DÖA gibi yenilikçi tekniklerin kullanımı ile meşcere hacmi, göğüs yüzeyi ve ağaç sayısı gibi tahminleri çap sınıfı düzeyinde detaylandırarak ormancılık planlamasını ve sürdürülebilir ormancılık uygulamalarını destekler. Ülkemizde, artım ve büyümenin tahmin edilmesinde Normal Hasılat Tabloları ve Sıklığa Bağlı Hasılat Tabloları kullanılmaktadır. Ancak, meşcere yapıları hakkında daha ayrıntılı tahminlere ihtiyaç duyulmaktadır ve mevcut envanter çalışmalarının detayları sınırlıdır. Yapay zeka modelleri olan DÖA gibi modelleri güncel ve yenilikçi tekniklerle geliştirilen çap dağılım modelleri, envanter verilerini çap kademeleri düzeyinde tahmin etme imkanı sunarak bu kısıtları azaltır. Özellikle çeşitli olasılık yoğunluk fonksiyonları ile Sıklığa Bağlı Hasılat Tabloları kullanılarak elde edilen tahminler, meşcere ağaç sayısı, göğüs yüzeyi ve hacmi gibi değerlerin meşcerenin çap basamaklarına dağılımlarını tahmin etmek için kullanılabilir. Bu bütünleşik kullanım, orman amenajmanı ve silvikültür planlaması için önemli ayrıntılı tahminlerin elde edilmesine yardımcı olur.

Farklı meşcere yapılarına sahip ormanlarımızın çap dağılımlarının modellenmesinde, çeşitli ağaç türlerinin ve yetiştirme ortamlarının dikkate alınması önemlidir. Ayrıca, çap

dağılım modellerinin başarıyla geliştirilmesi için çeşitli parametre tahmin yöntemlerinin belirlenmesi gerekmektedir. Gelecekteki çap dağılımlarının tahmin edilmesi için ise yarı devamlı veya devamlı deneme alanlarının kurulması ve periyodik ölçümlerin yapılması önemlidir. Sonuç olarak, çap dağılım modellerinin kullanımı ve yarı devamlı deneme alanlarının kurulması, ormancılık faaliyetlerinde daha etkin planlama ve yönetim için önemli araçlar olarak görülmektedir. Bu yaklaşımlar, ormancılık sektöründe sürdürülebilirlik ve verimlilik sağlamak için önemlidir. Bu çalışmada geliştirilen çap dağılım modelleri, geçici örnek alanlardan elde edilmiş veriler ile geliştirilmiş olup, diğer taraftan çeşitli tek ağaç ve meşcere özelliklerindeki değişimin daha başarıyla ortaya konmasında, bu meşcerelerin belirli zaman periyotunda devamlı izlendiği devamlı ya da yarı devamlı deneme alanlarının tesisi ve belirli periyotlarla ölçülmesi büyük bir önem taşımaktadır. Ancak, ülkemiz ormancılığı açısından devamlı ve yarı devamlı deneme alanlarının tesisi ve belirli periyotlarla ölçümü önemli bir gereklilik olarak karşımıza çıkmaktadır.

KAYNAKLAR

- Alkan, O., Özçelik, R. ve Kalkanlı Genç, Ş. 2023. Almus yöresi doğal Doğu Kayını meşcerelerinin çap dağılımının Weibull dağılımı ile modellenmesi. Türkiye Ormancılık Dergisi, 24(3): 197-207.
- Andrasev, S., Bobinac, M. and 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
- Asan, Ü. 2000. Ulusal orman envanteri kavramı ve Türkiye'deki durumu. T.C. Orman Bakanlığı, Teknik Bülten, Yıl,1, sayı 2.
- Asan, Ü. Başkent, E. Z. ve Özçelik, R. 2001. Gelişmiş ülkelerdeki ulusal orman envanter sistemleri ve Türkiye için öneriler. 1. Ulusal Ormancılık Kongresi, 19-20 Mart, 30-51, Ankara.
- Ashraf, M. I., Zhao, Z., Bourque, C. P. A., MacLean, D. A. and Meng, F. R. 2013. Integrating biophysical controls in forest growth and yield predictions with artificial intelligence technology. Canadian Journal of Forest Research, 43(12): 1162-1171.
- Atıcı, E. 1998. Değişikyaşlı Doğu Kayını (*Fagus orientalis* Lipsly.) Ormanlarında Artım ve Büyüme. Doktora Tezi, İstanbul Üniversitesi, 398 sayfa, İstanbul.
- Atkinson, P. M. and Tatnall, A.R. 1997. Introduction: neural networks in remote sensing. International Journal of Remote Sensing, 18(4): 699-709.
- Bailey, R. L. 1980. Individual tree growth derived from diameter distribution models. Forest Science, 26(4): 626-632.
- Bailey, R. L. and Dell, T.R. 1973. Quantifying diameter distributions with the Weibull function. Forest Science, 19(2): 97-104.
- Bailey, R.L., Burgan, T.M. and Jokela, E.J. 1989. Fertilized midrotation-aged *Slash pine* plantations-stand structure and yield prediction models. Southern Journal of Applied Forestry, 13(2): 76-80.
- Baldwin, V. C. and Feduccia, D. P. 1987. Loblolly pine growth and yield prediction for managed West Gulf plantations. USDA For. Serv. Res. Pap. SO 236, 27 p.
- Başkent, E. Z. 1996. 21. Yüzyıl Ormancılığına Yeni Bir Yaklaşım: Sayısal Ormancılık, KTÜ Orman Fakültesi, Güz Yarıyılı Seminerleri, Seminer Serisi, No: 1: 77-84.

- Başkent, E.Z. 1999. Ekosistem amenajmanı ve biyolojik çeşitlilik, Turkish Journal of Agriculture and Forestry, 23(2): 355-363.
- Başkent, E.Z. ve Keleş, S. 2004. Ormancılıkta model ve modelleme kavramlarının kullanımı ve genel değerlendirilmesi. Orman Mühendisliği Dergisi, 40(1): 19-32.
- Bengio, Y. 2012. Practical recommendations for gradient-based training of deep architectures. Neural networks: Tricks of the trade. Springer, Berlin, Heidelberg.
- Bliss, C.I. and Reinker, K.A. 1964. A lognormal approach to diameter distributions in even-aged stands. Forest Science, 10(3): 350-360.
- Bolat F. 2014. Bursa-Kestel Orman İşletme Şefliği içerisindeki meşcereler için çap dağılım modellerinin geliştirilmesi. Yüksek Lisans Tezi, Çankırı Karatekin Üniversitesi, 77 sayfa, Çankırı.
- Bolat, F. 2015. 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, F. 2021. Ankara Orman Bölge Müdürlüğü Anadolu karaçamı meşcerelerinde artım ve büyümenin yapay sinir ağları ile modellenmesi, Doktora Tezi, Çankırı Karatekin Üniversitesi, 213 sayfa, Çankırı.
- Bolat, İ. and 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.
- Bolat F, Ercanlı İ, 2017. Modeling diameter distribution by using Weibull function in forests located Kestel-Bursa. Kastamonu University Journal of Forestry Faculty, 17(1): 107-115.
- Bolat, F., Ercanlı, I. and Günlü A. 2023. Yield of forests in Ankara Regional Directory of Forestry in Turkey: comparison of regression and artificial neural network models based on statistical and biological behaviors. iForest 16: 30-37.
- Borders, B. E. and Patterson, W. D. 1990. Projecting stand tables: a comparison of the weibull diameter distribution method, a percentile-based projection method and a basal area growth projection method. Forest Science, 36: 413– 424.

- Brooks, J. R., Borders, B. E. and Bailey, R. L. 1992. Predicting diameter distributions for site prepared loblolly and slash pine plantations. Southern Journal of Applied Forestry, 16: 130-133.
- Brynjolfsson, E. and Mitchell, T. 2015. What can machine learning do? Workforce implications. Science 358: 1530–1534.
- Cao, Q. V. 2004. Predicting parameters of a Weibull function for modelling diameter distribution. Forest Science, 50(5): 682–685.
- Carus, S. 1996. Aynı Yaşlı Doğu Kayını (*Fagus orientalis* Lipsly.) Meşcerelerinde çap dağılımının bonitet ve yaşa göre değişimi. İstanbul Orman Fakültesi Dergisi, 46: 171-181.
- Carus, S. 1998. Aynı yaşlı Doğu kayını meşcerelerinde artım ve büyüme. Doktora tezi, İstanbul Üniversitesi, 360 sayfa, İstanbul.
- Carus, S. ve Çatal, Y. 2008. Kızılçam (*Pinus brutia* Ten.)-Anadolu karaçamı (*Pinus nigra* Arnold. Subsp. *pallasiana* (Lamb) Holmboe) karışık meşcerelerinde artım ve büyüme ilişkileri. Yüksek lisans tezi, Süleyman Demirel Üniversitesi, 111 sayfa, Isparta.
- Čavlović, J., Božić, M. and 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.
- Clutter, J. L. and Bennet, F. A. 1965. Diameter distributions in old-field slash pine plantation. Georgia Forest Research Council, Report No. 13, 9 p., USA.
- Clutter, J.L., Harms, W.R., Brister, G.H. and 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 s.
- Carranza-Rojas, J., Goeau, H., Bonnet, P. et al. Going deeper in the automated identification of Herbarium specimens. BMC Evol Biol 17, 181.
- Coble, D.W. and Lee, Y. J. 2008. A new diameter distribution model for unmanaged slash pine plantations in East Texas. Southern Journal of Applied Forestry, 32: 89-94.

- Cosenza, D. N., Packalen, P., Maltamo, M., Varvia, P., R  ty, J., Soares, P., Tom  , M., Strunk, J.B., Korhonen, L. 2022. Effects of numbers of observations and predictors for various model types on the performance of forest inventory with airborne laser scanning. *Canadian Journal of Forest Research*, 52(3): 385-395.
- Diamantopoulou, M. J. 2006. Tree-Bole Volume Estimation on Standing Pine Trees Using Cascade Correlation Artificial Neural Network Models. *Agricultural Engineering International: the CIGR ejournal*. Manuscript IT 06 002. Vol. VIII.
- Diamantopoulou, M. J. and   z  elik, 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.,   z  elik, R., Crecente-Campo, F. and Eler,   . 2015. Estimation of Weibull function parameters for modelling tree diameter distribution using least squares and artificial neural networks methods. *Biosystem engineering*, 133: 33-45.
- Doğ  da  ,   . 2014. Burdur-Ağlasun y  resi Kızıl  am ormanlarında me  cere aē   sayısı, hacim ve hacim artımının   ap basamaklarına daē  lımının modellenmesi. Y  ksek lisans tezi, S  leyman Demirel   niversitesi, 98 sayfa, Isparta.
- Ercanlı,   . 2020a. Innovative deep learning artificial intelligence applications for predicting relationships between individual tree height and diameter at breast height. *Forest Ecosystems*, 7: 1-18.
- Ercanlı,   . 2020b. Artificial intelligence with deep learning algorithms to model relationships between total tree height and diameter at breast height. *Forest Systems*, 29(2): e013-e013.
- Ercanlı,   . ve Yavuz, H. 2010. Doē  u ladini (*Picea Orientalis* (L.) Link)-Sarı  am (*Pinus Sylvestris* L.) karı  ık me  cerelerinde   ap daē  lımlarının olasılık yoē  nluk fonksiyonları ile belirlenmesi. *Kastamonu Orman Fak  ltesi Dergisi*, 10(1): 68-83.
- Ercanlı   ., Bolat F., Kahriman 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., Kahriman, 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., Kahriman, 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., Kahriman, 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, F. 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. ve Bolat, F., 2020. Ankara Orman Bölge Müdürlüğü Anadolu Karaçamı Meşcereleri İçin Tek Ağaç Gövde Çapı ve Gövde Hacminin Uyumlu Gövde Çapı Denklemleri ve Yapay Sinir Ağları ile Tahmin Edilmesi”, TUBİTAK 1002 Projesi, 71 s.
- Ercanlı, İ., Günlü, A., Şenyurt, M. and Keleş, S. 2018a. 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.
- Ercanlı, İ., Bolat, F. ve Yavuz, H. 2018b. 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.
- Ercanlı, İ., Bolat, F., Yavuz, H. 2018c. 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

- Ercanlı, İ., Bolat, F., Yavuz, H. 2023a. A comparison of artificial neural networks and regression modeling techniques for predicting dominant heights of Oriental spruce in a mixed stand. *Forest Systems*, 32(1): e004.
- Ercanlı, İ., Günlü, A., Şenyurt, M., Çakır, M., Şatır, O., Bulut, S., Bolat, F. 2023b, Batı Karadeniz Bölgesinde Doğal Yayılış Gösteren Saf Doğu Kayını Meşcerelerinin Artım ve Büyümesinin Derin Öğrenme Algoritmaları ile Modellenmesi, Tubitak 1001 Proje Sonuç Raporu, 189 s.
- Esteban, L. G., Fernandez, F. G. and de Palacios, P. 2009. MOE Prediction in *Abies pinsapo* boiss. Timber: application of an artificial neural network using non-destructive testing. *Computers and Structures*, 87: 1360–1365.
- Feduccia, D. P., Dell, T. R., Mann, W. F. and 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.
- Fırat, M. 2002. Doğrusal ve Kıvrımlı Akarsulara Yerleştirilen Köprü Ayakları Etrafında Meydana Gelen Oyulma Derinliğinin Yapay Sinir Ağları ile Belirlenmesi. Yüksek Lisans Tezi, Pamukkale Üniversitesi, 125 sayfa, Denizli.
- Fırat, M. ve Güngör, M. 2004. Askı Maddesi Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi, *İMO Teknik Dergi*, 15 (3): 3267- 3282.
- Freeman, J. and Skapura, D. 1991. Neural networks-algorithms, applications, and programming techniques. Addison-Wesley, Boston, 550 p.
- Gorgoso-Varela, J. J., Alvarez-Gonzalez, J. G., Rojo, A. and 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.
- Gorgoso-Varela, J. J., Rojo, A., Cámara-Obregón, A. and Diéguez-Aranda, U. 2012. A comparison of estimation methods for fitting Weibull, Johnson's SB and beta functions to *Pinus pinaster*, *Pinus radiata* and *Pinus sylvestris* stands in northwest Spain. *Forest Systems*, 21(3): 446-459.
- Günlü, A. and 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.

- Günlü, A. and Ercanlı, İ. 2020. Artificial neural network models by ALOS PALSAR data for aboveground stand carbon predictions of pure beech stands: a case study from northern of Turkey. *Geocarto International*, 35(1): 17-28.
- H2O.ai, 2018 H2O R Package Documentation. Available online at <https://docs.h2o.ai/>; last accessed Dec. 30, 2021.
- Hafley, W.L. and Schreuder, H. T. 1977. Statistical distributions for fitting diameter and height data in even-aged stands, *Canadian Journal of Forest Research*, 4: 481 – 487.
- Hawkins, D. M. 2004. The problem of overfitting. *Journal of chemical information and computer sciences*, 44(1): 1-12.
- Jacobs, R. A. 1988. Increased rates of convergence through learning rate adaptation. *Neural Network*, 1: 295–307.
- Jiang, L. C. and Brooks, J. R. 2009. Predicting diameter distributions for young longleaf pine plantations in Southwest Georgia. *Southern Journal of Applied Forestry*, 33: 25-28.
- Johnson, N. L. 1949. System of frequency curves generated by methods of translation. *Biometrika*, 36(1-2): 149-176.
- Karakaş R. 2013. Önsen doğal Fıstıkçamı (*Pinus pinea* L.) meşcerelerinde çap dağılımlarının modellenmesi. Yüksek Lisans Tezi, Kahramanmaraş Sütcü İmam Üniversitesi, 67sayfa, Kahramanmaraş
- Khandetsky, V. and Antonyuk, I. 2002. Signal Processing in Defect Detection using Back-propagation Neural Networks. *NDT & E International journal*, 35(7): 483-488.
- Knoebel, B. R., Burkhart, H. E. and Beck, D. E. 1986. A Growth and Yield Model for Thinned Stands of Yellow-Poplar. *Forest Science Monograph*, 27, 39 s.
- Knowe, S. A. 1992. Basal Area and Diameter Distribution Models for loblolly Pine Plantations with Hardwood Competition in The Piedmont And Upper Coastal Plain. *Southern Journal of Applied Forestry*, 16: 93–98.
- Knowe, S. A., Ahrens, G. A., and 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*, 98(1): 49-60.

- Köse, S., Yavuz, H., Mısır, M. ve Mısır, N. 2001. KTÜ Orman Fakültesi Araştırma Ormanı Ladin meşçerelerinin hasılat esasları sonuç raporu. K.T.Ü. Araştırma Fonu Başkanlığı, Sonuç Raporu, 27 s.
- Laar A. and Akça A. 2007. Forest mensuration: in Managing Forest Ecosystems, Dordrecht, The Netherlands: Springer. 383 p.
- LeCun, Y., Bengio, Y., Hinton, G. 2015. Deep learning. *Nature*, 521: 436–444.
- Leak, W. B. 1965. The J-Shaped Probability Distribution. *Forest Science*, 11: 405–409.
- Lee, Y.J. and Coble, D. W. 2006. A new diameter distribution model for unmanaged loblolly pine plantations in East Texas. *Southern Journal of Applied Forestry*, 30: 13-20.
- Lei, Y. 2008. Evaluation of three methods for estimating the Weibull distribution parameters of Chinese Pine (*Pinus tabulaeformis*). *Journal of Forest Science*, 54(12): 566-571.
- Liu, C., Zhang, S.Y., Lei, Y., Newton, P.F. and Zhang, L. 2004. Evaluation of tree methods for predicting diameter distributions of black spruce (*Picea mariana*) plantations in central Canada. *Canadian Journal of Forest Research*, 34(12): 2424-2432.
- Liu, C., Beaulieu J., Pregent G. and Zhang, S. Y. 2009. Applications and comparison of six methods for predicting parameters of the Weibull function in unthinned *Picea glauca* plantations. *Scandinavian Journal of Forest Research*, 24(1): 67–75.
- Lohrey, R.E. and 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 s
- Matney, T. G. and Sullivan, A. D. 1982. Compatible Stand and Stock Tables for Thinned and Unthinned Loblolly Pine Stands. *Forest Science*, 28: 161–171.
- 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.
- McCorduck, P. 2004. Machines who think: A personal inquiry into the history and prospects of artificial intelligence. CRC Press. 598 p.

- Meyer, H.A. and Stevenson, D. D. 1943. The structure and growth of virgin beech-birch-maplehemlock forests in northern Pennsylvania. *Journal of Agricultural Research*, 67: 465-484
- Nelder, J.A., Mead R., 1965. A simplex algorithm for function minimization. *Computer Journal* 7: 308-313.
- Nelson, T.C. 1964. Diameter distribution and growth of *Loblolly pine*. *Forest Science*, 10 (1): 105-114.
- Nunes, M. H. and Görgens, E. B. 2016. Artificial intelligence procedures for tree taper estimation within a complex vegetation mosaic in Brazil, *PLoS One* 11: e0154738.
- Ogana, F. N. And Ercanli, I. 2022. Modelling height-diameter relationships in complex tropical rain forest ecosystems using deep learning algorithm. *Journal of Forestry Research*, 33(3): 883-898.
- Ogana, F. N. and Ekpa, N. E. 2020. Modelling the non-spatial structure of *Gmelina arborea* Roxb stands in Oluwa Forest Reserve, Nigeria. *Forestist*, 70 (2): 133-140.
- Özçelik, R. ve Çevlik, M. 2017. Batı Akdeniz yöresi doğal sedir meşcereleri için hacim denklemleri. *Turkish Journal of Forestry*, 18 (1): 37-48.
- 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., Brooks, J. R. and Wiant Jr, H. V. 2010. Estimating tree bole volume using artificial neural network models for four species in Turkey. *Journal of Environmental Management*, 91(3): 742-753.
- 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.

- Özdemir, G. A. 2013. Karadeniz yöresi Gökmar meşcerelerinde aktüel kuruluşun optimal kuruluşu götürülmesi. Journal of the Faculty of Forestry Istanbul University, 64 (1): 51-56.
- Özdemir, G. A. 2016. Douglas (Pseudotsuga menziesii (Mirb.) Franco) meşcerelerinin çap dağılımlarının modellenmesi. İstanbul Üniversitesi Orman Fakültesi Dergisi, 66 (2): 548-558.
- Özdemir, G. 2018. Karabük yöresi kayın-gökmar karışık meşcerelerinde gövde çaplarının yapay sinir ağı ile tahmin edilmesi, Yüksek Lisans Tezi, Kastamonu Üniversitesi, 112 sayfa, Kastamonu.
- Öztemel, E. 2006. Yapay Sinir Ağları (2. Baskı), İstanbul: Papatya Yayıncılık, 232 s.
- 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. and Trasobares, A. 2006. Calibrating predicted tree diameter distributions in Catalonia (Spain). Silva Fennica, 40 (3): 487-500.
- Palahi, M., Pukkala, T. and Trasobares, A. 2007. Modelling 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.
- Peace, I.C., Uzoma, A.O., Ita, S.A. 2015. Effect of learning rate on artificial neural network in machine learning, International Journal of Engineering Research and Technology. 4 (02): 359-363.
- 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 Swietokrzyski National Park (Poland). Forest Ecology and Management, 236 (2): 393-402.
- Poudell, K. P. 2011. Evaluation of methods to predict Weibull parameters for characterizing diameter distributions. Master Thesis, Graduate Faculty of the Louisiana State University and Agricultural and Mechanical College, 60 p., USA.
- Poudel, K. P. and 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.
- Qian, N. 1999. On the momentum term in gradient descent learning algorithms. *Neural networks*, 12(1): 145-151.
- R Core Team, 2024. R: A Language and Environment for Statistical Computing, R Foundation for Statistical Computing, Vienna, Austria.
- Rennolls, K., Geary, D. N. and Rollinson, T. J. D. 1985. Characterizing Diameter Distributions by The Use of The Weibull Distribution. *Forestry*, 58: 58–66.
- Sakıcı, O. E. and Gülsunar, M. 2012. Diameter distribution of Bornmullerian fir in mixed stands. *Kastamonu Üniversitesi, Orman Fakültesi Dergisi*, 12(3): 263-270.
- Sakıcı, O. E. and Günlü, A. 2018. Artificial intelligence applications for predicting some stand attributes using Landsat 8 OLI satellite data: A case study from Turkey, *Applied Ecology and Environmental Research*, 16(4): 5269-5285.
- Sakıcı, O. E. and Ozdemir, G. 2018. Stem taper estimations with artificial neural networks for mixed Oriental beech and Kazdağı fir stands in Karabük region, *CERNE*, 24 (4): 439-451.
- Sakıcı, O.E. and Dal, E., 2021. Kastamonu yöresi sarıçam meşcereleri için çap dağılımlarının modellenmesi ve çeşitli meşcere özellikleri ile ilişkilerinin belirlenmesi. *Bartın Orman Fakültesi Dergisi*, 23 (3): 1026-1041.
- Shao, Y., Taff, G. N., S.J. and Walsh. 2011. Comparison of early stopping criteria for neural-network-based subpixel classification, *IEEE Geoscience and Remote Sensing Letters*, 8(1): 113-117.
- Scolforo, J. R. S., Tabai, F. C. V., de Macedo, R. L. G., Acerbi, F. W., de Assis, A.L. 2003. SB distribution's accuracy to represent the diameter distribution of *Pinus taeda*, through five fitting methods. *Forest Ecology and Management*, 175: 489–496.
- Seki, M. 2022. Determination of Relationships Between Stand Variables and Parameters of Weibull Function for *Fagus orientalis* Libsky Stands. *Kastamonu University Journal of Forestry Faculty*, 22 (1): 68-77.

- Seki, M. ve Sakıcı, O. E., 2024. Kastamonu ve Sinop bölgesi karaçam meşcereleri için çap dağılımlarının ekorejyon bazlı incelenmesi. *Turkish Journal of Forestry*, 25(4): 08-422.
- Şenyurt, M., Ercanlı, İ., Yavuz, H. and Kahriman, 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.
- Şenyurt, M. and Ercanlı, İ. 2019. A comparison of artificial neural network models and regression models to predict tree volumes for crimean black pine trees in Cankiri forests. *Šumarski List*, 143 (9-10): 413-423.
- Şenyurt, M., Ercanlı, İ., Günlü, A., Bolat, F. and Bulut, S. 2020. Artificial neural network models for predicting relationships between diameter at breast height and stump diameter: Crimean pine stands at ÇAKÜ Forest. *Bosque*, 41 (1): 25-34.
- Smalley, G. W. and Bailey, R. L. 1974. Yield tables and stand structure for *Shortleaf pine* plantations in The Tennessee, Alabama and Georgia Highlands. Forest Service Research Paper, 97 p., USA.
- Saramäki, J. 1992. A growth and yield prediction model of *Pinus kesiya* (Royle ex Gordon) in Zambia. *Acta Forestalia Fenica* 230, 68 p.
- Saraçoğlu, Ö. 1988. Karadeniz Yöresi Gökmar Meşcerelerinde Artım ve Büyüme. O. G. M. Yayınları, No: 25, 312.
- Sutskever, I., Martens, J., Dahl, G. and Hinton, G. 2013. On the importance of initialization and momentum in deep learning. International conference on machine learning PMLR.
- Thike, P. H., Zhao, Z., Liu, P., Bao, F., Jin, Y. and Shi, P. 2020. An early stopping-based artificial neural network model for atmospheric corrosion prediction of carbon steel, *Computational Materials Science* 65: 2091-2109.
- Yavuz, H., Gül, A. U., Mısır, N., Özçelik, R. ve Sakıcı, O. E. 2002. Meşcerelerde çap dağılımının düzenlenmesi ve bu dağılımlara ilişkin parametreler ile çeşitli meşcere ögeleri arasındaki ilişkilerin belirlenmesi. Orman Amenajmanı'nda Yeni Kavramsal Açılımlar ve Yeni Hedefler Sempozyumu, 2012, İstanbul.

- Yu, X.H., Chen, G. A. and Cheng, S. X. 1995. Dynamic learning rate optimization of the backpropagation algorithm, *IEEE Transactions on Neural Networks and Learning Systems*, 6 (3): 669–677.
- Weibull, W. 1951. A Statistical Distribution Function of Wide Applicability. *Journal of Applied Mechanics*, 18: 293-297.
- Zhang, L. and Liu, C. 2006. Fitting Irregular Diameter Distributions of Forest Stands By Weibull, Modified Weibull and Mixture Weibull Models. *Journal Forest Research*, 11: 369–372.

