

**ÇANKIRI KARATEİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

DOKTORA TEZİ

**ANKARA ORMAN BÖLGE MÜDÜRLÜĞÜ ANADOLU KARAÇAMI
MEŞCERELERİNDE ARTIM VE BÜYÜMENİN YAPAY SİNİR AĞLARI İLE
MODELENMESİ**

Ferhat BOLAT

ORMAN MÜHENDİSLİĞİ ANABİLİM DALI

**ÇANKIRI
2021**

Her hakkı saklıdır

TEZ ONAYI

Ferhat BOLAT tarafından hazırlanan “**Ankara Orman Bölge Müdürlüğü Anadolu Karaçamı Meşcerelerinde Artım ve Büyümenin Yapay Sınır Ağları ile Modellenmesi**” adlı tez çalışması 09/06/2021 tarihinde aşağıdaki jüri tarafından oy birliği ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalında **DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Alkan GÜNLÜ

Jüri Üyeleri :

Başkan: Prof. Dr. Ramazan ÖZÇELİK

Isparta Uygulamalı Bilimler Üniversitesi, Orman Fakültesi

Üye: Doç. Dr. Alkan GÜNLÜ

Çankırı Karatekin Üniversitesi, Orman Fakültesi

Üye: Doç. Dr. Oytun Emre SAKICI

Kastamonu Üniversitesi, Orman Fakültesi

Üye: Prof. Dr. Sedat KELEŞ

Çankırı Karatekin Üniversitesi, Orman Fakültesi

Üye: Prof. Dr. Yılmaz ÇATAL

Isparta Uygulamalı Bilimler Üniversitesi, Orman Fakültesi

Yukarıdaki sonucu onaylarım

Prof. Dr. İbrahim ÇİFTÇİ

Enstitü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğine göre hazırlamış olduğum “Ankara Orman Bölge Müdürlüğü Anadolu Karaçamı Meşcerelerinde Artım ve Büyümenin Yapay Sinir Ağları ile Modellenmesi” 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. (06/07/2021)

Ferhat BOLAT

ÖZET

Doktora Tezi

ANKARA ORMAN BÖLGE MÜDÜRLÜĞÜ ANADOLU KARAÇAMI MEŞCERELERİNDE ARTIM VE BÜYÜMENİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ

Ferhat BOLAT

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Orman Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Alkan GÜNLÜ

Bu çalışmada Ankara Orman Bölge Müdürlüğünde yayılış gösteren saf Anadolu karaçamı meşcerelerine ilişkin büyüme modellerinin geliştirilmesi amacıyla farklı yaş, sıklık ve bonitet sınıflarından olmak üzere toplam 180 örnek alanda envanter yapılmıştır. Ayrıca, tek ve çift girişli ağaç hacim denklemlerinin ve gövde çapı modellerinin geliştirilmesi amacıyla toplam 300 adet ağaç örneklenmiştir. Elde edilen verilerle (i) genelleştirilmiş çap-boy modelleri, (ii) parçalı gövde çapı modelleri, (iii) tek ve çift girişli ağaç hacim denklemleri, (iv) meşcere büyüme modelleri, (v) çap dağılım modelleri ve (vi) tek ağaç çap artım modeli geliştirilmiştir. Modelleme aşamasında hem regresyon hem de yapay sinir ağı teknikleri kullanılmıştır. Geliştirilen modellerin büyüme kanuniyetlerine uygunluğu araştırılmıştır. Ağaç boylarını tahmin etmek için geliştirilen regresyon (RM) ve bayesçi yapay sinir ağı modellerinin (BYSAM) düzeltilmiş belirtme katsayıları ($R_{düz}^2$) sırasıyla 0,82 ve 0,81'dir. Gövde çaplarını tahmin etmek için geliştirilen RM ve BYSAM'nin $R_{düz}^2$ değerleri sırasıyla 0,90 ve 0,89'dur. Ağaç hacimlerini tahmin etmek için geliştirilen tek ve girişli RM ve BYSAM'nin $R_{düz}^2$ değerleri 0,94 ve 0,90'dır. Çift girişli RM ve BYSAM'nin ise sırasıyla 0,99 ve 0,85'tir. Meşcere elemanlarını tahmin etmek için geliştirilen RM, orta çap, orta boy, göğüs yüzeyi, ağaç sayısı ve hacimdeki değişkenliğin sırasıyla %87, 89, 96, 83 ve 85'ni açıklamıştır. BYSAM ise sırasıyla %83, 88, 97, 77 ve 80'ni açıklamıştır. Çap artımını tahmin etmek için geliştirilen RM ve BYSAM eşit belirtme katsayısına sahiptir ($R_{düz}^2=0,50$). Çap dağılımlarını tahmin etmek için geliştirilen Weibull, Johnson SB ve BYSAM sırasıyla 139, 177 ve 66 örnek alanda uygun bulunmuştur. Büyüme kanuniyetleri bakımından hem RM hem de BYSAM anlamlı bulgulara sahiptir. BYSAM'nin büyüme kanuniyetlerine uygunluğu ağın öğrenme sürecini kontrol eden öğrenme oranı ve momentum terimi gibi hiperparametrelerin iyi bir şekilde belirlenmesine bağlıdır. Gereğince tasarlanmış bir yapay sinir ağı modeli iyi bir genelleştirme kabiliyetine sahip olabilmekte ve böylece aşırı uyum problemi göstermemektedir.

2021, 193 sayfa

ANAHTAR KELİMELEER: Karaçam, regresyon, yapay sinir ağı, artım, büyüme



ABSTRACT

PhD Thesis

MODELING FOREST GROWTH AND YIELD IN ANATOLIAN BLACK PINE STANDS LOCATED ANKARA FOREST DISTRICT DIRECTORATE BY ARTIFICIAL NEURAL NETWORK

Ferhat BOLAT

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

Supervisor: Assoc. Prof. Dr. Alkan GÜNLÜ

In this study, the inventory studies are carried out in a total of 180 sample plots of different age, stand density, and site index classes to develop growth models for pure Anatolian black pine stands distributed in Ankara Regional Forest Directory. In addition, a total of 300 trees were sampled to develop single and double entry tree volume equations and taper models. With the data obtained, (i) generalized height-diameter models, (ii) segmented taper models, (iii) single and double entry tree volume equations, (iv) stand growth models, (v) diameter distribution models and (vi) single tree diameter increment model has been developed. Both regression and artificial neural network techniques were used in the modeling phase. The suitability of the developed models to growth laws has been investigated. Adjusted coefficients of determination (R_{adj}^2) of the regression (RM) and Bayesian neural network models (BYSAM) developed to estimate tree heights are 0.82 and 0.81, respectively. R_{adj}^2 values of RM and BYSAM, which were developed to estimate the bole diameters at the heights, are 0.90 and 0.89, respectively. R_{adj}^2 values of single-entry RM and BYSAM, which were developed to estimate tree volumes, are 0.94 and 0.90. The double-entry RM and BYSAM's are 0.99 and 0.85, respectively. RM that was developed to predict stand parameters explained 87, 89, 96, 83 and 85% of the variation in quadratic mean diameter, mean height, basal area, number of trees and volume, respectively while BYSAM accounted for 83, 88, 97, 77 and 80%, respectively. RM and BYSAM that were developed to estimate the diameter increment have the same R_{adj}^2 (0.50). Weibull, Johnson SB and BYSAM, which were developed to estimate the diameter distributions, were found suitable in 139, 177 and 66 sample plots, respectively. Both RM and BYSAM have significant findings in terms of their growth laws. The suitability of BYSAM to the growth laws depends on the determination of hyperparameters such as learning rate and momentum term that control the learning process of the network. A properly designed artificial neural network model can have a good generalization capability and thus does not have the overfitting problem.

2021, 193 pages

Key Words: Black pine, regression, artificial neural network, increment, yield



ÖNSÖZ VE TEŞEKKÜR

“Ankara Orman Bölge Müdürlüğü Anadolu karaçamı meşcerelerinde artım ve büyümenin yapay sinir ağları ile modellenmesi” adlı bu çalışma 2015-2021 yılları arasında hazırlanarak Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsüne “Doktora Tezi” olarak sunulmuştur. Bu araştırmanın amacı, yapay sinir ağlarının ormancılık disiplinde kullanılabilirliği araştırmaktır.

Doktora tezimin planlanması, yürütülmesi ve yazım sürecinde her zaman ilgili, özverili ve yol gösterici olan değerli hocam Doç. Dr. İlker ERCANLI ’ya teşekkürü bir borç bilirim.

Tez izleme süreçlerinde değerli görüş ve önerileriyle tezime katkı sağlayan; Prof. Dr. Ramazan ÖZÇELİK, Prof. Dr. Yılmaz ÇATAL, Prof. Dr. Sedat KELEŞ, Doç. Dr. Oytun Emre SAKICI, Doç. Dr. Alkan GÜNLÜ ve Dr. Öğr. Üyesi Muammer ŞENYURT hocalarıma sonsuz teşekkür ederim.

Çalışmanın arazi ve büro aşamasında yardımlarını esirgemeyen Arş. Gör. Dr. Sinan BULUT, Arş. Gör. Dr. Mehmet Seki ve Orman Müh. Kutay Kaya’ya ve Orman Genel Müdürlüğü personellerine, Orman Genel Müdürlüğü Dış İlişkiler, Eğitim Araştırma Daire Başkanlığına ve Orman İdaresi ve Planlama Daire Başkanlığına teşekkürlerimi sunarım.

Sevgili eşime anlayışı, özverisi ve desteği için teşekkür ediyorum.

Her zaman bana destek olan anneme, babama, ablama ve yeğenime şükranlarımı sunarım.

Doktora tezime maddi destek sağlayan Çankırı Karatekin Üniversitesi Bilimsel Araştırmalar Proje Birimine (Proje No: OF061218D05) ve Türkiye Bilimsel ve Teknolojik Araştırma Kurumuna (Proje No: 119O061) teşekkür ederim. Bu çalışmada doğrusal olmayan problemlerin çözümü için *R* kodlama dilinde geliştirilen çözücü uygulaması, TÜBİTAK Bilim İnsanlarını Destekleme Programı 2237-A Bilimsel Eğitim Etkinleri kapsamında katılımcı olarak katıldığım “*Doğa Bilimlerinde İstatistiksel Modelleme Teknikleri ve Uygulamaları*” kursunda tasarlanmıştır. Bu nedenle, bilimsel eğitim etkinliğinin yürütücüleri olan Prof. Dr. Kürşat ÖZKAN ve Prof. Dr. Gamze ÖZEL KADILAR ile Doç. Dr. Emrah ALTUN başta olmak üzere diğer tüm eğitmen hocalarıma teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	iii
ÖNSÖZ VE TEŞEKKÜR.....	v
SİMGELER DİZİNİ	viii
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xiii
1. GİRİŞ	1
1.1 Genel Bilgiler	1
1.2 Büyüme Modelleri.....	7
1.2.1 Meşcere büyüme modelleri.....	10
1.2.2 Çap dağılım modelleri.....	12
1.2.3 Tek ağaç modelleri	13
1.3 Yapay Sinir Ağı Modelleri.....	16
2. MATERYAL VE YÖNTEM	29
2.1 Materyal	29
2.1.1 Çalışma alanı	29
2.1.2 Örnek alanların seçimi ve yapılan ölçümler	31
2.1.3 Örnek ağaçların seçimi ve yapılan ölçümler	34
2.2 Yöntem	35
2.2.1 Gövde çapı modelleri	36
2.2.2 Ağaç hacim modelleri	43
2.2.3 Gövde çapı ve ağaç hacim modellerinin denetlenmesi	47
2.2.4 Meşcere büyüme modelleri.....	47
2.2.5 Çap dağılım modelleri.....	57
2.2.6 Tek ağaç büyüme modeli	61
3. BULGULAR.....	67
3.1 Parçalı Gövde Çapı Modellerine İlişkin Bulgular	67
3.1.1 Gövde çapı modellerinin denetimi.....	71
3.2 Ağaç Hacim Modellerine İlişkin Bulgular	71
3.2.1 Tek ve çift girişli regresyon denklemlerine ilişkin bulgular	71
3.2.2 Görünüşte ilişkisiz regresyon modeline ilişkin bulgular	73
3.2.3 Bayesçi yapay sinir ağı modeline ilişkin bulgular	73
3.2.4 Ağaç hacim modellerinin örnek alanlara uygunluğunun testi.....	79
3.3 Çap-Boy Modellerine İlişkin Bulgular	79
3.4 Meşcere Sıklığına İlişkin Bulgular	84
3.5 Asli Meşcere Elemanlarına İlişkin Bulgular	86
3.5.1 Meşcere orta çapına ilişkin bulgular	88
3.5.2 Meşcere orta boyuna ilişkin bulgular.....	90
3.5.3 Meşcere ağaç sayısına ilişkin bulgular	91
3.5.4 Meşcere göğüs yüzeyine ilişkin bulgular	93
3.5.5 Meşcere hacmine ilişkin bulgular	94
3.6 Ayrılan Meşcere Elemanlarına İlişkin Bulgular	100
3.7 Çap Dağılım Modellerine İlişkin Bulgular	114
3.8 Tek Ağaç Çap Artım Modeline ilişkin Bulgular	120
3.8.1 Tepe boyutlarına ilişkin bulgular	120
3.8.2 Tek ağaç çap artım modellerinin denetimi	125

4. TARTIŞMA	127
4.1 Regresyon Modellerine İlişkin Tartışma	127
4.1.1 Gövde çapı modelleri	127
4.1.2 Ağaç hacim modelleri	129
4.1.3 Genelleştirilmiş çap-boy modelleri	130
4.1.4 Meşcere modelleri	132
4.1.5 Çap dağılım modelleri.....	133
4.1.6 Tek ağaç çap artım modelleri	134
4.2 Bayesçi Yapay Sinir Ağı Modellerine İlişkin Tartışma	135
5. SONUÇ VE ÖNERİLER.....	141
KAYNAKLAR	146
EKLER.....	163
ÖZGEÇMİŞ.....	194



SİMGELER DİZİNİ

α	Weibull Fonksiyonunun Konum Parametresi
β	Weibull Fonksiyonunun Ölçek Parametresi
γ	Weibull Fonksiyonunun Şekil Parametresi
δ	Johson SB Fonksiyonunun Şekil Parametresi
ε	Model Hata Terimi
ζ	Johson SB Fonksiyonunun Konum Parametresi
λ	Johson SB Fonksiyonunun Ölçek Parametresi
μ	Aritmetik Ortalama
σ	Standart Sapma

Kısaltmalar

AHD	Ağaç Hacim Denklemi
AHY	Ara Hasılat Yüzdesi
AIC	Akaike Bilgi Kriteri
AR (p)	p. Dereceden Otoregresif Model
ARMA (p, r)	Otoregresif Hareketli Ortalama Modeli
BYSAM	Bayesçi Yapay Sinir Ağı Modeli
CAR	Sürekli Otoregresif Model
ÇBM	Genelleştirilmiş Çap-Boy Modeli
dg	Meşcere Orta Çapı
ETFOP	Ekosistem Tabanlı Fonksiyonel Planlama
G	Meşcere Göğüs Yüzeyi
GHV	Genel Hacim Verimi
GMOHA	Genel Meşcerenin Ortalama Hacim Artımı
hg	Meşcere Orta Boyu
HKOK	Hata Kareler Ortalamasının Karekökü
id	Tek Ağaç Çap Artımı
JSB	Johnson SB Olasılık Yoğunluk Fonksiyonu
KMOHA	Kalan Meşcerenin Genel Ortalama Artımı
MA (p)	p. Hareketli Ortalama Modeli
N	Meşcere Ağaç Sayısı
OH	Ortalama Hata
OMH	Ortalama Mutlak Hata
OMHY	Ortalama Mutlak Hata Yüzdesi
PGÇM	Parçalı Gövde Çapı Modeli
$R_{düz}^2$	Düzeltilmiş Belirtme Katsayısı
RM	Regresyon Modeli
SO	Sıklık Oranı
Syx	Standart Hata
TH	Toplam Hata
THY	Toplam Hata Yüzdesi
V	Meşcere Hacmi

YCHA	Yıllık Cari Hacim Artımı
YCHAY	Yıllık Cari Hacim Artım Yüzdesi
ye_i	Yarışma Endeksi



ŞEKİLLER DİZİNİ

Şekil 2.1 Ankara Orman Bölge Müdürlüğünde yayılış gösteren saf karaçam meşcerelerinin konumsal dağılımı ve örneklenen alanlar	30
Şekil 2.2 Örnek alanların yükselti gruplarına göre dağılımı	32
Şekil 2.3 Örnek alanların eğim gruplarına göre dağılımı	32
Şekil 2.4 Örnek alanların bakı gruplarına göre dağılımı	33
Şekil 2.5 Modellerin oluşturulmasında (a) ve uygunluğunun test edilmesinde (b) kullanılan verilerin oransal çap değerlerinin oransal boy değerlerine göre dağılımı	35
Şekil 2.6 İki katmanlı ve iki nöronlu örnek yapay sinir ağı modeli	43
Şekil 2.7 Meşcere büyüme modellerinin geliştirilmesine ilişkin diyagram	54
Şekil 3.1 PGÇM-4 ve BYSAM'nin hata dağılımları ve tahmin-gözlem grafikleri	68
Şekil 3.2 Parçalı gövde çapı modellerinin gecikmeli hata dağılımları	70
Şekil 3.3 Göğüs yüksekliği çapını esas alan BYSAM'nin simülasyon veri setindeki davranışı	74
Şekil 3.4 Göğüs yüksekliği çapını ve toplam ağaç boyunu esas alan BYSAM'nin simülasyon veri setindeki davranışı	75
Şekil 3.5 Ağaç hacim modellerinin gözlemlere karşı tahminlerin dağılımları	76
Şekil 3.6 Ağaç hacim modellerinin çap sınıflarına göre hata dağılımları	77
Şekil 3.7 Çalışma kapsamında geliştirilen tek girişli ağaç hacim modelinin amenajman planı ve Sun vd. (1978) ile karşılaştırılması	78
Şekil 3.8 Çalışma kapsamında geliştirilen çift girişli ağaç hacim modelinin Gülen (1958) ile karşılaştırılması	79
Şekil 3.9 Genelleştirilmiş çap-boy modellerine ilişkin hata dağılımları ve gözlem-tahmin grafikleri	82
Şekil 3.10 Genelleştirilmiş çap-boy modellerinin çap sınıflarına göre hata dağılımları	83
Şekil 3.11 Genelleştirilmiş çap-boy modellerinin orman işletme müdürlüklerine göre hata dağılımları	83
Şekil 3.12 Kalıpsız (1963)'den elde edilen meşcere orta çapının meşcere ağaç sayısı ile ilişkisi	84
Şekil 3.13 Meşcere elemanlarının meşcere yaşına göre dağılımları	87
Şekil 3.14 Örnek alanların yaş, bonitet ve sıklık dağılımları	88
Şekil 3.15 Meşcere orta çapı modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri	89
Şekil 3.16 Meşcere orta boyu modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri	91
Şekil 3.17 Meşcere ağaç sayısı modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri	92
Şekil 3.18 Meşcere göğüs yüzeyi modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri	94
Şekil 3.19 Meşcere hacim modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri	95
Şekil 3.20 Meşcere orta çapının (cm) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi	96

Şekil 3.21 Meşcere orta boyunun (m) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi.....	96
Şekil 3.22 Meşcere göğüs yüzeyinin (m^2/ha) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi.....	97
Şekil 3.23 Meşcere hacminin (m^3/ha) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi.....	97
Şekil 3.24 Meşcere ağaç sayısının (adet/ha) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi.....	98
Şekil 3.25 Meşcere orta çapının (cm) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi.....	98
Şekil 3.26 Meşcere orta boyunun (m) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi.....	99
Şekil 3.27 Meşcere göğüs yüzeyinin (m^2/ha) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi.....	99
Şekil 3.28 Meşcere hacminin (m^3/ha) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi.....	100
Şekil 3.29 Meşcere ağaç sayısının (adet/ha) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi.....	100
Şekil 3.30 66 numaralı örnek alanda çap dağılım modellerinin birikimli oransal mutlak hataları.....	116
Şekil 3.31 8 numaralı örnek alanda çap dağılım modellerinin birikimli oransal mutlak hataları.....	117
Şekil 3.32 132 numaralı örnek alanda çap dağılım modellerinin birikimli oransal mutlak hataları.....	117
Şekil 3.33 Çap dağılım modellerinin yaş sınıflarına göre hata dağılımları.....	118
Şekil 3.34 Çap dağılım modellerinin veri sayısına göre hata dağılımları	119
Şekil 3.35 Standart sapması yüksek olan iki örnek alanda çap dağılım modellerinin davranışı.....	119
Şekil 3.36 Tek ağaç çap artım modellerinin çap sınıfları düzeyinde hata dağılımları ve gözlemlere karşı tahmin grafikleri	122
Şekil 3.37 BYSAM ile elde edilen tek ağaç çap artımlarının sıklığa göre değişimi (Meşcere özellikleri be=32m, dg=30 cm, BAL=40 m^2 ve G=30 m^2/ha)	123
Şekil 3.38 BYSAM ile elde edilen tek ağaç çap artımlarının bonitete göre değişimi (Meşcere özellikleri sd=9, dg=30 cm, BAL=40 m^2 ve G=30 m^2/ha)	123
Şekil 3.39 BYSAM ile elde edilen tek ağaç çap artımlarının BAL değişkenine göre değişimi (Meşcere özellikleri be=32m, dg=30 cm, sd=9 ve G=30 m^2/ha)	124
Şekil 3.40 RM ile elde edilen tek ağaç çap artımlarının sıklığa göre değişimi (Meşcere özellikleri be=32m, dg=30 cm, BAL=40 m^2 ve G=30 m^2/ha)	124

Şekil 3.41 RM ile elde edilen tek ağaç çap artımlarının bonitete göre değişimi (Meşcere özellikleri $s_d=9$, $d_g=30$ cm, $BAL=40$ m ² ve $G=30$ m ² /ha)	125
Şekil 3.42 RM ile elde edilen tek ağaç çap artımlarının BAL değişkenine göre değişimi (Meşcere özellikleri $b_e=32$ m, $d_g=30$ cm, $s_d=9$ ve $G=30$ m ² /ha)	125



ÇİZELGELER DİZİNİ

Çizelge 2.1 Saf karaçam meşcerelerinin orman işletme müdürlüklerine göre alansal dağılımı	29
Çizelge 2.2 Örnekleme yapılan meşcerelere ilişkin tanımlayıcı istatistikler	33
Çizelge 2.3 Örneklenen ağaçlara ilişkin tanımlayıcı istatistikler	34
Çizelge 2.4 Örneklenen ağaçların çap ve boy sınıflarına dağılımı	35
Çizelge 3.1. Parçalı gövde çapı modellerine ilişkin bulgular	67
Çizelge 3.2 PGÇM-4 ve BYSAM'ne ilişkin model performans değerleri	67
Çizelge 3.3 Otoregresif modellere ilişkin bulgular	69
Çizelge 3.4 PGÇM-4'ün ARMA (1, 1) ile çözümüne ilişkin parametre tahminleri, standart hata, t ve p değerleri	70
Çizelge 3.5 Parçalı gövde çapı modelinin denetimine ilişkin bulgular	71
Çizelge 3.6 Tek ve çift girişli ağaç hacim modellerinin parametre tahminleri	72
Çizelge 3.7 Tek ve çift girişli ağaç hacim denklemlerinin model performans değerleri	72
Çizelge 3.8 GİRM ile geliştirilen çift girişli ağaç hacim modellerinin performans değerleri	73
Çizelge 3.9 Ağaç hacim modellerinin denetimi	79
Çizelge 3.10 Genelleştirilmiş çap-boy modellerine ilişkin bulgular	80
Çizelge 3.11 Örnek alanların sıklık değerlerine ilişkin bulgular	85
Çizelge 3.12 Meşcere orta çapı modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri	89
Çizelge 3.13 Meşcere orta boyu modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri	90
Çizelge 3.14 Meşcere ağaç sayısını modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri	92
Çizelge 3.15 Meşcere göğüs yüzeyi modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri	93
Çizelge 3.16 Meşcere hacim modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri	95
Çizelge 3.17 Regresyon tekniği ile BE=32 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu	102
Çizelge 3.18 Regresyon tekniği ile BE=32 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu	102
Çizelge 3.19 Regresyon tekniği ile BE=32 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu	102
Çizelge 3.20 Regresyon tekniği ile BE=32 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu	103
Çizelge 3.21 Regresyon tekniği ile BE=22 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu	103
Çizelge 3.22 Regresyon tekniği ile BE=22 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu	104
Çizelge 3.23 Regresyon tekniği ile BE=22 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu	104
Çizelge 3.24 Regresyon tekniği ile BE=22 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu	105

Çizelge 3.25 Regresyon tekniği ile BE=12 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	105
Çizelge 3.26 Regresyon tekniği ile BE=12 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	106
Çizelge 3.27 Regresyon tekniği ile BE=12 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	106
Çizelge 3.28 Regresyon tekniği ile BE=12 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	107
Çizelge 3.29 Bayesçi yapay sinir ağı ile BE=32 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	107
Çizelge 3.30 Bayesçi yapay sinir ağı ile BE=32 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	108
Çizelge 3.31 Bayesçi yapay sinir ağı ile BE=32 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	109
Çizelge 3.32 Bayesçi yapay sinir ağı ile BE=32 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	109
Çizelge 3.33 Bayesçi yapay sinir ağı ile BE=22 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	110
Çizelge 3.34 Bayesçi yapay sinir ağı ile BE=22 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	110
Çizelge 3.35 Bayesçi yapay sinir ağı ile BE=22 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	111
Çizelge 3.36 Bayesçi yapay sinir ağı ile BE=22 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	111
Çizelge 3.37 Bayesçi yapay sinir ağı ile BE=12 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	112
Çizelge 3.38 Bayesçi yapay sinir ağı ile BE=12 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	112
Çizelge 3.39 Bayesçi yapay sinir ağı ile BE=12 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	113
Çizelge 3.40 Bayesçi yapay sinir ağı ile BE=12 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu.....	113
Çizelge 3.41 Tepe çapı modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri	120
Çizelge 3.42 Tepe başlangıç modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri	120
Çizelge 3.43 Tek ağaç çap artım modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri	121
Çizelge 3.44 Tek ağaç çap artım modellerinin denetimine ilişkin bulgular	125

1. GİRİŞ

1.1 Genel Bilgiler

İnsanoğlunun ilk çağlardan günümüze kadar en çok yararlandığı doğal kaynaklardan birisi ormanlardır. İlk çağlarda ormanlar beslenme ve barınma ihtiyaçları için kullanılmaktayken, son yüzyılda nüfusun artışına ve endüstriyel faaliyetlerin yaygınlaşmasına paralel olarak orman kaynaklarına olan ihtiyaçlar çeşitlenerek artmıştır. Ancak, bu ihtiyaçların karşılanmasını düzenleyecek kapsamlı bir planlama sisteminin henüz kurulamamış olması ormanların planlı ve dengeli bir şekilde işletilmesini engellemiştir. Bununla birlikte, ormanlık alanların izinsiz ve aşırı faydalanma gibi çeşitli sebeplerle tahrip edilmesi, iklim değişikliğine, çevre kirliliğine, erozyon ve heyelan gibi doğal felaketlerin artışına ve biyolojik çeşitliliğin azalmasına sebep olmuştur. Ormanlık alanların planlı ve sistemli bir şekilde işletilememesinin ve ormanlık alanların tahrip edilmesinin beraberinde getirdiği en büyük sorun ise temel gıda ihtiyaçlarının devamlılığını sekteye uğratması olmuştur. Bu nedenle, plan ünitesinin potansiyeli aşılmadan ve ekosistem içerisindeki dengeye zarar vermeden ormanların sunduğu ürün ve hizmetlerin toplumun talepleri doğrultusunda planlanması gerekmektedir (Asan 2013). Bu anlayışla, günümüzde sürdürülebilir işletmecilik prensibi benimsenerek ormanların sunduğu ekonomik faydayla birlikte ekolojik ve sosyo-kültürel faydalar da planlamalarda dikkate alınmaya başlamıştır.

Ormanların sunduğu ürün ve hizmetlere olan talepler toplumun farklı kesimleri için değişiklikler göstermektedir. Söz konusu bu talepler başta odun eksenli ürünlerin üretimi olmakla birlikte toprak koruma, su üretimi, ekoturizm aktiviteleri ve odun dışı orman ürünleri üretimi şeklinde çeşitlenmektedir. Bununla birlikte, her orman yapısı tüm ormancılık işletme amaçlarını yerine getirebilecek potansiyele de sahip değildir. Dolayısıyla toplumun taleplerinin nereden ve ne şekilde karşılanacağını belirlenmesi ayrı bir önem taşımaktadır. Günümüzde ekosistem tabanlı fonksiyonel planlama (ETFOP) önem kazanmış ve bu planlama yaklaşımında biyolojik çeşitliliğin korunması, katılımcılığın esas alınması, çok amaçlı faydalanmanın düzenlenmesi, bilişim teknolojilerinin ve karar destek sistemlerinin kullanılması dikkate alınmaya başlamıştır.

Bununla birlikte, çok amaçlı yararlanmayı destekleyecek yeterli ekosistem envanterinin yapılması ve farklı kuruluş ve yapıdaki meşcerelerin gelişimlerinin yeterince temsil edebilecek artım ve büyüme modellerinin geliştirilmesi etkili planlamanın yapılmasını mümkün kılacaktır (Başkent 2005).

Türkiye ormancılığında özellikle 1970'li yıllardan sonra yöneylem araştırmaları adı altında çok aşamalı sorun çözme teknikleri uygulamaya başlanmıştır (Sun 1977). Bu gelişmelerle birlikte, dinamik ve karmaşık bir yapıya sahip olan orman ekosistemlerindeki ağaç ve meşcere gelişimlerinin ortaya konulmasında karşılaşılan birçok olasılığın (belirsizliğin) çözümü için matematiksel işlemlere dayalı çözümsel yöntemler geliştirilmiştir. Teknik ilerlemeler sayesinde belirsizliklerle dolu orman ekosistemlerini oluşturan öğeler arasındaki ilişkilerin yeterince açıklanabilmesi mümkün olabilmış ve tek ağaç ve meşcere gelişimleri güvenilir bir şekilde ortaya konulabilmektedir. Bugünün dinamik ormancılığında ise orman ekosistemini oluşturan öğelerin zaman içerisinde nasıl bir davranış sergilediğinin incelenebilmesi amacıyla çeşitli modelleme yaklaşımları geliştirilmiştir. Bu modelleme yaklaşımları orman ekosistemi içerisinde bulunan öğelerin birbiriyle olan ilişkilerini ve bu öğelerin çevreyle olan etkileşimlerini bir bütün içerisinde irdelemektedir (Sun 1977).

Büyüme modelleri olmadan orman ekosisteminden elde edilen verilerin işlenmesi, elde edilen bulguların değerlendirilmesi (yorumlanması) ve sonuçların genelleştirilebilmesi oldukça zordur. Bu modeller ile meşcereye katılmalar ve meşcereden ayrılmalar belirlenebilmekte ve silvikültürel müdahaleler sonrası meşcere gelişimindeki değişimler izlenebilmektedir. Bu nedenle, ormanların çok amaçlı planlama yaklaşımına göre işletilebilmesi ancak güvenilir büyüme modelleriyle mümkün olabilecektir. Artım ve büyüme modelleri değişik çevresel koşullar altında yetişen tek ağaç ve meşcerelerin farklı silvikültürel uygulamalar neticesinde nasıl bir gelişim yapacağının tahmin edilmesinde, bir meşcerenin odun eksenli orman ürünlerini üretebilme potansiyelinin belirlenmesinde, farklı planlama stratejilerinin karşılaştırılmasında ve amenajman planlarının karar verme süreçlerinde yoğun bir şekilde kullanılmaktadır (Vancley 1994). Orman amenajman planlarının yeterliliği ve geçerliliği tek ağaç ve meşcerelere ilişkin artım ve büyüme değerlerinin doğru tahmin edilmesiyle yakından ilişkilidir. Bu

nedenle, artım ve büyüme modelleri ETFOP yaklaşımının lokomotifi konumunda olup planlamalarda yararlanılacak temel altlıklardan birisi olarak karşımıza çıkmaktadır.

Artım ve büyümenin tahmin edilmesine yönelik çalışmalar yaklaşık iki yüz yıllık bir geçmişe sahiptir. 1778 ve 1795 yıllarında Paulsen kayın, meşe, ladin ve çam türlerinin, 1789 yılında Perthuis meşenin ve aynı yıl Nanquette sarıçamın artım ve büyümesini ortaya koymuşlardır (Fırat 1972). 1800-1930 yılları arasında artım ve büyüme grafiksel okumalar üzerinden tayin edilirken daha sonraki yıllarda bilimsel ve teknik ilerlemeler neticesinde istatistiki yöntemlerden birisi olan regresyon tekniği kullanılmaya başlanmıştır. Günümüzde mühendislik, tıp ve ormancılık gibi uygulamalı bilimlerde çalışan araştırmacılar açıklayıcı değişkenler yardımıyla ölçümü zor olan bir değişkeni tahmin etmek için değişkenler arasındaki fonksiyonel ilişkilerden yararlanarak regresyon modelleri geliştirmektedir. Orman hasılatı ve dendrometri disiplini ise tek ağaçların boyutları, yarışma endeksleri ve(veya) meşcere özellikleri yardımıyla artım ve büyümeyi tahmin etmek için regresyon analizlerinden sıklıkla yararlanılmaktadır (Günel 1981). Artım ve büyümenin tahmini için kullanılan regresyon modellerinin güvenilirliği belirli varsayımların yerine getirilmesine bağlıdır (Zuur *et al.* 2010). Bu varsayımları dikkate aldığımızda geliştirilecek bir regresyon modelinin hataları (i) normal dağılmalı, (ii) sabit bir varyansa sahip olmalı, (iii) ardışık olarak bağımlı olmamalı, (iv) bağımsız değişkenden bağımsız olmalıdır. Sözü edilen istatistiki varsayımlardan bazıları ormancılık çalışmalarında sağlanamamaktadır. Özellikle, verilerin birbirlerinden bağımsız olması ve bağımsız değişkenler arasında korelasyon olmaması varsayımları ormancılıkta genellikle sağlanamamaktadır. Örneğin, tekrarlı ölçümlerle elde edilen verilerin birbirini takip eden değerleri arasında yüksek korelasyonun (otokorelasyon, gövde çapı verileri gibi) veya örnek alan içinde yapılan ölçümlerle elde edilen hiyerarşik veri yapılarında gözlemlenen konumsal otokorelasyonun (çap-boy verileri gibi) olduğu örneklerde (i) verideki küçük değişimler parametre tahmininde büyük değişimlere, diğer bir deyişle parametre varyansının artmasına, (ii) regresyon katsayılarına ilişkin standart hatanın artmasına, (iii) regresyon katsayısına ilişkin işaretinin ve büyüklüğün yanlış elde edilmesine, (iv) regresyon katsayısının ve model anlamlılığının tespit edilmesi amacıyla hesaplanan t ve F değerlerinin yanlış elde edilmesine ve (v) model hataları için hesaplanan varyansın düşük veya yüksek elde

edilmesine sebep olmaktadır (Kozak 1997). İstatistiki varsayımların sağlanamadığı durumlarda yukarıda açıklanan olumsuzlukların kontrol altına alınabilmesi amacıyla farklı regresyon teknikleri geliştirilmiştir. Örneğin, gövde analizi ya da gövde çapı ölçümleri ile elde edilen veriler zamansal olarak birbirine bağımlı bir yapı teşkil etmektedir. Bu veri yapılarında otoregresif parametreleri içeren AR (the m-order autoregressive model), MA (the n-order moving average model) ve CAR (the p. order continuous autoregressive model) gibi regresyon teknikleri önem kazanmaktadır (Corral-Rivas *et al.* 2007, Crecente-Campo *et al.* 2010, Zhao *et al.* 2019, Alkan and Özçelik 2020). Diğer taraftan, farklı örnek alanlardan elde edilen verilerin bir veri setinde birleştirilmesi durumunda, örnek alan içi homojen ancak örnek alanlar arası heterojen veri yapıları görülmekte ve bu durum hiyerarşik veri yapıları meydana getirmektedir. Bu problemin çözümü için sabit ve rasgele parametreleri içeren karışık etkili regresyon teknikleri kullanılmaktadır (Trincado *et al.* 2007, Wang *et al.* 2008).

Otokorelasyonun sebep olduğu olumsuzlukların otoregresif modeller ve karışık etkili modeller ile tam olarak giderildiği konusunda da bir fikir birliği oluşmuş değildir. Wang *et al.* (2008) karışık etkili modelleme tekniğinde karşılaşılan bazı problemlerin henüz istatistik disiplininde dahi yeterince açıklanamadığını belirtmişlerdir. Ayrıca, söz konusu regresyon teknikleri güçlü bir istatistik alt yapısı da gerektirmektedir. Günümüzde istatistiki varsayımlara bağlı olmayan ve regresyon modelleriyle yarışabilecek ve hatta karmaşık problemlerin çözümünde daha başarılı olabilecek bir yöntem olan yapay sinir ağları konusu önem kazanmaktadır. Yapay sinir ağları mühendislik, tıp ve haberleşme gibi disiplinlerde yaygın bir şekilde kullanılmaktayken ormancılık disiplininde son birkaç yılda önem kazanmıştır. 1991 yılından günümüze kadar ormancılığın farklı konularında yapay sinir ağlarının kullanıldığı görülmektedir. Ormancılık alanında gündeme geldiği ilk yıllarda az sayıda çalışma yapılmış olmasına rağmen günümüzde özellikle son birkaç yılda farklı konularda çok sayıda çalışma yapılmıştır. Bu çalışmaların önceleri genellikle sınıflandırma yapmak amacıyla yapıldığı ancak özellikle regresyon tekniklerindeki kısıtların tartışılır hale geldiği günümüzde artım ve büyüme çalışmalarında da yer bulduğu görülmektedir. Örneğin, uluslararası çalışmalarda ağaçların kuruma olasılıklarını (Guan and Gertner 1991), vejetasyon indisini (Paruelo and Tomasel 1997), meşcere yaşını (Jensen *et al.* 1999),

çeşitli meşcere özelliklerini (Corne *et al.* 2004, Klobučar *et al.* 2008, Higgins 2011, Che *et al.* 2019), ağaç hacimlerini (Liu and Zhang 2005, Castellanos *et al.* 2007, Huang *et al.* 2014), bonitet endeksini (Whang *et al.* 2005), orman yangın riskini (Li *et al.* 2009), ağaç boylarını (Castaño-Santamaría *et al.* 2013, Huang *et al.* 2014), gövde çaplarını (Kaloudis *et al.* 2006, Leite *et al.* 2011), hacim artımını (Castro *et al.* 2013), göğüs yüzeyi artımını (Ashraf *et al.* 2013), ormanların çap dağılımlarını (Diamantopoulou *et al.* 2015), bonitet endeksini (Lima *et al.* 2017), meşcere göğüs yüzeyini (Che *et al.* 2019), biyokütle miktarını (Vahedi 2016), ve tek ağaç çap artımlarını (Zhang *et al.* 2000, Reis *et al.* 2016, Hamidi *et al.* 2021) tahmin etmek için yapay sinir ağları başarılı bir şekilde kullanılmıştır. Ülkemizde yapılan çalışmalarda ise ağaç hacimlerini (Özçelik *et al.* 2008, Ercanlı 2018), ağaç boylarını (Diamantopoulou and Özçelik 2012, Özçelik *et al.* 2013), gövde çapı tahminlerini (Özçelik *et al.* 2014, Sakıcı ve Özdemir 2018), meşcere karbonunu (Günlü and Ercanlı 2017), çap dağılımlarını (Bolat and Ercanlı 2016), yaş-boy ilişkilerini (Ercanlı *et al.* 2015), yaprak alan indeksini (Ercanlı *et al.* 2018), meşcere özelliklerini (Sakıcı and Günlü 2018) ve dip kütük-göğüs çapı arasındaki ilişkileri (Şenyurt *et al.* 2020) tahmin etmek için yapay sinir ağları başarılı bir şekilde kullanılmıştır.

Her modelleme yaklaşımında olduğu gibi yapay sinir ağlarının da sahip olduğu çeşitli avantaj ve dezavantajları bulunmaktadır. Avantajları arasında en çok öne çıkanlar; (i) istatistiksel varsayımlardan bağımsız olması, (ii) verileri işlemek için herhangi bir matematiksel modele ihtiyaç duymaması ve (iii) ağ yapısının doğrusal olmamasıdır. Bu nedenlerle yapay sinir ağları doğrusal olmayan karmaşık problemlerin çözümünde oldukça etkilidir. Dikkate alınması gereken dezavantajları ise (i) ağıın tasarımının deneme-yanılma yoluyla yapılması nedeniyle bazen çok zaman alıcı olması, (ii) her problem için farklı bir ağ tasarımına ihtiyaç duyulması ve tasarlanan ağıın her zaman en iyi çözüm olarak değerlendirilememesi, (iii) öğrenme oranı, momentum değeri gibi ağıın öğrenme sürecini kontrol eden parametrelerin ve katman sayısının belirlenmesinde bir fikir birliği olmamakla birlikte uzman görüşüne ihtiyaç duyulması ve (v) en önemlisi biyolojik çıkarımların yapılamamasıdır. Yapay sinir ağlarının literatürde belirtilen en büyük çıkmazı ise; bazı verilerde aşırı uyum problemi (overfitting) görülmesi ve ağıın genelleştirme kabiliyetinin zayıf olmasıdır. Bu durum özellikle test veri sayısının ağıın

parametre sayısına yakın olduğu örneklerde belirginleşmektedir. Bu tip veri setlerinde yapay sinir ağının eğitimi aşamasında (öğrenme sürecinde) oldukça yüksek elde edilen belirtme katsayısı değeri test veri setinde %50'den fazla azalma gösterebilmektedir. Bu nedenle geliştirilen bir yapay sinir ağı modelinin aşırı uyum problemine sahip olmaması ve örnekleminin az olduğu veri aralıklarında dahi genelleştirme kabiliyetinin (enterpolasyon gücünün) yüksek olması için ağı öğrenme sürecini kontrol eden hiperparametrelerin probleme özgü bir şekilde tanımlanması çok önemlidir (Elmas 2013). Bununla birlikte, öğrenme algoritması, transfer fonksiyonu ve verilerin tasarlanacak yapay sinir ağına ne şekilde tanıtılacağı ayrı bir önem taşımaktadır. Aksi taktirde yapay sinir ağı modelinden beklenen verim alınamayacaktır.

Günümüze kadar yapılan birçok araştırmada yapay sinir ağı modelleri istatistiksel başarı ölçütlerine göre (ör. belirtme katsayısı, ortalama hata, hata kareler ortalamasının karekökü ve Akaike bilgi kriteri) değerlendirilmiştir. Ancak, ağaçların ve meşcerelerin büyüme kanuniyetleri gereğince ortaya konulduğunda meşcere gelişimleri üzerine etkili olan faktörler sağlıklı bir şekilde belirlenebilmektedir (Sun vd. 1977). Bu nedenle, geliştirilecek bir büyüme modelinin hem başarı ölçütleri hem de büyüme kanuniyetleri bakımından değerlendirilmesi gerekmektedir. Örneğin, bir ağacın yaşamı boyunca meşcere göğüs yüzeyi gelişimi sigmoid bir eğriyi takip etmekte ve belirli bir yaşta asimptota ulaşmaktadır. Ağaç sayısı gelişimi ise ters J eğrisini takip etmekte ve belirli bir yaşta dengelenmektedir. Bu büyüme eğrilerinin değişik bonitet ve sıklık sınıflarında asimptotik ve polimorfik bir davranış sergilemesi beklenmektedir. Ülkemizde ve uluslararası düzeyde yapay sinir ağı modellerini büyüme kanuniyetlerine göre değerlendiren çalışmalar sınırlı sayıda kalmıştır. Günümüze kadar birçok çalışmada regresyon teknikleri büyüme kanuniyetleri bakımından denetlenmişken yapay sinir ağları konusunda literatürde yeterli bilgi bulunmamaktadır. Bu nedenle bu çalışmada Orman Hasılatı ve Dendrometri konularından gövde çapının, ağaç hacminin ve çap-boy ilişkisinin modellenmesi ile tek ağaç çap artımının, meşcere elemanlarının ve çap dağılımının modellenmesi konularında yapay sinir ağlarının kullanılabilirliği ve yapay sinir ağlarında biyolojik büyüme kanuniyetlerinin sağlanabilmesi için öğrenme sürecini etkileyen faktörler araştırılmıştır. Ayrıca, yapay sinir ağlarının regresyon teknikleri ile

kıyaslaması yapılmıştır. Böylece, bu çalışmada yapay sinir ağlarının birçok açıdan değerlendirilmesi yapılmış ve bazı öneriler getirilmiştir.

1.2 Büyüme Modelleri

Geçmişten günümüze karmaşık biyolojik sistemlerdeki ilişkileri belirli varsayımlar altında basitleştirerek açıklamak için çeşitli matematiksel eşitlikler ve istatistiksel fonksiyonlar, diğer bir ifade ile artım ve büyüme modelleri geliştirilmiştir (Vanclay 1994). Büyüme modelini Vanclay (1994) meşcereye katılmaları, ayrılmaları ve meşcere yapısındaki değişimleri kapsayan doğal dinamiklerin bir yansıması, Yıldızbakan (2005) farklı zaman ve durumlardaki gelişmeyi önceden tahmin eden denklemler bütünü, Pretzsch and Zenner (2017) gerçek bir meşcerenin matematiksel ve istatistiksel olarak (biometrically) bilgisayar ortamında yeniden oluşturulması (reproducing) şeklinde tanımlanmaktadır. Tanımlardan da anlaşılacağı üzere, büyüme modelleri ağaçların ve meşcerelerin bugünkü ve gelecekte artım ve büyüme miktarlarını çeşitli tek ağaç ve meşcere özelliklerinin fonksiyonu olarak tahmin etmektedir. Böylece, (i) planlanan üretim sürecinde bir meşcereden toplam veya belirli periyotlarda ne kadarlık bir odun hasılatının elde edileceği, (ii) meşcere gelişimini desteklemek amacıyla düzenlenecek bir silvikültürel eylem planına meşcerelerin nasıl tepki vereceği, (iii) optimal göğüs yüzeyi artımını sağlayabilecek silvikültürel seçeneklerin değerlendirilmesi ve (iv) toprak koruma, kaliteli su üretimi ve erozyonu önleme amacıyla işletilecek bir meşcerenin sahip olacağı göğüs yüzeyine göre planlanması artım ve büyüme modelleri ile mümkün olabilmektedir (Mısır 2001, Keleş 2003, Karahalil 2003). Bununla birlikte, artım ve büyüme modelleri ile meşcerelerin sahip olacağı biyokütle, karbon ve oksijen miktarları da belirli periyotlar için tahmin edilebilmektedir (Kirschbaum 1999). Bu bakımdan özellikle sürdürülebilir ormancılık esasına dayalı olan ETFOP'un yapılmasında farklı stratejilerin oluşturulabilmesi ve oluşturulan stratejiler içerisinde en uygun olanının seçilmesinde artım ve büyüme modelleri vazgeçilemez bir araç olarak görülmektedir (Başkent 2005).

Meşcerelerin çeşitli özelliklerinden faydalanarak meşcere gelişiminin ve veriminin tahmin edildiği çalışmaların tarihsel süreci 18. yy. başlarına dayanmaktadır. Hasılat

tablolarına ilk defa 1721 yılında Réaumur tarafından işaret edildiği görülmektedir. Bugünkü hasılat tablolarına benzer çalışmalar ilk olarak Paulsen tarafından 1778 yılında gerçekleştirilmiştir. Takip eden yıllarda (1790-1795) Perthuis ve Nanquette'nin benzer çalışmalar yaptığı görülmektedir. Paulsen tarafından geliştirilen hasılat tabloları Hartig tarafından yeniden düzenlenmiş ve bu tablolarda artım seyrine ve sebeplerine ilişkin bilgiler verilmiştir. Bu özelliğiyle hasılat araştırmaları konusunda çok önemli bir yere sahip olmuştur. Bu çalışmalara ek olarak ilk kez 1881 yılında Baur tarafından normal sıklıktaki eşit yaşlı saf meşcerelere ilişkin verim gücü ortaya konmuştur. Bu çalışmada ayrıca ağaç hacmi ile meşcere orta boyu arasındaki fonksiyonel ilişkinin varlığı ilk kez açıklanmıştır (Fırat 1972).

Artım ve büyüme çalışmaları tarihsel süreçte farklı gelişim süreçlerinden geçmiştir. Bilgi birikimi ve teknik ilerlemelerle birlikte basit tablolardan karmaşık simülasyon modellerine bir geçiş yaşanmıştır. Bu süreçte artım ve büyüme modelleri çeşitli araştırmacılar tarafından farklı şekilde sınıflandırılmıştır. Örneğin, Vanclay (1994) artım ve büyüme modellerini ampirik ve süreç tabanlı modeller olarak iki gruba ayırmaktayken Weiskittel *et al.* (2011) ise deneysel, süreç tabanlı, hibrid ve gap modelleri olmak üzere dört sınıfa ayırmaktadır. Bu sınıflandırmalar modelleme yöntemlerine ve modellerde yer alan değişkenlere göre farklılık göstermektedir. Bu farklılıklar temelinde artım ve büyüme modelleri en genel haliyle deneysel (ampirik) ve süreç tabanlı olmak üzere iki sınıfa ayrılmaktadır. Deneysel modeller çeşitli istatistiksel fonksiyonlar aracılığıyla tek ağaç ve meşcere parametreleri arasındaki ilişkileri verilerin elde edildiği meşcereler için genellemeler yaparak ortaya koymaktadır (Taylor *et al.* 2009). Deneysel modeller uygulamada en çok tercih edilen modelleme tekniği olmasına karşın iklimsel ve çevresel değişkenlere ilişkin bilgi içermediklerinden dolayı sadece ölçüm yapılan alanlarda güvenilir tahminler üretebilmektedir (Kimmins 1990). Süreç tabanlı modeller ise hem yetişme ortamı hem de meşcere özellikleri hakkında bilgi içerdiklerinden iklimsel ve çevresel faktörlerin etkilerini açıklayabilmektedir (Weiskittel *et al.* 2011). Bu nedenle değişen iklim ve çevresel faktörlere karşı kalibre edilebilmekte (*adjusting*) ve güvenilir tahminler verebilmektedir. Bununla birlikte, süreç tabanlı modellerde yer alan değişkenlerin orman envanter çalışmalarında ölçülmesi güçtür. Bu nedenle, yetişme ortamı ve meşcere özelliklerine ilişkin

değişkenlere sahip olan hibrid modeller geliştirilmiştir. Hibrid modeller meşcere özellikleri yanında çevresel değişkenlerin artım ve büyüme üzerindeki etkisini ortaya koyabildiğinden dolayı ETFOP'a güvenilir bir altlık olabilecek niteliktedir (Robinson and Ek, 2003).

Deneysel modeller modellenen birim dikkate alındığında tek ağaç, çap sınıfı ve meşcere modelleri olarak sınıflandırılmaktadır. En genel ifadeyle, meşcere düzeyinde geliştirilen modeller çeşitli meşcere özelliklerine göre hektardaki meşcere ağaç sayısının, göğüs yüzeyinin ve hacminin gelecekteki değerlerini tahmin etmektedir. Tek ağaç düzeyindeki modeller, beş veya on yıllık ortalama artımı (genellikle çap ya da göğüs yüzeyi artımı), ağaçların boyutları (göğüs çapı ve tepe çapı gibi) ve (veya) konumları ile çeşitli meşcere özelliklerinin (sıklık ya da göğüs yüzeyi) fonksiyonu olarak tahmin etmektedir. Çap sınıfı modelleri ise, çeşitli olasılık yoğunluk fonksiyonları aracılığıyla belirli göğüs çapı aralıkları için meşcere elemanlarını tahmin eden modellerdir. Tek ağaç modelleri ağaçlar arası mesafenin dikkate alınması bakımından uzaklıktan bağımsız ve uzaklığa bağımlı tek ağaç artım modelleri olarak iki gruba ayrılmaktadır. Bir yetiştirme ortamında ağaçların genetik yapısı ile ağaçlar arası mesafe tepe çapı gelişimi üzerinde etkili faktörler olduğundan dolayı ağaçların artım ve büyümesini gerçekçi bir şekilde ortaya koymak için uzaklığa bağlı tek ağaç modellerinde ağaçlar arası uzaklık, ağaçların büyüme alanı, ağaçların yaşı ve boyutları gibi değişkenler kullanılmaktadır (Newnham and Smith 1964). Uzaklıktan bağımsız tek ağaç modellerinde ise ağaçlar arası mesafe dikkate alınmamaktadır. Bu modellerde aynı yetiştirme ortamında büyüyen ağaçların benzer boyutlara sahip olacağı varsayılarak ağaçların büyümesi yetiştirme ortamı özellikleri, meşcere özellikleri ve ağaçların yaşı ve (veya) boyutlarını dikkate alınarak modellenmektedir (Munro 1973). Tek ağaç artım ve büyüme modellerinde genellikle 10-15 yıllık öngörüler (projeksiyonlar) yapılmaktayken meşcere büyüme modellerinde uzun dönemli tahminler yapılmaktadır.

Model kullanıcıları tarafından artım ve büyüme modelleri değerlendirildiğinde, örneğin, amenajman uygulamalarında farklı özellikteki orman parçalarının zamana ve yetiştirme ortamına göre meşcere artım ve büyümesi değerlendirilerek meşcerenin son hasılat kesimine konu olacağı zamanı ya da ortalama bonitete göre göğüs yüzeyi veya hacmi dikkate alarak bir meşcereden ne kadar ürün çıkarılabileceğini belirlenebilmektedir.

Silvikültür uygulamalarında sıklık, bonitet ve yaşı bir fonksiyonu olarak geliştirilen büyüme modelleri ile göğüs yüzeyi gelişim seyri analiz edilerek optimal aralama derecesi üzerinde bir fikir yürütülebilmektedir. Ormancılık politikası uygulamalarında artım ve büyüme modelleri ile yetiştirme ortamının odun eksenli üretim potansiyeli üzerinde çıkarımlar yapılarak bir yılda toplam potansiyel üretim miktarı üzerinde bir değerlendirme yapabilmekte ve söz konusu veriler ile çeşitli politikalar belirlenebilmektedir. Yukarıdaki açıklamalar dikkate alındığında artım ve büyüme modelleri çok aşamalı sorun çözme tekniği olarak değerlendirilebilmektedir. Artım ve büyüme modellerinin bu öneminden dolayı özellikle Amerika Birleşik Devletleri başta olmak üzere ETFOP'u kullanan ülkelerde yukarıda belirtilen görevlere destek olması amacıyla büyüme simülatörleri geliştirilmiştir. Deneysel modellere örnek olarak DFSIM (Curtis *et al.* 1981), FIBER (Solomon *et al.* 1995), ORGANON (Hann *et al.* 2011), SILVA (Pretzsch *et al.* 2002) ve TASS (Mitchell 1969) gösterilebilmektedir. Süreç tabanlı modellere örnek olarak BALANCE (Grote and Pretzsch 2002), CenW (Kirschbaum 1999) ve Forest-BGC (Running and Coughlan 1988) çalışmaları verilebilmektedir.

1.2.1 Meşcere büyüme modelleri

Meşcere büyüme modelleri meşcere gelişim seyrini ortalama olarak (genel trend) ortaya koymaktadır (Vanclay 1994). Bu konuda geçmişte yapılan ilk çalışmalarda geçici örnek alan verileriyle hesaplanan hektardaki meşcere hacmi, göğüs yüzeyi ve ağaç sayısı, ortalama çap ve ortalama boy değerleri ile bonitet endeksi ve meşcere yaşı arasındaki ilişkiler grafiksel olarak ortaya konulmuştur (Kalıpsız 1963). Daha sonraki yıllarda yapılan çalışmalarda, insan müdahaleleri neticesinde meşcere yapıları değişikliğe uğradığından dolayı, meşcere gelişimlerini daha doğru bir şekilde belirlemek için yaş ve bonitet endeksi değişkenlerine ek olarak sıklık değişkeni de dikkate alınmıştır (Yeşil 1992, Mısır 2003). Meşcere büyüme modellerinin tahminlerini belirli çap sınıfı aralığında detaylandırmak için istatistiksel dağılım fonksiyonlarının parametreleri ve meşcere elemanları arasındaki fonksiyonel ilişkiden yararlanılmaktadır (Magnussen 1986). Ancak yine de meşcere gelişimleri detaylı bir şekilde ortaya konulmuş olmamaktadır.

Ülkemizde asli ağaç türlerimizin yayılış gösterdiği müdahale görmemiş alanlar için çeşitli araştırmacılar tarafında normal hasılat tabloları (optimal kuruluş) geliştirilmiştir. İlk hasılat tablosu 1954 yılında Trakya-Demirköy yöresinde yayılış gösteren meşe ormanları için İsmail Eraslan tarafından düzenlenmiştir (Günel 1981). Devam eden yıllarda, Alemdağ (1962), Erkan (1995) ve Çatal (2009) kızılçam, Kalıpsız (1963) karaçam, Alemdağ (1967) sarıçam, Evcimen (1963) sedir, Akalp (1978) ladin, Batu ve Kapucu (1995) kızılğaç, Carus (1998) kayın, Kapucu vd. (1999) dişbudak, Bilgili (2007) titre kava, Asan (1984) Kazdağı göknarı ve Eler (1986) boylu ardıc için normal hasılat tabloları geliştirmişlerdir.

Eşit yaşı, saf ve müdahale görmüş kestane meşcereleri için Kapucu vd. (2002), Artvin-Merkez Orman İşletme Şefliğinde yayılış gösteren doğu ladini meşcereleri için Ercanlı (2003) ve KTÜ Araştırma ormanında yayılış gösteren doğu ladini meşcereleri için Köse vd. (2001), Yalnızçam ve Uğurlu Orman İşletme Şefliklerinde yayılış gösteren sarıçam meşcereleri için Ercanlı vd. (2007a), Batı Karadeniz yöresinde yayılış gösteren sarıçam meşcereleri için Şenyurt (2011), Sinop Merkez ve Bektaşğa Orman İşletme Şefliklerinde yayılış gösteren sahil çamı meşcereleri için Ercanlı vd. (2007b), Trakya Bölgesinde yayılış gösteren ve koruya tahvile konu olan meşe meşcereleri için Özdemir (2013) ve Mersin yöresinde yayılış yapan kızılçam meşcereleri için Şahin (2015), Akdeniz Bölgesi kızılçam meşcereleri için Yeşil (1992) ve Karadeniz yöresi göknar meşcereleri için Saraçoğlu (1986) sıklığa bağılı hasılat tabloları düzenlemişlerdir. Bununla birlikte, Birler ve Yüksel (1983) ve Özcan (2002) sahil çamının, Usta (1991) kızılçamın, Birler (1983) melez kavağın, Birler vd. (1995) okaliptüsün, Kapucu vd. (1999) dişbudağın, Mısır (2003) karaçamın yapay meşcereleri ve Seki (2020) Kastamonu yöresinde yayılış yapan saf karaçam meşcereleri için sıklığa bağılı hasılat tabloları geliştirmişlerdir.

Karışık meşcerelere ilişkin çalışmalar incelendiğinde ise Durkaya (2004) Zonguldak Orman Bölge Müdürlüğünde yayılış gösteren sarıçam-göknar-kayın karışık meşcerelerinin artım ve büyüme ilişkilerini, Yücesan (2006) Rize ili, Çamlıhemşin ilçesi, Fırtına vadisinin yüksek dağlık arazilerindeki ladin ve kayın ağaç türlerinin saf ve

karışık meşcerelerinin meşcere kuruluşlarını, Ercanlı (2010) Trabzon ve Giresun Orman Bölge Müdürlükleri sınırları içerisinde yayılış gösteren doğu ladini-sarıçam karışık meşcerelerinin artım ve büyüme ilişkilerini, Yavuz vd. (2010) Karadeniz Bölgesi'nde yayılış gösteren saf sarıçam ve sarıçamın karaçam, kayın, ladin ve göknar ile meydana getirdiği karışık meşcerelerin artım ve büyüme ilişkilerini ve Kahriman (2011) Karadeniz Bölgesi'nde yayılış gösteren sarıçam-kayın karışık meşcerelerinin artım ve büyüme ilişkilerini incelemişlerdir.

1.2.2 Çap dağılım modelleri

Meşcere büyüme modelleri ile geliştirilen hasılat tabloları odun eksenli orman ürünlerinin çeşitlerine ilişkin ortalama bir değer vermektedir. Söz konusu ürün çeşitlerine ilişkin hacim bilgilerine ihtiyaç duyulduğunda ya da bir meşcereye kaç metre küp tomruk veya maden direği olduğunun belirlenmesinde çap dağılım modellerine ihtiyaç duyulmaktadır (Newton *et al.* 2005). Ayrıca, çap dağılım modelleri ile söz konusu ürün çeşitliliğinin zamansal olarak değerlendirilebilmesi de mümkün olabilmektedir (Reynolds *et al.* 1988).

Meşcere düzeyinde elde edilen tahminlerin çap sınıfı düzeyinde detaylandırılması için olasılık yoğunluk fonksiyonlarından yararlanılmaktadır. Ormancılık alanında çap dağılımlarının modellenmesi amacıyla genellikle Gamma (Nelson 1964), Log-normal (Bliss and Reineker 1964), Beta (Clutter and Bennet 1965), Weibull (Weibull 1951) ve Johnson SB (Johnson 1949) olasılık yoğunluk fonksiyonları tercih edilmektedir (Knoebel and Burkhart 1991, Nord-Larsen and Cao 2006, Gorgoso *et al.* 2012). Ülkemizde, Carus (1996) Beta, Normal, Gamma ve Weibull; Carus ve Çatal (2008) Beta, Gamma, Weibull, Normal ve Log-normal; Ercanlı ve Yavuz (2010) Gamma, Beta, Log-normal, Normal, Weibull ve Johnson SB; Sönmez vd. (2010) Weibull, Gamma, Beta, Lognormal, Normal ve Johnson SB; Kahriman ve Yavuz (2011) Gamma, Beta, Log-normal, Normal, Weibull ve Johnson SB; Sakıcı ve Gülsunar (2012) Üssel ve Weibull; Ercanlı *et al.* (2013) Weibull ve Johnson SB; Bolat (2014) Weibull; Doğdaş (2014) Gamma, Beta, Log-normal, Normal, Weibull ve Johnson SB; Çatal ve Güneş (2016) Beta, Gamma, Weibull, Normal ve Log-normal; Özçelik *et al.* (2016) Johnson SB; Sakıcı vd. (2016) Beta, Gamma, Johnson's SB, Lognormal, Normal ve Weibull;

Dal (2019) Beta, Gamma, Johnson SB, Log-normal, Normal ve Weibull ve Alkan (2019) Johnson SB olasılık yoğunluk fonksiyonlarını kullanarak çap dağılımlarını modellemişlerdir.

Çap dağılım fonksiyonlarına ilişkin parametrelerin tahmin edilmesinde maksimum olabilirlik (Zhang *et al.* 2003), moment (Ogana *et al.* 2017) ve dağılımların belirli yüzdeliklerini esas alan yöntemler (Maltamo *et al.* 2000, Bolat 2014) sıklıkla tercih edilmektedir. Ancak bazı araştırmacılar parametre hesaplama yönteminin basit olması ve beklenen doğrulukta tahminler üretmesi nedeniyle çap dağılımlarının yüzdeliklerini esas alan yöntemleri tercih etmektedir (Borders *et al.* 1987, Kangas and Maltamo 2000, Mehtätalo 2004, Stankova and Zlatanov 2010).

Meşcere ögeleri ile çap dağılım modellerinin parametreleri arasında fonksiyonel ilişkilerin kurulması ile ilgilenilen meşcere elemanının gelecekteki değerleri çap sınıfları düzeyinde hesaplanabilmektedir (Vanclay 1994). Gelecekteki çap dağılımlarının tahmin edilmesinde parametre tahmin yöntemi (prediction method) ve parametre çözümleme yöntemi (recovery method) kullanılmaktadır. Parametre tahmin yönteminde, çap dağılım fonksiyonlarının parametreleri ile meşcere özellikleri arasındaki fonksiyonel ilişkilerin belirlenirken parametre çözümleme yönteminde çap dağılımların ortalamaları, momentleri, standart sapmaları ve belirli yüzdelikleri ile meşcere elemanlarının geçmiş dönemdeki ve günümüzdeki değerleri arasındaki fonksiyonel ilişkiler belirlenmektedir (Reynold *et al.* 1988). Her iki parametre belirleme yönteminin başarısı kullanılan olasılık yoğunluk fonksiyonunun çap dağılımlarını temsil edebilme başarısına bağlı olarak değişmektedir.

1.2.3 Tek ağaç modelleri

Tek ağaç modelleri; çap dağılım modelleri ve meşcere büyüme modellerine kıyasla meşcere gelişimlerini daha ayrıntılı bir şekilde açıklayabilmektedir. Kısa dönemli silvikültürel seçeneklerin değerlendirilmesinde ya da orman zararlıları gibi çeşitli ekolojik etkilerin meşcere gelişimi üzerindeki etkilerinin gözlemlenmesinde tek ağaç

modelleri avantajlı görünmektedir. Özellikle rekabetin daha belirgin olarak görüldüğü karışık meşcerelerde ve değişik yaşlı meşcerelerde tek ağaç modelleri meşcere gelişimini daha gerçekçi yansıtabilmektedir (Peng 2000, Porté and Bartelink 2002). Ancak, tek ağaç modellerinin geliştirilmesinde kullanılan değişkenlerin ölçümünün zor olması ve orman envanter çalışmalarındaki ölçüm yükünü artırması nedeniyle meşcere ve çap dağılım modelleri ile kıyaslandığında tek ağaç modelleri dezavantajlı konuma düşmektedir. Benzer şekilde, meşcere modelleri ile kıyaslandığında tek ağaç modellerinin özellikle uzun dönemli tahminlerde meşcere gelişimini iyi bir şekilde açıklayamadığı ifade edilmektedir (Qin and Cao 2006).

Tek ağaç düzeyinde geliştirilen modeller örnek alanda çap ölçümü yapılan her bir ağacın gelişimini ortaya koymaktadır. Bu nedenle tek ağaç modellerinde gerçeğe yakın tahminler elde edebilmek için ağaçların boyutları, meşcere özellikleri, ağaçların yarışma durumları, toprak özellikleri, topoğrafik özellikler ve iklim parametreleri açıklayıcı değişkenler olarak kullanılabilir (Monserud and Sterba 1996, Adame *et al.* 2008a). Ancak bazı araştırmalarda kullanılacak değişkenlerin belirlenmesi noktasında farklı görüşler bulunmaktadır. Örneğin yaş değişkeninin tek ağaç modellerinde kullanılmasının bir kısıtlayıcı olduğunu ve çap değişkenin yaş değişkenine göre daha temsil edici olduğunu ifade eden çalışmalar bulunmaktadır (Ryan and Yoder 1997, Bond *et al.* 2007). Benzer şekilde, eğim, bakı, yükselti, toprak özellikleri ve iklim değişkenleri gibi çap artımı üzerinde etkili olan faktörler yerine söz konusu değişkenlerin bir göstergesi olan bonitet endeksini açıklayıcı değişken olarak dikkate alan çalışmalar bulunmaktadır (Mısır 2003, Ercanlı 2010).

Tek ağaç modelleri ağaçlar arası mesafe ve ağaçların boyutları dikkate alınarak geliştirildiğinde uzaklığa bağlı tek ağaç modelleri, diğer bir ifade ile konumsal modeller olarak adlandırılmaktadır. Ağaçlar arası mesafenin dikkate alınmadığı modeller uzaklıktan bağımsız tek ağaç modelleri olarak isimlendirilmektedir. Her iki model tipinde de kullanılan bağımsız değişkenlere ilişkin ölçümlerin zor ve zaman alıcı olması modellerin kullanılabilirliğini kısıtlamaktadır. Ancak tek ağaç modellerinin meşcere gelişimi ve kompozisyonu üzerinde oldukça etkili olan yarışma endekslerinin fonksiyonu olarak geliştiriliyor olması, söz konusu modelleri öne çıkaran avantajıdır.

Uzaklığa bağlı tek ağaç modelleri örnek alandaki ağaçların konumlarına dayalı olarak yarışma endeksini ortaya koyduğundan dolayı silvikültürel müdahalelerin artım üzerine etkisinin değerlendirilmesinde önemli bir araç olarak karşımıza çıkmaktadır (Newnham and Smith 1964). Ancak söz konusu yarışma endekslerinin hesaplanmasında ağaçlar arası mesafenin kullanılıyor olması bu modeller için en belirgin kısıtlayıcıdır. Diğer taraftan, ağaçların gelişiminin ortaya konmasında ağaçlar arası mesafenin oldukça önemli olması uzaklığa bağlı tek ağaç modellerini avantajlı konuma getirmektedir. Kolombiya’da ve Almanya’da geliştirilen TASS ve SILVA yazılımları uzaklığa bağlı tek ağaç büyüme simülatörlerine örnek olarak verilebilir. Uzaklıktan bağımsız tek ağaç modellerinde yarışma endeksi ağaçların boyutlarına göre hesaplanmaktadır. Bu nedenle, söz konusu bu modeller klasik orman envanterinden elde edilen bilgilere dayalı olarak geliştirilebilmektedir. Bu yöntemde ağaçlar arası mesafe dikkate alınmadığından örnek alan içindeki her bir ağacın diğer ağaçlarla rekabet içinde olduğu varsayılmaktadır. Dolayısıyla örnek alan büyüklüğü değiştiğinde ağaçlara ilişkin yarışma indeksi değişebilmektedir. Bu durum uzaklıktan bağımsız tek ağaç modellerine ilişkin en belirgin kısıtlayıcı olarak karşımıza çıkmaktadır. Avusturya’da ve Amerika’da geliştirilen PROGNAUS ve ORGANON yazılımları uzaklıktan bağımsız tek ağaç simülatörlerine örnek olarak verilebilir.

Ülkemizde, Üçler vd. (2001) Alpin zona yakın saf doğu ladini meşcerelerinin çap artımını, Mısır (2003) karaçam plantasyonlarının çap, göğüs yüzeyi ve hacim artımlarını, Carus (2004) Isparta-Sütçüler yöresinde yayılış gösteren boylu ardıc meşcerelerinin çap artımını, Atıcı (2004) değişik yaşlı doğu kayını meşcerelerinin çap, boy ve hacim artımlarını, Sıvacıoğlu vd. (2006) Kastamonu-Taşköprü yöresinde yayılış gösteren sarıçam meşcerelerinde uygulanan sıklık bakımının çap, boy, göğüs yüzeyi ve hacim artımları üzerine etkisini, Ercanlı vd. (2007c) sarıçam meşcerelerinde meşcere yaşı, bonitet endeksi ve sıklık derecesinin hacim artımı üzerine etkisini, Carus ve Çiçek (2007) Adapazarı-Süleymaniye yöresinde yayılış gösteren dişbudak plantasyonlarının çap artımını, Ercanlı (2010) Trabzon ve Giresun Orman Bölge Müdürlüklerinde yayılış gösteren doğu ladini-sarıçam karışık meşcerelerinin çap artımını, Yavuz vd. (2010) Karadeniz Bölgesinde yayılış gösteren saf ve karışık sarıçam meşcerelerinin çap

artımını, Özdemir (2011) sarıçam-göknar-kayın karışık meşcerelerinin çap artımını, Şenyurt (2011) Batı Karadeniz Bölgesinde yayılış gösteren sarıçam meşcerelerinin çap artımını, Kahriman ve Yavuz (2012) doğu karadeniz göknarı-doğu ladini karışık meşcerelerinde yarışma endekslerinin çap artımına etkisini, Çatal vd. (2014) Isparta Orman Bölge Müdürlüğü Alağsun Orman İşletme Şefliği sınırlarında yayılış gösteren kızılçam plantasyonlarında periyot süresi ve meşcere sıklığının çap artımı üzerine etkisini, Özdemir (2014) Karadeniz yöresinde yayılış yapan göknar meşcerelerinin çap ve hacim artımını ve Yazıcı ve Çatal (2019) Isparta ili, Uluborlu ilçesinde bulunan Uluborlu barajının Anadolu karaçamı meşcerelerinin çap artımı üzerine etkisini araştırmışlardır.

1.3 Yapay Sinir Ağı Modelleri

İnsanlara benzer makinaların tasarımı düşüncesi 13. yy. kadar dayanmaktadır. Arap dünyasında ortaya atılan *matematikte mantıksal çıkarımlar düşüncesi*, Avrupa’da bilimin ilerlemesine katkı sağlamış ve *Raymond Lilly*’in (1235-1315) “*Ars Magna*” kitabında “*düşünme yetenekleri ilkesi*” ortaya atılmıştır. Bu ilkeye göre, simge ya da kelimeden oluşan girdi değişkenleri rasgele biçimde yeterince büyük uzunluklu ardışık bir seri oluşturabilirse çıkış katmanında anlamlı geçerlilikler taşıyan alfabeler üretilebilir şeklinde ifade edilmiştir. Düşünen makine fikri *Descartes*’i de etkilemiştir. *Descartes* hayvanları iç güdülerine göre hareket eden kodlanmış canlılara benzetmektedir.

Yapay zekâ konusunda yapılan somut çalışmaların ilki İngiliz matematikçi *Alan Turing*’in “*Turing testi*” olarak bilinen oyununa dayanmaktadır. *Mind (ABD)* dergisinde 1950 yılında basılan “*Computing Machinery and Intelligence*” başlıklı makalede “makinalar düşünebilir mi?” sorusuna yanıt aranmıştır. Söz konusu çalışmanın sonucunda bir makinanın insan kadar anlamlı yanıt verebildiği belirtilmiştir (Turing 1950). Devam eden yıllarda satranç gibi yapay zekâ problemlerinin kodlanmaya başlanması düşünen makineler fikrini güçlendirmeye başlamıştır. *Simon and Newell* (1958) bilgisayarların on yıl içerisinde satranç şampiyonu olacaklarını, müzik yazabileceklerini ve henüz bilinmeyen önemli matematiksel teoremleri

çözebileceklerini ifade etmişlerdir. Ancak yapay zekâ konusunda *Simon* ve *Newell*'ın hayal ettiği kadar bir gelişme yaşanmamıştır. Buna karşın, IBM tarafından 1997 yılında geliştirilen “*Deep Blue*” isimli satranç bilgisayarının eski dünya şampiyonu *Garry Kasparov*'u yenmesi önemli bir gelişme olarak kaydedilmiştir (URL-1).

İlk yapay sinir ağı yapısı McCulloch and Pits (1943) tarafından bazı matematiksel teoremlere dayalı olarak geliştirilmiştir. İlgili çalışmada yapay sinir ağı hücrelerinin paralel çalışması gerektiği fikri ortaya atılmış ve böylece ilk öğrenme kuralı ortaya çıkmıştır. Bu çalışmayı takiben 1949 yılında Hebb “*Organization of Behavior*” isimli kitabında “*Hebbian Öğrenme*” kuramını tanıtmış ve yapay sinir ağının bağlantı sayısı ile öğrenme yeteneği arasında bir ilişkinin olduğunu ortaya çıkarmıştır. İlgili öğrenme kuramı esas alınarak 1951 yılında ilk *nuro-bilgisayar* üretilmiştir. Farelly and Clark (1954) rassal ağlar ile adaptif tepki üretme yaklaşımını ortaya atmış ve daha sonra bu yaklaşım Rosenblatt (1958) tarafından geliştirilerek tek katmanlı, bir giriş ve bir çıkışın olduğu öğrenebilen yapay sinir ağı modeli tasarlanmıştır. Mühendislik alanında ilk yapay sinir ağı modelinin kullanımı Widrow and Hoff (1960) tarafından geliştirilen ADALINE (*Adaptive Linear Neuron*) modeli ile gerçekleşmiştir. Söz konusu model esas alınarak 1970’li yıllarda telefon hatlarında oluşan yankıları gidermek amacıyla MADALINE algoritması geliştirilmiştir. Dünyada bu gelişmeler yaşanırken Cahit Arf 1959 yılında Atatürk Üniversitesinde (Erzurum) düzenlediği bir Halk Konferansında “*Makine düşünebilir mi ve nasıl düşünebilir?*” başlıklı çalışmasında yer verdiği farklı tipten problemleri bir makinanın kendisine tanıtılan bilgilerden faydalanarak nasıl öğrendiğini ve nasıl çözüm ürettiği anlatmıştır. Bu gelişmeler her ne kadar dikkatleri yapay sinir ağlarına çekmiş olsa da yapay zekâ fikrinin öncülerinden *Minsky* ve *Papert* 1969 yılında yayımladıkları “*Perceptrons*” adlı kitapta yapay sinir ağlarının doğrusal olmayan problemlere çözüm üretemediğini (XOR problemi) belirtmişlerdir. Yaşanan bu gelişme yapay sinir ağları konusundaki çalışmaları durdurma noktası getirmiş ve hatta ABD’de yapay sinir ağları çalışmalarına verilen fonlar durdurulmuştur. Bu gelişmelere rağmen çalışmalarına devam eden bazı bilim insanları yapay sinir ağları konusunu yeniden canlandırmıştır. Özellikle Kohonen (1982)’in kendi kendine öğrenme nitelik haritalarını (*self organzing feature maps*) konu edinen çalışması ve Hopfield (1982)’in yapay sinir ağlarının genelleştirilebileceğini ve çözülmesi zor olan problemlere çözüm

üretebileceğini gösteren çalışması yapay sinir ağlarına karşı duyulan ilgiyi yeniden canlandırmıştır. Bu gelişmelerin neticesinde yapay sinir ağları farklı disiplinlerde istatistiksel bir araç olarak kullanılmaya başlanmıştır (Sharda 1994). Yapay sinir ağlarının yeniden gündeme geldiği tarihlerde yapılan çalışmalar incelendiğinde çoğunlukla sınıflandırma amacıyla kullanıldığı görülmektedir. Ayrıca, ilgili dönemde bu çalışmalara ek olarak yapay sinir ağlarının doğrusal ve doğrusal olmayan optimizasyon problemlerinin çözümünde de kullanıldığı görülmektedir (Looi 1992, Wang and Chankong 1992). Takip eden yıllarda neredeyse tüm disiplinlerde binlerce çalışma gerçekleştirilmiştir. Bu tez çalışmasında ormancılık disiplinde üretilen dokümanlardan bazıları tarihsel bir sırayla verilmiştir.

Ormancılık alanında yapay sinir ağları konusunda yapılan çalışmaların tarihçesi 1991 yılına dayanmaktadır. Guan and Gertner (1991) ağaçların kuruma olasılıklarını tahmin ettikleri çalışmalarında yapay sinir ağları yöntemini kullanmıştır. Bu çalışmayı önemli kılan bir diğer husus, yapay sinir ağlarının büyüme kanuniyetlerine göre değerlendirilmesidir.

Zurk *et al.* (1992) yarı kurak bir bölgedeki toprak sıcaklığını jeofiziksel değişkenleri (toprak nemi, vejetasyon nemi ve toprak sıcaklığı) kullanarak yapay sinir ağları ile tahmin etmişlerdir.

Pierce *et al.* (1993) “*Canopy Scattering model*”, MIMICS, yöntemini 3 gizli katmana ve 10 nörona sahip bir yapay sinir ağı modeliyle karşılaştırmış ve özellikle tepe çapı çeşitliliğinin fazla olduğu örneklerde yapay sinir ağlarının MIMICS yönteminden daha başarılı olduğunu ifade etmişlerdir.

Kanellopoulos *et al.* (1993) maksimum olabilirlik yöntemine dayalı kontrollü sınıflandırma ve yapay sinir ağları ile arazi kullanımlarını sınıflandırmışlardır. Bu çalışmada yapay sinir ağları ile istatistiksel metodun sonuçları birbirine yakın elde edilmiştir.

Elizondo *et al.* (1994) tarım bitkilerinin artım ve büyümesi üzerinde etkili olan ve bu alanda geliştirilen birçok büyüme modelinde açıklayıcı değişken olarak kullanılan ancak ölçümü zor ve pahalı ekipmanlar gerektiren günlük toplam solar radyasyonu günlük meteorolojik ve çevresel değişkenlerden faydalanarak yapay sinir ağları ile tahmin etmiştir. Bu çalışmada yalnızca günlük minimum ve maksimum hava sıcaklığı ve yağış miktarı bilirse günlük toplam solar radyasyondaki değişkenliğin en az %52'si ve en çok %74'nün yapay sinir ağları ile açıklanabildiği ifade edilmiştir.

Vega-Garcia *et al.* (1996) insan kaynaklı orman yangınlarını ormanlık alan miktarı, orman yoluna uzaklık, toplam şahıs arazisi, yangın yayılım oranı, potansiyel yanıcı madde miktarı ve rüzgâr hızı bilgilerinden faydalanarak yapay sinir ağları ile tahmin etmişlerdir. Bu çalışmada yapay sinir ağlarının sınıflama doğruluğu %78 olarak bulunmuştur.

Foody *et al.* (1997) orman, mera ve nehir arazi türlerini 3 girdi, 6 gizli ve 3 çıktı katmanı bulunan yapay sinir ağı modeliyle sınıflandırmış ve özellikle mera ve orman arazi sınıfları için elde edilen tahminlerin gerçek verilerle sırasıyla %84 ve %85 oranında yüksek ilişkiler içinde olduğunu ifade etmişlerdir.

Paruelo and Tomasel (1997) regresyon modeli ve yapay sinir ağları ile aylık yağış ve sıcaklık verilerinden faydalanarak normalize edilmiş vejetasyon indisini tahmin ettikleri çalışmalarında yapay sinir ağlarının daha başarılı olduğunu ifade etmişlerdir.

Schmoldt *et al.* (1997) bilgisayarlı tomografi görüntüleri üzerinden odun kusurlarını sınıflandırmak için yapay sinir ağları yöntemini kullandıkları çalışmalarında %95 doğruluk oranı elde etmişlerdir.

Schultz *et al.* (1999) *Pinus teada* ağaçlarından elde edilen talaş kalınlığını ağaç ve meşcere özelliklerinden faydalanarak yapay sinir ağları ve regresyon yöntemleri ile

tahmin etmiş ve yapay sinir ağlarının talaş kalınlığındaki değişkenliğin %96'sını açıklayabildiğini ifade etmişlerdir.

Jensen *et al.* (1999) Landsat TM verilerinden faydalanarak yapay sinir ağları ve regresyon modeli ile iğne yapraklı bir ormanda meşcere yaşını tahmin ettikleri çalışmalarında yapay sinir ağlarına ilişkin hata kareler ortalamasının karekökü değerini (rmse) 1,440, regresyon modeline ilişkin değeri ise 1,913 olarak bulmuşlardır.

Zhang *et al.* (2000) iklim değişkenlerinden faydalanarak yapay sinir ağları ile çap artımını tahmin ettikleri çalışmalarında, çap artımındaki değişkenliğin %66,8'ni açıklamışlardır.

Hyppä *et al.* (2000) çeşitli uydu görüntüleri yardımıyla yapay sinir ağlarını kullanarak meşcere orta boyu, meşcere göğüs yüzeyi ve meşcere hacmini tahmin etmişlerdir. Meşcere orta boyu, göğüs yüzeyi ve hacmi için en yüksek belirtme katsayıları sırasıyla %77, %59 ve %68 olarak elde edilmiştir.

Hasenauer *et al.* (2001) göğüs yüksekliği çapı, ağaç boyu, yarışma endeksi, yükselti, toprağın A ve F horizon kalınlıklarına ilişkin verilerden faydalanarak yapay sinir ağları ve lojistik regresyon modeliyle ağaçların kuruma olasılığını tahmin ettikleri çalışmalarında iki yöntemin birbirine yakın doğrulukta sonuçlar ürettiklerini ifade etmişlerdir.

Leduc (2001) meşcere özellikleri ile 3 parametrelili Weibull fonksiyonunun parametreleri arasındaki ilişkinin tahmin edilmesinde regresyon yöntemi, parametre çözümleme yöntemi ve yapay sinir ağlarını kullandıkları çalışmalarında karesel ortalama hata değerlerini (mse) sırasıyla 0,002861, 0,002591 ve 0,002378 olarak bulmuşlardır.

Lopez *et al.* (2001) birçok biyolojik süreci kontrol eden saatlik fotosentetik aktif radyasyonu meteorolojik, radyometrik ve güneşlenme süresi değişkenlerinden

faydalananak yapay sinir ađları ile tahmin ettikleri alıřmalarında saatlik fotosentetik aktif radyasyondaki deđiřkenliđin %99’nu aıklamıřlardır.

Corne *et al.* (2004) cođrafi koordinat bilgileri ve topođrafik verileri kullanarak ormanları kapalılık durumuna, arazi kullanım türüne (orman toprađı, saf ormanlar ve karıřık ormanlar) ve geliřim ađına göre (ince ve kalın aplı) sınıflandırmak için farklı yapay sinir ađı modellerini test etmiřtir. Bu alıřmada, genelleřtirilmiř regresyon ađları ve olasılık tabanlı yapay sinir ađları yöntemini en bařarılı olarak belirlemiřtir. Kapalılık, arazi kullanım ve geliřim ađı sınıflarında genelleřtirilmiř ve olasılık tabanlı yapay sinir ađlarının dođruluk oranlarını sırasıyla %87,7 ve 90,0, %86,2 ve 86,1, %55,7 ve 54,1 olarak bulmuřlardır.

Hanewinkel (2005) fırtına vb. iklimsel tehlikelere karřı ormanların duyarlılıđını analiz ettiđi alıřmasında lojistik regresyon ve yapay sinir ađları yöntemini kıyaslamıř ve yapay sinir ađlarının bahsi geen istatistiksel metottan daha iyi olduđunu ifade etmiřtir.

Wang *et al.* (2005) metrik cođrafi koordinatlardan ve iklim deđiřkenlerinden faydalananak dođrusal olmayan regresyon, karar ađaları modeli, genelleřtirilmiř eklemeli model ve yapay sinir ađları yöntemi ile bonitet endeksini tahmin etmiřler ve bonitet haritaları üretmiřlerdir. En bařarılı yöntemin yapay sinir ađlarını olduđunu ifade etmiřlerdir.

Liu and Zhang (2005) yapay sinir ađları ve regresyon yöntemlerini kullanarak ađa hacimlerini tahmin ettikleri alıřmalarında iki yöntemin birbirine yakın bařarı ölçütlerine sahip olduđunu (sırasıyla R^2 , 0,9756 ve 0,9753); ancak göz ardı edilebilecek bir farkla yapay sinir ađlarının daha üstün olduđunu ifade etmiřlerdir.

Diamantopoulou (2006) ađaların farklı yüksekliklerindeki gövde aplarını yapay sinir ađları ile tahmin ettiđi alıřmasında en düşük belirtme katsayısı deđerlerini yerden 3,3

metre yüksekliğindeki göğüs çapı için 0,9740 ve en yüksek belirtme katsayısı değerini yerden 8,8 metre yüksekliğindeki göğüs çapı için 0,9999 olarak elde etmişlerdir.

Kaloudis *et al.* (2006) yükseklik, eğim, bakı, pH, yüzey taşlılık miktarı, ağacın göğüs yüzeyi, tepe kapallılığı ve toprak derinliği verilerini kullanarak gövde çaplarını tahmin ettikleri çalışmalarında en düşük ve en yüksek belirtme katsayısı değerlerini sırasıyla 0,9224 ve 0,9581 olarak bulmuşlardır.

Kuplich (2006) yapay sinir ağları yöntemini kullanarak meşcereleri yaşlarına göre sınıflandırdığı çalışmasında yaş sınıfları düzeyinde yeterli veri olmadığından modelin doğruluk oranını %46 olarak elde etmiştir. Bu çalışmada tüm yaş sınıflarını birleştirip meşcereler arazi kullanımlarına göre sınıflandırıldığında %71,57 doğruluk oranı elde edilmiştir.

Castellanos *et al.* (2007) göğüs yüksekliği çapı, kabuk kalınlığı, çap artımı ve ağaç boyu verilerini kullanarak yapay sinir ağları ile ağaç hacimlerini tahmin ettikleri çalışmalarında Huber formülü ve yapay sinir ağları için hesaplanan karesel ortama hata değerlerini sırasıyla 0,05 ve 0,007 olarak bulmuşlardır.

Klobučar *et al.* (2008) meşcere hacmi, meşcere ağaç sayısı ve meşcere yaşını tahmin etmek için yapay sinir ağı yönteminden faydalandıkları çalışmada karesel ortalama hata değerlerini sırasıyla 0,0468, 0,1092 ve 0,1631 olarak hesaplamışlardır.

Li *et al.* (2009) nüfus ve meteorolojik parametrelerden faydalanarak orman yangın riskini yapay sinir ağları ve polinom regresyon modelleri ile geliştirdikleri çalışmalarında ideal yakınsama değerinin 0,0001 ile 0,000001 arasında değiştiğini bildirmişlerdir.

Diamantopoulou and Milios (2010) kabuklu ve kabuksuz ağaç hacimlerini doğrusal ve doğrusal olmayan regresyon analizi ile yapay sinir ağlarını kullanarak tahmin ettikleri

alışmalarında metotlara ilişkin hata kareler ortalamasının karekökü deęerlerini (rmse) sırasıyla 0,06792, 0,04979 ve 0,02810 olarak bulmuşlardır.

Král *et al.* (2010) yapay sinir aęları yöntemiyle meşcerelerdeki canlı ve kurumuş aęaçları gelişim çaęlarına ve büyüme dönemlerine (ör. growth stage, optimum stage ve breakdown stage) göre sınıflandırmışlar ve %68,4 doğruluk oranı elde etmişlerdir.

Bilgili (2011) aylık ortalama toprak sıcaklığını meteorolojik parametrelerden yararlanarak yapay sinir aęları yöntemi ile tahmin ettięi alışmasında en yüksek ilişkiyi topraęın 100 cm derinliğinde ölçülen sıcaklık deęeri ile elde etmiştir (korelasyon katsayısı 0,9984).

Özelik *et al.* (2010) eşitli aęaç türlerinin gövde hacimlerini tahmin etmek için Smalian formülü, *Centroid* metodu ve yapay sinir aęlarını kullandıkları alışmalarında Centroid metodunun dięer yöntemlerden daha doğru sonuçlar ürettiğini ifade etmişlerdir.

Higgins (2011) yapay sinir aęları ile artım ve büyümeyi tahmin ettięi alışmasında kuruma olasılığı tahmini için karesel ortalama hata deęerlerini 0,0078, hata kareler ortalamasının karekökü deęerini göęüs yüzeyi için 24 cm² ve hacim için 16 cm³ olarak bulmuşlardır.

Diamantopoulou and Özelik (2012) ap ve boy arasındaki fonksiyonel ilişkiyi belirlemek amacıyla genelleştirilmiş regresyon aęları yöntemi ile doğrusal olmayan modelleri (ör. Gompertz, Weibull ve Richards fonksiyonu) kıyasladıkları alışmalarında yapay sinir aęları yöntemini daha başarılı bulmuşlardır.

Leite *et al.* (2011) yapay sinir aęları ve Kozak *et al.* (1969) denklemi ile aęaçların farklı yükseklikteki gövde aplarını tahmin ettikleri alışmalarında yapay sinir aęları yöntemini daha başarılı bulmuşlardır.

Ashraf *et al.* (2013) iğne yapraklı ve geniş yapraklı ağaçların göğüs yüzeyleri toplamı, BAL değerleri, galip ağaçların boyu, sıklık oranı, toprak nemi, toprak besin elementleri, büyüme sezonu içindeki sıcaklık, solar radyasyon ve tür sınıflama kodu (19 tür) olmak üzere toplam 29 girdi değişkenini kullanarak yapay sinir ağı tekniği ile göğüs yüzeyi ve hacim artımını tahmin eden uzaklıktan bağımsız tek ağaç modeli geliştirmişlerdir. Bu çalışmada göğüs yüzeyi ve hacim artımı için elde edilen en küçük hata kareler ortalamasının karekökü değerlerini sırasıyla 23,2130 cm² ve 0,0180 m³ olarak elde etmişlerdir.

Özçelik *et al.* (2013) göğüs çapı değişkeninden yararlanarak ağaç boylarını doğrusal olmayan model, ve yapay sinir ağı ile tahmin ettikleri çalışmalarında kalibre edilmiş doğrusal olmayan karışık etkili Gompertz modelinin en başarılı olduğunu ifade etmişlerdir.

Castaño-Santamaría *et al.* (2013) değişik yaşlı meşcerelerde ağaç boyunu tahmin etmek için doğrusal olmayan model, doğrusal olmayan karışık etkili model ve yapay sinir ağı yöntemini kullandıkları çalışmalarında kalibre edilmiş Bertalanffy–Richards modeli ile yapay sinir ağlarının başarı ölçütlerine göre oldukça benzer olduklarını ancak az bir farkla kalibre edilmiş karışık etkili modelin daha başarılı olduğunu ifade etmişlerdir.

Vinícius Oliveira Castro *et al.* (2013) ağaçların kuruma olasılıklarını, göğüs çaplarını ve boylarını yapay sinir ağı ile tahmin ettikleri çalışmalarında en başarılı ağ tasarımına ilişkin hata kareler ortalaması karekökü değerlerini sırasıyla 0,799, 0,993 ve 0,995 olarak bulmuşlardır.

Özçelik *et al.* (2014) gövde çapı verileri, tepe uzunluğu ve tepe oranı değişkenlerinden yararlanarak gövde çapı ve ağaç hacimlerini tahmin etmek için farklı optimizasyon yöntemlerine dayalı olarak geliştirdikleri yapay sinir ağı modellerini kıyasladıkları çalışmalarında Levenberg-Marquardt optimizasyon tekniği ile geliştirilen yapay sinir ağını en başarılı olarak bulmuşlardır.

Diamantopoulou *et al.* (2015) iki parametrelili Weibull fonksiyonunun şekil ve ölçek parametrelerini meşcere orta çapı, meşcere göğüs yüzeyi, meşcere ağaç sayısı ve meşcere yaşı değişkenlerinden faydalanarak doğrusal model ve yapay sinir ağları yöntemiyle tahmin ettikleri çalışmalarında; şekil parametresine ilişkin belirtme katsayıları sırasıyla

0,0364 ve 0,9491 ve ölçek parametresine ilişkin belirtme katsayıları sırasıyla, 0,9617 ve 0,9868'dir.

Ercanlı *et al.* (2015) yapay sinir ağları ile yaş ve boy arasındaki ilişkileri modelledikleri çalışmalarında belirtme katsayısı değerini 0,97 olarak bulmuşlardır.

Şenyurt *et al.* (2015) yapay sinir ağları ile asli meşcere elemanlarını tahmin ettikleri çalışmalarında orta çap, orta boy, ağaç sayısı, göğüs yüzeyi ve hacimdeki değişkenliğin sırasıyla %82,5, 86,7, 83,7, 99,8 ve 98,5'nin açıklandığını ifade etmişlerdir.

Bolat and Ercanlı (2016) İleri beslemeli yapay sinir ağı tekniği ile çap sınıfının orta değerini, çap dağılımlarının %31 ve %63'lük değerlerini girdi değişkeni olarak kullanarak her bir çap sınıfındaki ağaç oranını regresyon tekniği ve yapay sinir ağları ile tahmin ettikleri çalışmalarında belirtme katsayılarını sırasıyla 0,74 ve 0,90 olarak elde etmişlerdir.

Ercanlı *et al.* (2016) Landsat TM görüntüsünden elde edilen bant yansıma ve vejetasyon indis değerlerinden faydalanarak yapay sinir ağları ve regresyon modeli ile meşcere karbon miktarını tahmin ettikleri çalışmalarında belirtme katsayıları değerlerini sırasıyla 0,654 ve 0,425 olarak elde etmişlerdir.

Reis *et al.* (2016) göğüs yüksekliği çapı, yarışma endeksi ve gelişim çağı, gövde sınıflaması ve *liana* zararlısının bulaşma yoğunluğuna ilişkin kategorik değişkenleri

kullanarak yapay sinir ağıları tekniği ile yıllık çap artımındaki değişkenliğin %98,98'ni açıklamışlardır.

Vahedi (2016) bazı türlerin biyokütle miktarını tahmin etmek için doğrusal modeller ve yapay sinir ağılarını kullandıkları çalışmalarında modeller için hesaplanan en yüksek belirtme katsayıları sırasıyla 0,913 ve 0,976'dır.

Özçelik *et al.* (2017) kızılçam biyokütle miktarını görünüşte ilişkisiz regresyon yöntemi ve yapay sinir ağıları yöntemiyle tahmin ettikleri çalışmalarında hesaplanan belirtme katsayıları sırasıyla 0,9821 ve 0,9883'tür.

Lima *et al.* (2017) meşcere hacmi ve bonitet endeksini yapay sinir ağıları ile tahmin ettikleri çalışmalarında standart hata değerlerini sırasıyla 12,90 m³ ve 4,35 m olarak raporlamışlardır.

Günlü and Ercanlı (2017) doğrusal regresyon ve yapay sinir ağıları ile meşcere karbonunu tahmin ettikleri çalışmalarında modellerin belirtme katsayılarını sırasıyla 0,374 ve 0,510 olarak elde etmişlerdir.

Ercanlı *et al.* (2018) karaçam meşcerelerinin yaprak alan indeksini meşcere göğüs yüzeyi, meşcere ağaç sayısı, bonitet endeksi ve meşcere yaşı değişkenlerinden faydalanarak yapay sinir ağıları ve doğrusal regresyon yöntemiyle tahmin ettikleri çalışmalarında belirtme katsayılarını sırasıyla 0,6392 ve 0,5431 olarak hesaplamışlardır.

Sakıcı and Özdemir (2018) kayın ve kazdağı göknarı ağaçlarının değişik yüksekliklerdeki gövde çaplarını gövde çapı modelleri ve yapay sinir ağıları ile tahmin etmişlerdir. Bu çalışmada kayın için en başarılı gövde çapı modelinin ve en başarılı yapay sinir ağıının belirtme katsayıları sırasıyla 0,987 ve 0,990; Kazdağı göknarı için 0,988 ve 0,990 olarak elde edilmiştir.

Sakıcı and Günlü (2018) Landsat 8 uydu görüntüleri yardımıyla meşcere parametrelerini yapay sinir ağları ile tahmin ettikleri çalışmalarında meşcere orta çapı, göğüs yüzeyi, hacim ve ağaç sayısındaki değişkenliğin sırasıyla %59, 63, 65 ve 61’ni açıklayabilmişlerdir.

Che *et al.* (2019) meşcere göğüs yüzeyini meşcere yaşı, meşcere ağaç sayısı, meşcere orta çapı ve bonitet endeksi değişkenlerinden yararlanarak karışık etkili modelleme, yapay sinir ağları ve destek vektör makinaları yöntemleriyle tahmin ettikleri çalışmalarında destek vektör makinaları yöntemini en başarılı olarak bulmuşlardır.

Şenyurt and Ercanlı (2019) ağaç hacimlerini tek ve çift girişli regresyon modelleri, görünüşte ilişkisiz regresyon modeli ve yapay sinir ağları ile tahmin ettikleri çalışmalarında belirtme katsayılarını sırasıyla 0,9087, 0,9582, 0,9173 ve 0,9802 olarak bulmuşlardır.

Shen *et al.* (2020) ağaç boylarını tahmin etmek için doğrusal olmayan çap-boy modelleri ve yapay sinir ağlarını kullandıkları çalışmalarında modellere ilişkin belirtme katsayılarını sırasıyla 0,6837 (en başarılı olan Mitscherlich) ve 0,7541 olarak elde etmişlerdir.

Şenyurt *et al.* (2020) dip kütük çapı ve göğüs çapı arasındaki ilişkiyi açıklamak için çeşitli doğrusal modeller (Power, S ve logaritmik) ve yapay sinir ağlarını kullandıkları çalışmalarında elde ettikleri belirtme katsayılarını sırasıyla 0,9303 (en başarılı olan Quadratic) ve 0,9368 olarak bulmuşlardır.

Ercanlı (2020) göğüs çapı ve ağaç boyu arasındaki ilişkiyi açıklamak için karışık etkili modelleme parametreleri içeren doğrusal olmayan çap-boy modelleri ve derin öğrenme yöntemini kullandığı çalışmasında başarı ölçütlerine göre modellerin oransal sıra numaralarını hesaplamıştır. Bu çalışmada, oransal sıra numarasına göre en başarılı model derin öğrenme olarak elde edilmiştir.

Günlü and Ercanlı (2020) doğrusal model ve yapay sinir ağları ile meşcere karbonunu tahmin ettikleri çalışmalarında yapay sinir ağları kullanıldığında belirtme katsayısının %13 oranında arttığını ifade etmişlerdir.

Hamidi *et al.* (2021) tek ağaç çap artımlarını doğrusal model ve yapay sinir ağları ile tahmin ettikleri çalışmalarında elde ettikleri belirtme katsayıları sırasıyla 0,73 ve 0,86'dır.

Verilen literatür özeti değerlendirildiğinde yapay sinir ağlarının 2010 yılına kadar genellikle sınıflandırma amacıyla, 2010 yılından sonra ise sınıflandırmaya ek olarak artım, büyüme ve allometrik ilişkilerin modellenmesinde kullanıldığı görülmektedir. Ancak, artım ve büyüme modelleri konusunda az sayıda çalışma bulunduğu ve bu çalışmalarda yapay sinir ağı tasarımı hakkında verilen bilgilerin yeterli düzeyde olmadığı görülmektedir. Bu bağlamda, bu çalışmada artım ve büyüme modelleri konusunda yapay sinir ağlarının tasarımı hakkında detaylı bilginin verilmesi amaçlanmaktadır.

2. MATERYAL VE YÖNTEM


2.1 Materyal

2.1.1 Çalışma alanı

Bu çalışmada, Ankara Orman Bölge Müdürlüğü sınırları içerisinde yayılış gösteren saf Anadolu karaçamı (*Pinus nigra* Arnold. subsp. *pallasiana* Lamb.) meşcereleri örneklenmiştir. Envanter çalışmaları sekiz farklı Orman İşletme Müdürlüğünde gerçekleştirilmiştir. Orman İşletme Müdürlüklerindeki karaçam meşcerelerinin alansal dağılımları ve toplam alan içinde yüzdesel olarak ne kadar bir alana sahip oldukları Çizelge 2.1’de verilmektedir. Bu bölgelerdeki karaçamın yayılışı ve örnek alanların konumları Şekil 2.1’de verilmektedir.

Çizelge 2.1 Saf karaçam meşcerelerinin orman işletme müdürlüklerine göre alansal dağılımı

Orman İşletme Müdürlükleri	Alan (ha)	%
Beyazır	13606	10,8
Çamlıdere	6832	5,4
Çankırı	22437	17,8
Çerkeş	7022	5,6
Eskipazar	8315	6,6
İlgaz	15986	12,7
Kızılcahamam	13491	10,7
Nallıhan	38371	30,4
Toplam	126060	100




Şekil 2.1 Ankara Orman Bölge Müdürlüğünde yayılış gösteren saf karaçam meşcerelerinin konumsal dağılımı ve örneklenen alanlar

2.1.2 Örnek alanların seçimi ve yapılan ölçümler


Bu çalışmada değişik bonitet, sıklık ve yaş sınıflarını temsil edecek şekilde örnekleme yapılmış ve dairesel bir örnekleme şekli benimsenmiştir. Her bir örnek alanda, alanın kapalılık durumuna göre örnek alan büyüklüğü belirlenmiştir. Örnek alandaki ağaçların toprağı örtme derecesi %71'den büyük olduğunda, %41 ile 70 arasında olduğunda ve %11 ile 40 arasında olduğunda sırasıyla örnek alan büyüklükleri 400 m², 600 m² ve 800 m² olarak belirlenmiştir. Her bir örnek alanda;

- Göğüs yüksekliği çapı 4 cm'den büyük tüm ağaçların göğüs yüksekliği çapları ve farklı çap sınıflarından olmak üzere 10 ağaçta dip kütük çapları ölçülmüştür. 0-20 yaş aralığındaki genç meşcerelerde özel bir örnekleme yapılmış ve göğüs çapı 4 cm'den küçük ağaçlar da örneklenmiştir.
- Hektarda yüz ağaç yöntemine göre en boylu ağaçlarda yaş ve üst boy ölçümü yapılmıştır.
- Örnek alanın orta çap değerine eşit veya yakın göğüs yüksekliği çapına sahip 4-5 ağaçta yaş ölçümü yapılmıştır.
- Farklı çap sınıflarından olmak üzere 10-15 ağaçta kabuk kalınlığı, son 5 ve 10 yıllık halka kalınlıkları ölçülmüştür.
- Farklı çap basamakları dikkate alınarak en az 10 ağaçta boy ölçümü yapılmıştır.
- Boyları ölçülen ağaçların tepe başlangıç yükseklikleri ve tepe çapları ölçülmüştür.


Envanter çalışmalarının yapıldığı 180 örnek alanın yükselti, eğim ve bakı gruplarına göre dağılımı sırasıyla Şekil 2.2, Şekil 2.3 ve Şekil 2.4'te verilmiştir.



Şekil 2.2 Örnek alanların yükselti gruplarına göre dağılımı



Şekil 2.3 Örnek alanların eğim gruplarına göre dağılımı



Şekil 2.4 Örnek alanların bakı gruplarına göre dağılımı

Örnek alanların alındığı meşcere özelliklerine ilişkin tanımlayıcı istatistikler Çizelge 2.2’de verilmiştir.

Çizelge 2.2 Örnekleme yapılan meşcerelere ilişkin tanımlayıcı istatistikler

Meşcere Elemanları	Minimum	Maksimum	Ortalama	Standart Sapma
Meşcere Göğüs Yüzeyi (m ² /ha)	2	114	33	17
Meşcere Ağaç Sayısı (adet/ha)	138	6950	826	917
Meşcere Hacmi (m ³ /ha)	1	1584	375	283
Meşcere Orta Çapı (cm)	2	56	27	11
Meşcere Orta Boyu (m)	2	31	15	6
Bonitet Endeksi (m)	10	34	21	7
Sıklık Oranı [×]	1	17	6	3

[×]Curtis (1982)’ e göre hesaplanmış değerdir.

2.1.3 Örnek ağaçların seçimi ve yapılan ölçümler

Bu çalışmada ağaç hacimlerinin tahmini için sekiz Orman İşletme Müdürlüğünde yayılış gösteren saf karaçam alanları dikkate alınarak yapılan örneklemede toplam 300 adet ağaçta gövde boyunca 1 m ara ile göğüs çapı ölçümleri yapılmıştır. Örnek ağaçlar; 0-4 cm, 4,1-8, 8,1-12, 12,1-16, 16,1-20, 20,1-24, 24,1-28, 28,1-32, 32,1-36, 36,1-40, 40,1-44, 44,1-48, 48,1-52, 52,1-56 ve 56+ olmak üzere 15 çap sınıfı ve 0-3 m, 3,1-6, 6,1-9, 9,1-12, 12,1-15, 15,1-18, 18,1-21, 21,1-24, 24,1-27 ve 27+ olmak üzere 10 boy sınıfı dikkate alınarak belirlenmiş ve her çap ve boy basağından dengeli olacak şekilde 2'şer adet ağaçta ölçümler yapılmıştır. Ancak ince çaplı ve uzun boylu (4-8 cm çapında 24-28 metre boyunda) ya da kalın çaplı ve kısa boylu (56-64 cm çapında ve 4-8 metre boyunda) ağaçların, çalışma alanında bulunması çoğu durumda mümkün olmadığından, bu ölçüm sınıflarında yapılamayan ölçümler diğer ölçüm sınıflarına dengeli bir şekilde dağıtılmıştır. Örnek ağaçların değişik çap ve boy kademelerine mümkün olduğunca eşit ve dengeli bir biçimde dağıtılmasına ve hacim gelişimindeki değişkenliği iyi bir şekilde yansıtmasına özen gösterilmiştir. Örnek ağaçların bozuk tepeli, kusurlu (tepe kırıklığı, çatallık ya da kurumuş) olmamasına dikkat edilmiştir. Verilerin %85'i (n=254) ağaç hacim modellerinin oluşturulmasında, %15'i (n=46) geliştirilen hacim modellerinin uygulunun test edilmesi amacıyla bilinçli olarak iki gruba ayrılmıştır. Örneklenen ağaçlara ilişkin tanımlayıcı istatistik bilgileri Çizelge 2.3'te verilmektedir. Örneklemeye yapılan ağaçların çap ve boy basamaklarına dağılımı Çizelge 2.4'te verilmektedir.

Çizelge 2.3 Örneklenen ağaçlara ilişkin tanımlayıcı istatistikler


Değişken	Minimum	Maksimum	Ortalama	Standart Sapma
Boy (m)	1,5	31,0	18,4	5,87
Çap (cm)	0,8	86,0	25,6	13,15
Hacim (m ³)	0,001	4,349	0,925	0,944

Çizelge 2.4 Örneklenen ağaçların çap ve boy sınıflarına dağılımı

Çap Basamakları (cm)	Boy Basamakları (m)										Σ
	0-3,0	3,1-6,0	6,1-9,0	9,1-12,0	12,1-15,0	15,1-18,0	18,1-21,0	21,1-24,0	24,1-27,0	>27	
0-4	3(2)	2									5(2)
4,1-8,0		3(3)	3								6(3)
8,1-12,0			7(3)	7(2)	1						15(5)
12,1-16,0			6	8(3)	5						19(3)
16,1-20,0			1	8(3)	8(1)	4					21(4)
20,1-24,0				12	4(2)	9					25(2)
24,1-28,0				6(1)	6(1)	15	1(1)				28(3)
28,1-32,0				4(1)	3	9(2)	6(1)				22(4)
32,1-36,0				1(1)	1(1)	2	7	4(1)			15(3)
36,1-40,0				1	3(1)	5(1)	9(1)	6	1		25(3)
40,1-44,0				1	1	2	2	6(1)	7(1)	1(1)	20(3)
44,1-48,0					1	1	2(1)	2(1)	9	2	17(2)
48,1-52,0					2		2(1)	1(1)	4	2	11(2)
52,1-56,0					1	2(1)	1(1)	1	1(1)	2(1)	8(4)
>56					2	4(2)	4	4	1(1)	2	17(3)
Σ	3(2)	5(3)	17(3)	48(11)	38(6)	53(6)	34(6)	24(4)	23(3)	9(2)	254(46)

Not: Parantez () içerisindeki rakamlar, modellerinin uygululuğunun test edilmesinde kullanılan verileri temsil etmektedir.

Gövde çapı denkleminin oluşturulmasında ve uygunluğunun test edilmesinde kullanılan veriler için oransal çap değerlerine karşı oransal boy değerlerinin grafiği Şekil 2.5'te verilmektedir.



Şekil 2.5 Modellerin oluşturulmasında (a) ve uygunluğunun test edilmesinde (b) kullanılan verilerin oransal çap değerlerinin oransal boy değerlerine göre dağılımı

2.2 Yöntem

2.2.1 Gövde çapı modelleri

Bu çalışmada hem regresyon hem de yapay sinir ağları yöntemleriyle gövde çapları ve ağaç hacim tahminleri elde edilmiştir. Gövde çapı tahminlerinde parçalı gövde çapı (segmented taper model, PGÇM) ve Bayesçi yapay sinir ağı (Bayesian neural network, BYSAM) modelleri kullanılmıştır. PGÇM’nde, bir ağacın gövdesinin üç geometrik şekle bölünebileceği varsayılmaktadır. Ağaçların tepe bölümünün koni, gövde bölümünün parabolit ve dip kütük bölümünün nayloid şekline benzediği kabul edilmektedir. Bu modeller, ağaçların her bir bölümü için ayrı bir denklem içerdiklerinden dolayı gövde şekillerindeki değişkenliği iyi bir şekilde açıklayabilmektedirler. Bu çalışmada, Max and Burkhardt (1976), Parresol *et al.* (1987), Clark (1991) ve Fang *et al.* (2000) tarafından geliştirilen parçalı gövde çapı modelleri kullanılmıştır. Bu modellere ilişkin fonksiyonlar aşağıda verilmiştir.

Max and Burkhardt (1976) (PGÇM-1)

$$\left(\frac{d}{D}\right)^2 = b_1(q - 1) + b_2(q^2 - 1) + b_3(a_1 - q)^2 I_1 + b_4(a_2 - q)^2 I_2 \quad (1)$$

$$q = \frac{h}{H} \quad I_i = \begin{cases} I_1 = 1 & \text{Eğer } q \leq a_1; 0 \\ I_2 = 1 & \text{Eğer } q \leq a_2; 0 \end{cases} \quad (2)$$

Parresol *et al.* (1987) (PGÇM-2)

$$\left(\frac{d}{D}\right)^2 = z^2(b_1 - b_2 z) + (z - a_1)^2 [b_3 + b_4(z + 2a_1)] I \quad (3)$$

$$\{I = 1, \text{Eğer } z \geq a_1; 0\}$$

$$z = \frac{(H-h)}{H} \quad (4)$$

Clark (1991) (PGÇM-3)

$$d = \left\{ \begin{array}{l} I_S \left[D^2 \left(1 + \frac{(b_2+b_3/D^3)((1-h/H)^{b_1}-(1-1,30/H)^{b_1})}{1-(1-1,30/H)^{b_1}} \right) \right] + \\ I_B \left[D^2 - \frac{(D^2-F^2)((1-1,30/H)^{b_4}-(1-h/H)^{b_4})}{(1-1,30/H)^{b_4}-(1-5,30/H)^{b_4}} \right] + \\ I_T \left[F^2 \left(b_6 \left(\frac{h-5,30}{H-5,30} - 1 \right)^2 + I_M \left(\frac{1-b_6}{b_5^2} \right) \left(b_5 - \frac{h-5,30}{H-5,30} \right)^2 \right) \right] \end{array} \right\}^{0.5} \quad (5)$$

$$I_S = \{1, \text{ Eğer } h < 1,30; 0\} \quad (6)$$

$$I_B = \{1, \text{ Eğer } 1,30 \leq h < 5,30; 0\} \quad (7)$$

$$I_T = \{1, \text{ Eğer } h > 5,30; 0\} \quad (8)$$

$$I_M = \{1, \text{ Eğer } h < (5,30 + b_3(H-5,30)); 0\} \quad (9)$$

Fang *et al.* (2000) (PGÇM-4)

$$d = c_1 \sqrt{H^{(k-b_1)/b_1} (1-q)^{(k-\beta)/\beta} a_1^{I_1+I_2} a_2^{I_2}} \quad (10)$$

$$\begin{cases} I_1 = 1, \text{ Eğer } p_1 \leq q \leq p_2; 0 \\ I_2 = 1, \text{ Eğer } p_2 \leq q \leq 1; 0 \end{cases}$$

$$\beta = b_1^{1-(I_1+I_2)} b_2^{I_1} b_3^{I_2} \quad (11)$$

$$a_1 = (1-b_4)^{\frac{(b_2-b_1)k}{b_1 b_2}} \quad (12)$$

$$a_2 = (1-b_5)^{\frac{(b_3-b_2)k}{b_2 b_3}} \quad (13)$$

$$r_0 = (1-h_{st}/H)^{k/b_1} \quad (14)$$

$$r_1 = (1-b_4)^{k/b_1} \quad (15)$$

$$r_2 = (1-b_5)^{k/b_2} \quad (16)$$

$$c_1 = \sqrt{\frac{b_6 D^{b_7} H^{b_8-k/b_1}}{b_1(r_0-r_1) + b_2(r_1-a_1 r_2) + b_3 a_1 r_2}} \quad (17)$$

$$V = b_6 D^{b_7} H^{b_8} \quad (18)$$

Bu denklemlerde;

d: Toprak seviyesinden belirli yükseklikteki gövde çapını,
D: Göğüs yüksekliği çapını,
h: Seksiyonlardaki çap değerlerine karşılık gelen boy değerlerini,
H: Toplam ağaç boyunu,
 h_{st} : Dip kütük boyu olan 0,3 metreyi,
V: Toplam kabuklu gövde hacmini,
 a_{1-2} , b_{1-8} , c_0 , p_1 , p_2 : Tahmin edilecek regresyon katsayılarını,
k: $\pi/40000$ değerini,
q: h/H değerini,
F: 5,30 m' deki ölçülen gövde çapı değerini temsil etmektedir.

Gövde çapı modellerinin parametre tahminleri SAS yazılımının PROC MODEL prosedürü ile elde edilmiştir. Gövde çapı verileri ardışık ölçümler ile toplandığından dolayı verilerin birbirini takip eden değerleri arasında doğrusal bir ilişki oluşmaktadır. Parametrik regresyon yöntemlerinin önemli varsayımlarından birisi verilerin birbirinden bağımsız olmasıdır. Ancak, dendrometri ya da hasılat araştırmalarında bu durum mümkün olmamakta ve verilerin birbirinden bağımsız olması ilkesi ihlal edilmektedir. Dolayısıyla özellikle model hata dağılımlarında değişen varyans problemi ortaya çıkmakta ve sonuçların güvenilirliği şüpheli olmaktadır. Otokorelasyon olarak isimlendirilen bu problemin tahminler üzerindeki etkisini azaltmak için karışık etkili modelleme ve otoregresif modelleme teknikleri önerilmektedir (Trincado *et al.* 2007, Xu *et al.* 2014). Bu çalışmada, otoregresif modelleme teknikleri kullanılarak otokorelasyon probleminin çözülmesi amaçlanmıştır.

2.2.1.1 Otoresif modelleme

Gövde çapı tahminlerinde söz konusu olabilecek otokorelasyon problemine bir çözüm olarak çeşitli derecelerde otoregresif modelleme yönteminin kullanımı önerilmektedir (Özçelik ve Karaer, 2016, Poudel *et al.*, 2018). Bu çalışmada en başarılı gövde çapı modelinin parametrelerini yeniden tahmin etmek için farklı derecelerdeki (1., 2. ve 3.

derece) sürekli otoregresif (CAR (p)) ve hareketli ortalama (ARMA (p, q)) otoregresif hata yapısı modellemeye dahil edilmiştir. Bu konuda yapılan çalışmalarda genellikle sürekli otoregresif hata yapıları kullanılmaktadır (Alkan ve Özçelik 2020). Ancak, bu çalışmada her bir ağacın gövde çapları eşit aralıklarla ölçüldüğünden (0,3, 1,3, 3,3 ...) hareketli ortalama hata yapısının da parametre tahmininde kullanılabilmesine imkân doğmuştur. Oturegresif hata yapılarını içeren en başarılı gövde çapı modelinin parametreleri SAS istatistik paket programındaki PROC MODEL prosedürü kullanılarak tahmin edilmiştir.

Bu çalışmada otokorelasyon probleminin giderilip giderilmediği Durbin-Watson (DW) istatistiği ile test edilmiştir. DW değeri 0 ile 4 arasında değer almakta olup 2' ye yakın olması otokorelasyon sorunun olmadığını göstermektedir. DW test istatistiğine ilişkin eşitlik aşağıda verilmektedir.

$$d = \frac{\sum_{i=2}^n (e_i - e_{i-1})^2}{\sum_{i=2}^n e_i^2} \quad (19)$$

Bu eşitlikte; e hataları, e_{i-1} gecikmeli hataları, n veri sayısını ifade etmektedir.

Ayrıca olası otokorelasyon varlığının denetlenmesi amacıyla gecikmeli model hata dağılımları da analiz edilmiştir. Gecikmeli hata grafiklerinde, hataların x ve y ekseninin (0, 0) noktasında toplanması durumunda, otokorelasyon probleminin kullanılan tahmin yöntemi ile kontrol altına alındığı sonucuna varılabilmektedir.

2.2.1.2 Bayesçi yapay sinir ağları

Bu çalışmada MATLAB yazılımı kullanılarak ileri beslemeli geri yayımlı BYSAM tasarlanmıştır. Dendrometri ve hasılat araştırmalarında konveks olmayan sonuçlar üretecek ağ yapılarının tasarlanması büyük bir öneme sahiptir. Çünkü, ağaçların ve meşcerelerin gelişim seyri S eğrisine benzemektedir. Diğer bir ifade ile ağaçların ve meşcerelerin gelişim seyri, gençlik döneminde hızla artan ancak olgunluğa doğru yavaşlayan ve belirli bir dönemde asimptota ulaşan bir yapıyı takip etmektedir. Başka

bir açıdan bakıldığında, göğüs çapı ve ağaç hacmi arasındaki fonksiyonel ilişki de S eğrisi biçimindedir. Çap değeri arttıkça ağaç hacminin artması ve belirli bir değerde asimptota ulaşması beklenir. Ayrıca, tasarlanan ağ yapısının güçlü asimptot özelliği yanında, çoklu polimorfizm özelliğine de sahip olması beklenmektedir. Çünkü, meşcere gelişimleri yetiştirme ortamı verim gücü ve meşcere sıklığına göre değişik formlarda olmaktadır. Ancak yapay sinir ağ modellerinde aşırı uyum probleminden dolayı eğitim veri setinde iyi sonuçlar üreten ağ, test veri setinde kötü performans gösterebilmektedir. Diğer bir ifade ile bu durum ağın sonuçları genelleştirme kabiliyeti kazanamaması olarak belirtilmektedir. Aşırı uyum problemini aşmak için;


- Öncelikle yapılması gereken test veri setinin iyi bir şekilde seçilmesidir. Test veri seti, eğitim veri setinin değişkenliğini temsil edebilecek düzeyde olmalıdır. Bu seçilen veri seti ağın eğitimi sırasında, ağa gösterilmemelidir. Ağ eğitimi öncesi önemli olan bir diğer husus eğitim veri seti olarak ayrılan verilerin ağ eğitimi sırasında eğitim, test ve validasyon olarak nasıl ayrılacağına belirlenmesidir. Bu amaçla çeşitli veri ayırma yöntemleri mevcuttur. Hangi veri ayırma yönteminin daha iyi olduğu deneme-yanılma yolu ve uzman görüşü ile belirlenmektedir.
- Tasarlanan ağın birçok kez yeniden eğitilmesi (bir anlamda yeniden örnekleme) ağın öğrenme kabiliyetini artırmaktadır. Çünkü her eğitim aşamasında eğitim veri seti farklı şekilde gruplara ayrıldığından dolayı ağ, model hata değerini minimize edecek şekilde girdi değişkenlerinin ağırlıklarını değiştirmektedir. Örneğin, 5 nöronlu bir ağın 10 kez eğitilmesi. Ağın ortalama performansı, bireysel ağ performanslarının çoğundan düşük olduğunda ağın genelleştirme kabiliyetinin iyi olduğu söylenilebilmektedir.
- Birden fazla yapay sinir ağ modeli eğitmek, diğer bir ifade ile farklı nöron sayılarının ağ üzerindeki performansını test etmek karar verme sürecinde etkilidir.


- Ağın erken durdurma yapısına sahip olması ağın genelleştirme yeteneğini artırmaktadır. Erken durdurma, ağ eğitimi sırasında validasyon veri setindeki hata miktarı artmaya başladığında ağ eğitiminin durdurulması anlamına gelmektedir. Bu durumda, girdi değişkenlerinin ağırlıkları ve bunların hataları yeniden değiştirilecek şekilde ağ eğitim süreci devam ettirilmeli ve ağın hata değişim seyri takip edilmelidir.
- Ağın genelleştirme kabiliyetini etkileyen diğer bir husus regülerizasyon parametresidir. Bu parametre ağın genelleştirme hatasını minimize edecek şekilde ayarlanmalıdır. İyi bir regülerizasyon değeri belirlenirse ağ eğitim sürecinde bu parametreyi dikkate alarak aşırı uyumdan kaçınılabılır ve daha genel sonuçlar üretilebilir.
- Ağın genelleştirme kabiliyetini etkileyen bir diğer husus ağ eğitimi için belirlenen eğitim fonksiyonudur. Çünkü, seçilen eğitim fonksiyonuna göre parametre uyarlamaları değişmektedir. Bu çalışmada Bayesçi ağ eğitimi kullanılmıştır. Çünkü Bayesçi ağ yapıları erken durdurma ve regülerizasyon parametresi ile daha iyi uyum içinde çalışır. Bu ağ yapısında verilerin $[-1 \ 1]$ aralığında olacak şekilde düzenlenmesi ağın genelleştirme yeteneğini artırmaktadır.
- Ağ performansını etkileyen bir diğer husus katmanlar arası veri transferini sağlayan aktivasyon fonksiyonun seçimidir. Genellikle bir kırılma ve asimptot değerine sahip biyolojik yapıları iyi temsil edebilen lojistik sigmoid ve hiperbolik tanjant sigmoid fonksiyonları kullanılmaktadır. Bu çalışmada veriler $[-1 \ 1]$ aralığında düzenlendiğinden hiperbolik tanjant transfer fonksiyonu kullanılmıştır.

$$y = 2/(1 + \exp(-2n)) - 1 \quad (20)$$

- Ayrıca, lojistik sigmoid fonksiyonu, hiperbolik tanjant fonksiyonu ile kıyaslandığında veri aralığı daha dar ($[0 \ 1]$) olup daha erken asimptota ulaşmaktadır. Diğer bir ifade ile lojistik sigmoid fonksiyonunu içeren bir yapay sinir ağı modeli x-ekseninin pozitif tanımlı bölgesinde küçük değerlerde asimptota ulaştığından bağımsız veri setindeki yani x eksenindeki değişime çok az tepki verebilmekte ve dolayısıyla yapay sinir modelinde öğrenme kaybı gerçekleşmektedir.
- Ağ performansını etkileyen bir diğer husus öğrenme oranı ve momentum değeridir. Ağı öğrenme hızı momentum katsayısı ile belirlenir. Momentum değeri genellikle 0 ile 1 arasında seçilmektedir. Öğrenme oranı ağı eğitim sürecinde önemli parametrelerden bir diğeridir. Küçük öğrenme oranı ağı verilere aşırı uyum sağlamasına sebep olurken; büyük öğrenme oranı az öğrenmeye dolayısıyla büyük hatalara sebep olabilmektedir. Bu nedenlerle, öğrenme oranının ve momentum katsayısının eş zamanlı değerlendirilerek belirlenmesi ağ performansının iyileştirilmesi bakımından önemlidir.

Bu çalışmada hazır paket programları kullanmak yerine yukarıda belirtilen kriterleri yerine getirmek amacıyla manuel olarak MATLAB yazılım dilinde kodlanmış bir yapay sinir ağı tasarımı gerçekleştirilmiştir (EK 7). İki katmanlı ve iki nöronlu bir yapay sinir ağı yapısı Şekil 2.6'da verilmektedir. Aşağıda verilen örnek yapay sinir ağı girdi-gizli katman arası 4 ağırlık parametresi, gizli-çıkı katman arası 2 ağırlık parametresi, 2 nöron ve 1 çıkı katmanının hata parametresi olmak üzere toplam 9 parametreden oluşmaktadır.





Şekil 2.6 İki katmanlı ve iki nöronlu örnek yapay sinir ağı modeli

2.2.1.3 Gövde çapı modellerinin karşılaştırılması

Bu çalışmada regresyon yöntemleri ve BYSAM kullanılarak gövde çapı tahminleri elde edilmiştir. Regresyon yöntemlerinde olası otokorelasyon etkisini minimize etmek için CAR (p) ve ARMA (p, q) otoregresif parametreler kullanılmıştır. Parametreleri anlamlı bulunan regresyon modelleri arasında en başarılı olanın BYSAM ile karşılaştırılmasında aşağıdaki model değerlendirme ölçütlerinden yararlanılmıştır.

Karesel Ortalama
Hatanın Karekökü

$$HKOK = \sqrt{\frac{\sum_{i=1}^n (d_i - \hat{d}_i)^2}{n - p}} \quad (21)$$

Düzeltilmiş
Belirtme Katsayısı

$$R_{düz.}^2 = 1 - \left(1 - \frac{\sum_{i=1}^n (d_i - \hat{d}_i)^2}{\sum_{i=1}^n (d_i - \bar{d}_i)^2} \right) \left(\frac{n - 1}{n - p - 1} \right) \quad (22)$$

Akaike Bilgi
Kriteri

$$AIC = n \log \left(\frac{\sum_{i=1}^n (d_i - \hat{d}_i)^2}{n} \right) + 2p \quad (23)$$

Bu eşitliklerde; d_i , belirli bir h yüksekliğinde ölçülen çap değerini, $\hat{d}_i$, tahmin edilen çap değerini, $\bar{d}_i$, ölçülen gövde çaplarının ortalamasını, n veri sayısını, p modeldeki parametre sayısını ifade etmektedir.

2.2.2 Ağaç hacim modelleri

2.2.2.1 Tek ve çift girişli ağaç hacim modelleri

Ağaç hacim denklemleri; tek, çift ve çok girişli olmak üzere üç sınıfa ayrılmaktadır. Tek girişli ağaç hacim modellerinde göğüs yüksekliği çapı ve göğüs yüksekliği çapından türetilen bağımsız değişkenler ($\ln d$, $1/d$ gibi) kullanılarak fonksiyonel ilişkiler belirlenmektedir. Çift girişli ağaç hacim modellerinde göğüs yüksekliği çapı, toplam ağaç boyu ve bu değişkenlerden türetilen çeşitli bağımsız değişkenler ($d \times h$, $d^2 \times h$, $h^2 \times d$ gibi) kullanılarak fonksiyonel ilişkiler belirlenmektedir. Çok girişli hacim modellerinde ise çift girişli modellerde kullanılan bağımsız değişkenlere ek olarak toplam ağaç boyunun belirli bir oranına (örneğin %30) karşılık gelen yükseklikteki gövde çapı ya da yerden 7 metre yüksekliğindeki gövde çapı gibi üç ya da daha fazla bağımsız değişken bulunmaktadır. Ağaç hacim denklemlerinin geliştirilmesinin temel amacı dikili halde ticari ağaç hacimlerinin hesaplanmasıdır (Kapucu vd. 2002). Bu çalışmada pratik olması yanında güvenilir olan tek ve çift girişli ağaç hacim modelleri geliştirilmiştir. Bu amaçla, literatürde sıklıkla kullanılan aritmetik denklemler kullanılarak ağaçların dendrometrik özellikleri ile ağaç hacimleri arasındaki fonksiyonel ilişkiler belirlenmiştir. Ağaç hacim tablolarının oluşturulması sürecinde, ilk olarak aşağıdaki eşitlikler kullanılarak 1m ara ile gövde çapı ölçümleri yapılan her bir ağacın toplam hacmi belirlenmiştir.

$$\text{Gövdenin dip kütük hacmi} \quad V_{dip} = \frac{\pi}{4} \times d_{0,3}^2 \times 0,3 \quad (24)$$

$$\text{Gövdenin uç parça hacmi} \quad V_{uç} = \frac{1}{3} \frac{\pi}{4} d_{uç}^2 h_{uç} \quad (25)$$

$$\text{Gövde seksiyon hacmi} \quad V_{seksiyon} = \frac{\pi}{4} (d_0^2 + d_n^2) \frac{l}{2} \quad (26)$$

Bu eşitliklerde; d_0 ve d_n : sırasıyla gövde seksiyon kesitinin dip ve uç çapını, $d_{uç}$ ve $h_{uç}$: gövdenin uç parçasına ilişkin çapını ve boyunu, $d_{0,3}$: dip kütük çapını, l : seksiyon uzunluğunu temsil etmektedir.

Literatüründe tek ve çift girişli pek çok hacim fonksiyonu bulunmaktadır. Bu çalışmada, 4 adet tek girişli ve 9 adet çift girişli ağaç hacim fonksiyonu kullanılmıştır (Mısır 2003). Bu denklemlere ilişkin katsayılar, katsayıların önemlilik düzeyleri ve diğer istatistiklerin hesaplanmasında SPSS paket programı kullanılmıştır.

Tek girişli ağaç hacim modelleri;

$$AHD1, V = b_0 + b_1 d^2 \quad (27)$$

$$AHD2, V = b_0 + b_1 d + b_2 d^2 \quad (28)$$

$$AHD3, V = b_0 + b_1 d^2 + b_2 / d \quad (29)$$

$$AHD4, V = b_0 \cdot d^{b_1} \quad (30)$$

Çift girişli ağaç hacim modelleri;

$$AHD5, V = b_0 + b_1 \cdot d^2 h \quad (31)$$

$$AHD6, V = b_0 + b_1 d^2 + b_2 h + b_3 d^2 h \quad (32)$$

$$AHD7, V = b_0 + b_1 d + b_2 d^2 + (b_3 + b_4 d + b_5 d^2) h \quad (33)$$

$$AHD8, V = b_0 + b_1 d + b_2 d^2 + (b_3 d + b_4 d^2) h \quad (34)$$

$$AHD9, V = b_0 + b_1 d^2 + b_2 h^2 + b_3 d h^2 + b_4 d^2 h \quad (35)$$

$$AHD10, V = b_0 + b_1 d + b_2 d^2 + b_3 h + b_4 d h + b_5 d^2 h \quad (36)$$

$$AHD11, V = b_0 + b_1 d + b_2 d^2 + b_3 d h + b_4 d^2 h \quad (37)$$

$$AHD12, V = b_0 + b_1 d^2 + b_2 h^2 + b_3 d h^2 + b_4 d^2 h^2 \quad (38)$$

$$AHD13, V = b_0 + b_1 d h + b_2 d^2 h \quad (39)$$

Bu eşitliklerde;

AHD: Ağaç hacim denklemini,

V: Toplam gövde hacmini (m³)

d: Göğüs yüksekliği çapını (cm)

h: Ağaç boyunu (m)

b₀₋₅: Regresyon katsayılarını temsil etmektedir.

2.2.2.2 Parçalı gövde çapı modeli kullanılarak geliştirilen ağaç hacim modeli

Bu çalışmada kullanılan gövde çapı modelleri ticari ve toplam gövde hacmini hesaplayabilecek formlara sahiptir. Bu nedenle, uyumlu gövde çapı modeli olarak da adlandırılmaktadırlar. Bu çalışmada görünüşte ilişkisiz regresyon tekniği kullanılarak gövde çapı ve gövde hacim tahminleri eş zamanlı elde edilmiştir. Model performans değerlendirme ölçütlerine göre en başarılı olan uyumlu gövde çapı modeli kullanılarak çift girişli hacim denklemi elde edilmiştir. DW değeri hem gövde çapı modeli hem de gövde hacim modeli için ayrı ayrı elde edilmiştir. Bu amaçla SAS yazılımının PROC MODEL prosedürü kullanmıştır.

2.2.2.3 Bayesçi ağ yapıları ile geliştirilen tek ve çift girişli ağaç hacim modeli

Ayrıntılı bilgiler gövde çapı modelleri başlığı altında verilmiştir. İlgili başlık altında ifade edildiği üzere ağaç hacim tahminleri için de uygun BYSAM geliştirilmiştir.

2.2.2.4 Ağaç hacim modellerinin karşılaştırılması

Bu çalışmada kullanılan değişik modelleme yaklaşımları karşılaştırılmadan önce, tek ve çift girişli regresyon denklemleri kendi içlerinde karşılaştırılmış ve en başarılı olanlar belirlenmiştir. Daha sonra en başarılı olarak belirlenen çift girişli regresyon denklemi, uyumlu gövde çapı modelinden üretilen çift girişli model ve Bayesçi ağ yapıları ile geliştirilen çift girişli yapay sinir ağı modeli karşılaştırılmıştır. Ağaç hacim modellerinin karşılaştırılmasında aşağıda verilen istatistiksel model performans ölçütleri kullanılmıştır.

Düzeltilmiş Belirtme
Katsayısı

$$R_{düz}^2 = 1 - \left(1 - \frac{\sum_{i=1}^n (V_i - \hat{V}_i)^2}{\sum_{i=1}^n (V_i - \bar{V}_i)^2} \right) \left(\frac{n-1}{n-p-1} \right) \quad (40)$$

Ortalama Hata

$$\bar{D} = \frac{(\sum (V_i - \hat{V}_i))}{N} \quad (41)$$

$$\text{Ortalama Mutlak Hata} \quad |\bar{D}| = \frac{(\sum |V_i - \hat{V}_i|)}{N} \quad (42)$$

$$\text{Toplam Hata Yüzdesi} \quad THY = 100 \frac{\sum_{i=1}^n V_i - \sum_{i=1}^n \hat{V}_i}{\sum_{i=1}^n V_i} \quad (43)$$

$$\text{Ortalama Mutlak Hata Yüzdesi} \quad OMHY = 100 \frac{\sum_{i=1}^n |V_i - \hat{V}_i|}{\sum_{i=1}^n V_i} \quad (44)$$

Bu eşitliklerde; n veri sayısını, p parametre sayısını, $\hat{V}_i$ tahmin edilen hacim değerini, V_i ölçülen hacim değerini, V_{ort} ölçülen ortalama ağaç hacmi değerlerini göstermektedir.

2.2.3 Gövde çapı ve ağaç hacim modellerinin denetlenmesi

Hem gövde çapı hem de ağaç hacim tahminlerinde en başarılı olarak seçilen modellerin verilerin toplandığı Ankara Orman Bölge Müdürlüğü sınırlarında yayılış gösteren saf karaçam meşcerelerine uygunluğu denklik testi (equivalence test) ile denetlenmiştir (Diamantopoulou and Özçelik 2012). Bu amaçla test veri seti olarak ayrılan 46 adet ağaç verisi kullanılarak geliştirilen modellere ilişkin tahminlerinin, belirli güven aralıklarında gerçek verilerle ne kadar benzeştiği ortaya konulmuştur. Bu yöntemde, gerçek ve tahmin değerleri arasında kurulan basit doğrusal modelin ($b_0 + b_1X$) sabit katsayısı (b_0) ve eğim parametresi (b_1) üzerinden modellerin belirlenen önem düzeyinde gerçek verilerle ne kadar benzeş olduğu belirlenmekte ve sabit katsayının sıfır ve eğim parametresinin 1 olması beklenmektedir. Söz konusu benzerlik oranı, gözlemlerin ortalaması ve benzeşmezlik yüzdesi ile test edilir. Söz konusu testin; Sıfır hipotezi (H_0): İki grup ortalaması arasındaki fark hesaplanan eş değerlik aralığı dışında; alternatif hipotezi (H_A): İki grup ortalaması arasındaki fark hesaplanan eş değerlik aralığı içinde şeklindedir. Belirlenen benzeşmezlik oranında hesaplanan test değerinin 0,05'ten küçük olması beklenmektedir. Diğer bir ifade ile H_0 hipotezinin reddedilmesi beklenmektedir.

2.2.4 Meşcere büyüme modelleri

2.2.4.1 Meşcere elemanlarının hesaplanması

Meşcere yaşı

Eşit yaşlı meşcerelerde, meşcere yaşının belirlenmesi için meşcere orta çapı dikkate alınmaktadır. Göğüs yüksekliği çapı meşcere orta çapına eşit ya da yakın olan 5-6 adet ağaçta yaş ölçümü yapıp bunların ortalaması alınarak meşcere yaşı hesaplanmaktadır (Fırat 1972).

$$T_i = \frac{t_1 + t_2 + \dots + t_n}{n} \quad (45)$$

Bu eşitlikte; T_i , i. Örnek alanın yaşını; t , örnek ağacın yaşını; n , yaş ölçümü yapılan ağaç sayısını ifade etmektedir.

Meşcere orta çapı

Meşcere orta çapı, merkezi orta ağacının çapı olarak da bilinen karesel ortalama çap değeri kullanılarak hesaplanmıştır (Fırat 1972).

$$d_g = \sqrt{\frac{d_1^2 + d_2^2 + \dots + d_n^2}{n}} \quad (46)$$

Bu eşitlikte; d_g , bir örnek alan için orta çap değerini; d_i , göğüs çapı değerini ve n veri sayısını ifade etmektedir.

Meşcere boylanma eğrisi

Meşcere boylanma eğrilerinin oluşturulmasında literatürde sıklıkla kullanılan genelleştirilmiş çap-boy modellerinden (ÇBM1-6) ve bayesçi yapay sinir ağı yapılarından (ÇBM7) yararlanılmıştır. Geliştirilen modellerin temsil kabiliyetini artırmak için aşağıda verilen modellerden üst boy değişkenini içerenlerde üst boy yerine

bonitet endeks değeri kullanılmıştır. En başarılı çap-boy modelinin belirlenmesinde Denklem (21-23) kullanılmıştır.

$$\text{ÇBM1 Cañadas et al. (1999)} \quad h = 1,3 + (be - 1,3) \left(\frac{1 - e^{-b_1 d}}{1 - e^{-b_1 d_{mak}}} \right) \quad (47)$$

$$\text{ÇBM2 Hui and von Gadow (1993)} \quad h = 1,3 + b_1 be^{b_2} d^{b_3 be^{b_4}} \quad (48)$$

$$\text{ÇBM3 Soares and Tomé (2002)} \quad h = be(b_1 + (b_2 + b_3 be + b_4 dg) \times e^{\frac{b_5 d}{be}}) \quad (49)$$

$$\text{ÇBM4 Sharma and Parton (2007)} \quad h = 1,3 + (b_1 be^{b_2}) \left(1 - e^{-b_3 (N/G)^{b_4} d} \right)^{b_5} \quad (50)$$

$$\text{ÇBM5 Adame et al. (2008b)} \quad h = 1,3 + ((b_1 + b_2 G + b_3 be) e^{b_4/d}) \quad (51)$$

$$\text{ÇBM6 Castedo et al. (2006)} \quad h = (1,3^{b_1} + (be^{b_1} - 1,3^{b_1}) \left(\frac{1 - e^{-b_2 d}}{1 - e^{-b_2 d_{mak}}} \right)^{1/b_1}) \quad (52)$$

Bu eşitliklerde; be, bonitet endeksi (m); d, göğüs yüksekliği çapı (cm); dg, orta çap (cm); d_{mak}, maksimum çap; N, ağaç sayısı (adet/ha); G, göğüs yüzeyi (m²/ha); b₀₋₅, regresyon katsayılarını ifade etmektedir.

Meşcere orta boyu

Meşcere orta boyu, meşcere boylanma eğrisinde göğüs yüzeyi orta ağacının çapına karşılık gelen değer olarak hesaplanmıştır (Fırat 1972).

$$hg = f(dg) \quad (53)$$

Meşcere ağaç sayısı

Hektardaki ağaç sayısı aşağıdaki eşitlikle hesaplanmıştır.

$$N = \frac{10000}{\text{ÖAB}} n \quad (54)$$

Bu eşitlikte; $\ddot{O}AB$, örnek alan büyüklüğünü; n , örnek alandaki ağaç sayısını göstermektedir.

Meşcere göğüs yüzeyi

Meşcere göğüs yüzeyi örnek alanda ölçülen ağaçların göğüs yüzeyleri toplamının hektara çevrilmesiyle hesaplanmıştır.

$$G = \frac{10000}{\ddot{O}AB} \times \left(\frac{\pi}{4} \sum_{i=1}^n d_i^2 \right) \quad (55)$$

Bu eşitlikte; n , örnek alandaki ölçülen ağaç sayısını; d_i , örnek alanda ölçülen çapın metre cinsinden değerini ifade etmektedir.

Meşcere hacmi

Ağaç hacim modelleri başlığı altında ifade edilen modeller arasından en başarılı olan model ile örnek alandaki ağaçların hacimleri hesaplanmış, hesaplanan hacim değerleri toplanıp hektara çevrilerek meşcere hacmi elde edilmiştir.

$$V = \frac{10000}{\ddot{O}AB} \left(\sum_{i=1}^n v_i^2 \right) \quad (56)$$

Bu eşitlikte; v_i , i . örnek ağacın hacmini ifade etmektedir. i . ağacın hacmi çalışma kapsamında geliştirilen en başarılı çift girişli hacim modeli ile hesaplanmıştır.

Meşcere sıklığı

Bu çalışmada, hem Curtis (1982) hem de Reineke (1933) tarafından geliştirilen meşcere sıklık değerleri hesaplanmıştır. Meşcere modelleri oluşturma sürecinde daha başarılı sonuçlar elde edilen sıklık indeksi ile büyüme modelleri geliştirilmiştir (Kapucu vd. 2002).

$$\text{Curtis Oransal Meşcere Sıklığı} = \frac{G}{\sqrt{dg}} \quad (57)$$

$$\text{Reineke Sıklık İndeksi } N = b_1 dg^{b_2} \quad (58)$$

Reineke sıklık ölçütünün b_1 ve b_2 parametreleri Kalıpsız (1963) tarafından hazırlanan müdahale görmemiş saf karaçam meşcereleri için hazırlanan normal hasılat tablosundaki meşcere ağaç sayısı ve meşcere orta çapı değerleri kullanılarak elde edilmiştir.

Meşcere üst boyu

Bu çalışmada Ankara Orman Bölge Müdürlüğü sınırları içerisinde I. Bonitet saf karaçam meşcerelerinin yeterli miktarda olmaması nedeniyle bonitet endeks tablosu geliştirilememiştir. Bu nedenle Kalıpsız (1963) tarafından üretilen bonitet endeks tablosu ile örnek alanların bonitet endeks değeri belirlenmiştir.

2.2.4.2 Meşcere büyüme modellerinin geliştirilmesi

Birçok doğa biliminde olduğu gibi, orman hasılatı ve dendrometri konularında da doğrusal olmayan modellere ihtiyaç duyulmaktadır. Çünkü doğrusal modeller, genellikle büyümenin sabit bir eğimi takip ettiğini varsaymaktadır. Diğer bir ifade ile, iyi yetişme ortamı koşullarında bulunan meşcerelerin gelişimini gösteren eğrinin eğimi ile kötü yetişme ortamı koşullarında bulunan meşcerelerin gelişimini gösteren eğrinin eğiminin birbirinden farklı olması beklenmektedir. Ayrıca, özellikle büyümenin hızlı seyrettiği gençlik dönemlerinde meydana gelen hızlı değişkenliği doğrusal modeller yeterince açıklayamamaktadır.

Orman hasılatı ve dendrometri arařtırmaları özelinde, meřcerelerin geliřimi üzerine çok sayıda faktörün etkisi bulunmaktadır. Bu nedenle, örneğın deęiřik yař, sıklık ve bonitet deęerinde farklı řekillerde büyüme gerçekteřtiğinden geliřtirilen bir büyüme modelinden söz konusu deęiřkenlikleri göstermesi beklenmektedir. Doğrusal olmayan modeller bir kırılma noktası ve asimptot özellięi taşıyan söz konusu bu yapıları iyi bir řekilde temsil edebilmektedir. Çünkü doğrusal olmayan büyüme modelleri genellikle sigmoid bir yapıdadır.

Bu çalıřmada saf karaçam meřcereleri için sıklığa baęlı hasılat tablolarının oluřturulması amaçlanmaktadır. Bu nedenle meřcere elemanları sıklık, yař ve bonitet deęiřkenlerinin bir fonksiyonu olarak tahmin edilmesi amaçlanmıřtır. Bu amaçla, Gompertz (1825) büyüme modeli bonitet, yař ve sıklık deęiřkenini içerecek řekilde yeniden düzenlenmiřtir (Archontoulis and Miguez, 2015). Çünkü, meřcere yapıları (ör. bonitet ve sıklık) deęiřtikçe, model davranıřının deęiřmesi beklenmektedir (Yavuz vd. 2010). Doğrusal olmayan bir modelin yeniden düzenlenmesi konusu Archontoulis and Miguez (2013) tarafından detaylıca açıklanmıřtır. Literatürde farklı versiyonları bulunan Gompertz (1825) modeli, bu çalıřma kapsamında sıklık, bonitet ve meřcere yařı deęiřkenlerini içerek řekilde yeniden düzenlenmiřtir (Denklem 59-69).

Genel model formu ve parametre sayısı deęiřtiğinden dolayı, model bařlangıç deęerlerinin yeniden belirlenmesi gerekmektedir. Ancak, model parametre tahminlerinde karřılařılan en büyük güçlük parametre bařlangıç deęerlerinin iyi bir řekilde belirlenememesidir (Desta *et al.* 1999). Kötü belirlenmiř parametre bařlangıç deęerleri, modelin ıraksak çözüm sunmasına, dięer bir ifade ile, model hata kareler ortalamasının beklenen deęerden daha yüksek hesaplanmasına ve biyolojik açıdan anlamsız parametre deęerlerinin elde edilmesine sebep olmaktadır (Archontoulis and Miguez, 2015). Bu amaçla, bu çalıřmada R yazılım dilinde kodlanmıř bir çözücü uygulaması geliřtirilmiřtir (EK 7).

Meřcere orta çap modeli

(59)

$$\ln(dg) = b_1 \exp(-\exp((b_2 (1/t)))) \quad (60)$$

$$b_1 = a_1 + a_2 \ln(be) + a_3 \ln(sd) \quad (61)$$

$$b_2 = a_4 + a_5 \ln(be)$$

Meşcere orta boy modeli,

(62)

$$\ln(hg) = b_1 + b_2 \exp(-\exp(b_3 - b_4 b_3(1/t))) \quad (63)$$

$$b_3 = a_1(1/be) + a_2 \ln(sd)$$

Meşcere ağaç sayısı modeli,

(64)

$$\ln(N) = b_1 \exp(-\exp(b_2 - b_3 b_2(1/t))) \quad (65)$$

$$b_2 = a_1(1/be) + a_2(1/sd) + a_3 \ln(be) + a_4 \ln(sd)$$

Meşcere göğüs yüzeyi modeli,

(66)

$$\ln(G) = b_1 \exp(-\exp(b_2 - b_3 b_2(1/t))) \quad (67)$$

$$b_2 = a_1(1/be) + a_2(1/sd) + a_3(be)^2 + a_4(sd)^2$$

Meşcere hacim modeli,


(68)

$$\ln(V) = b_1 \exp(-\exp(b_2 - b_3 b_2(1/t))) \quad (69)$$

$$b_2 = a_1 \ln(be) + a_2(1/sd) + a_3(be)^2 + a_4(sd)^2$$

Bu eşitliklerde; be: bonitet endeksi, sd: sıklık oranı, t: meşcere yaşı ve b₁₋₆: tahmin edilecek regresyon katsayılarını ifade etmektedir.

Her meşcere elemanı için geliştirilen modelin parametre anlamlılıkları 0,05 önem düzeyinde test edilmiştir. Tüm parametreleri anlamlı olan ($p < 0,05$) modelin sıklık, yaş ve bonitet endeks değerine göre davranışı ve hata dağılımları analiz edilerek nihai modele karar verilmiştir (Şekil 2.7). Büyüme, genetik ve çevresel birçok faktörden etkilendiğinden dolayı örnekler arası farklılıklar oluşmakta ve bu durum model hata dağılımında değişen varyans problemine sebep olabilmektedir. Bu bakımdan hata dağılımlarının analiz edilmesi de model seçiminde önemli kriterlerden biridir. Bu çalışmada meşcere modellerinin hata dağılımlarını aynı düzeyde vermek için hataların z-skoruna $((x - \mu)/\sigma)$ göre normalizasyonu yapılmış ve grafiksel olarak gösterilmiştir.



Şekil 2.7 Meşcere büyüme modellerinin geliştirilmesine ilişkin diyagram

Bu çalışmada, meşcere elemanlarının BYSAM ile tahmininde örnek alan verilerinin tamamı kullanılmıştır. Çünkü, ağın büyüklüğü, diğer bir ifade ile ağın parametre sayısı test veri sayısına yakın olduğunda ağın genelleştirme kabiliyeti zayıfladığından dolayı ıraksak çözümler elde edilebilmektedir. Bu nedenle, ağın performansı hipotetik veriler üretilerek model davranışları üzerinden analiz edilmiştir. BYSAM modelinde kullanılan girdi ve çıktı değişkenleri regresyon modellerinde kullanılan bağımlı ve bağımsız değişkenler olarak belirlenmiştir.

Regresyon yöntemi ve BYSAM ile geliştirilen meşcere modelleri Denklem (21-23) kullanılarak karşılaştırılmıştır.

2.2.4.3 Ayrılan meşcerenin belirlenmesi

Meşcere gelişimi sırasında, bazı ağaçlar genetik faktörler, yetişme ortamı koşulları ve ağaçlar arası rekabete bağlı olarak mağlup duruma düşebilmektedirler. Söz konusu bu ağaçlar meşcere gelişimini desteklemek amacıyla silvikültürel müdahalelerle alandan çıkarılmasına öncelik verilenlerdir. Örnek alandaki dikili kuru ve silvikültürel müdahale ile çıkarılmış ağaçlar ile mağlup ağaçların ayrılan meşcere elemanları olduğu varsayılarak; ayrılan meşcere hacmi, $N_{ayrılan} \times v_{ayrılan}$ formülü ile hesaplanmaktadır. İlk olarak, ayrılan meşcerenin ağaç sayısı, kalan meşcere ağaç sayısının periyot başı ve sonundaki farkı alınarak hesaplanmaktadır. Kalan meşcere orta çapı ve orta boyu ile ayrılan meşcere orta çapı ve orta boyu arasındaki fonksiyonel ilişki farklı model yapıları kullanılarak belirlenmektedir (Ör. linear, power ve exponential model). Bu fonksiyonel ilişki kullanılarak, ayrılan meşcerenin orta çapı ve orta boyu hesaplanmaktadır. Tütün yayılımı yaptığı bölge için geliştirilen çift girişli denklemde söz konusu orta çap ve orta boy değerleri yerlerine konularak belirli bonitet ve sıklık değerindeki ilgili yaş için ayrılan meşcere hacmi belirlenmiş olmaktadır.

2.2.4.4 Sıklığa bağlı hasılat tablosunun diğer öğelerinin hesaplanması

Sıklığa bağlı hasılat tabloları, üç bölümden oluşmaktadır. Söz konusu üç bölüm soldan sağa olacak şekilde, kalan meşcere elemanlarını, ayrılan meşcere elemanlarını, genel meşcere özelliklerini içermektedir. İlk iki bölüm yukarıda açıklanmıştır. Son bölümde ise genel meşcereye ilişkin yıllık cari hacim artımı ve yüzdesi, genel meşcere verimi, genel hacim verimi içindeki ara hasılat yüzdesi, kalan ve genel meşcerenin ortalama artımları bulunmaktadır.

Yıllık cari hacim artımı (YCHA), belirli bir yaştaki kalan meşcerenin periyot sonu ve başındaki hacim farkına ayrılan meşcere hacmi eklenip periyot uzunluğuna bölünmesi ile hesaplanmaktadır.

$$YCHA = \frac{V_{ps} - V_{pb} + V_{pa}}{\text{Periyot uzunluğu}} \quad (70)$$

Yıllık cari hacim artım yüzdesi (YCHAY), periyot ortasındaki yıllık cari hacim artımının periyot ortasındaki meşcere hacmine yüzde olarak oranlanmasıyla hesaplanmaktadır.

$$YCHAY = \frac{YCHA}{\frac{V_{PS} + V_{PB}}{2} + \frac{V_{PA}}{2}} \times 100 \quad (71)$$

Genel hacim verimi (GHV), belirli bir yaş periyodunda kalan meşcere hacmine, ilgili periyotta kadar ayrılan toplam meşcere hacmi eklenerek hesaplanmaktadır.

$$GHV = V_t + \sum_{i=1}^m V_{pa} \quad (72)$$

Genel hacim verimi içindeki ara hasılat yüzdesi (AHY), belirli bir yaş periyodundaki toplam ayrılan meşcere hacminin, ilgili yaş periyodundaki kalan meşcere hacmine bölünmesiyle hesaplanmaktadır.

$$AHY = \frac{\sum_{i=1}^m V_{pa}}{GHV} 100 \quad (73)$$

Kalan ve genel meşcerenin ortalama hacim artımı (sırasıyla KMOHA ve GMOHA), belirli periyottaki kalan ve genel hacim değerlerinin ilgili periyottaki meşcere yaşına bölünmesiyle hesaplanmaktadır.

$$KMOHA = \frac{V_{kalan_t}}{t} \quad (74)$$

$$GMOHA = \frac{V_{genel_t}}{t} \quad (75)$$

Bu eşitliklerde; V_{pb} ve V_{ps} , belirli bir yaş periyodu için sırasıyla periyot başı ve sonu kalan meşcere hacmini; V_{pa} , belirli bir yaş periyodundaki ayrılan meşcere hacmini; V_{kalan_t} , belirli bir yaş periyodundaki kalan meşcere hacmini; V_{genel_t} , belirli bir yaş periyodundaki genel meşcere hacmini; m , periyot sayısını ifade etmektedir.

2.2.5 Çap dağılım modelleri

Meşcere büyüme modelleri ormanların planlanması sürecinde ihtiyaç duyulan ana kaynaklardan biridir ve genellikle bir ağaç türünün yayılış yaptığı alanlardan veriler toplanarak geliştirilirler. Ancak, bu modeller, bazı yöresel koşullardaki farklılıktan kaynaklanan değişik meşcere yapılarının olduğu alanları yeterince temsil edemezler. Ayrıca, söz konusu meşcere modelleri meşcere elemanları için 1 hektardaki ortalama değerleri yansıtmaktadır. Özellikle böyle farklılıklardan oluşan hataları azaltmak ve servet gibi orman işletmeleri için önemli parametreleri çap sınıfları düzeyinde ayrıntılı elde etmek için çap dağılım modellerine ihtiyaç duyulmaktadır. Çap dağılım modellerinde kullanılan değişkenler genel orman envanter çalışmalarında elde edilebilmektedir. Çap dağılım modelleri hacim, hacim artımı, göğüs yüzeyi ve orta boy gibi çap ile yüksek ilişkisi bulunan meşcere elemanlarının çap sınıfları düzeyinde tahmin edilmesine imkân sağlamaktadır. Böylece, söz konusu modeller ile birçok ormancılık uygulamasının ihtiyaç duyduğu detaylı bilgi zaman ve emek kaybı olmadan elde edilebilmektedir (von Gadow and Hui, 1999). Çap dağılım modellerinin parametrelerinin, meşcere özellikleri ile fonksiyonel ilişkileri belirlenerek, çap dağılımlarının projeksiyonu yapılabilmektedir. Böylece, odun eksenli ürün çeşitlerinin hem mevcut hem de zaman içindeki durumu çap sınıfları düzeyinde belirlenebilmektedir.

Bu çalışmada çap dağılım modelleri, regresyon yöntemi olarak üç parametrelili Weibull ve dört parametrelili Johnson's SB olasılık yoğunluk fonksiyonları ve BYSAM kullanılarak geliştirilmiştir. Bayesçi ağ yapılarında girdi değişkeni olarak, Weibull ve

Johnson's SB dağılımları arasında daha başarılı olan modeldeki değişkenler kullanılmıştır.

$$\text{Weibull (1951)} \quad f(x) = \frac{\gamma}{\beta} \left(\frac{x-a}{\beta} \right)^{\gamma-1} \exp \left(- \left(\frac{x-a}{\beta} \right)^{\gamma} \right) \quad (76)$$

$$\text{Johnson (1949)} \quad f(x) = \frac{\delta}{\sqrt{2\pi}} \frac{\lambda}{(\xi + \lambda - x)(x - \xi)} e^{-\frac{1}{2} \left[\lambda + \delta \ln \left(\frac{x-\xi}{\xi+\lambda-x} \right) \right]^2} \quad (77)$$

$$\xi < x < +\lambda, -\infty < \gamma < +\infty, \lambda > 0 \text{ ve } \delta > 0$$

Bu eşitliklerde; x , çap sınıfı orta değeri; a ve ξ , konum parametresi; β ve λ , ölçek parametresi; γ ve δ , şekil parametresini ifade etmektedir.

2.2.5.1 Çap dağılım modellerinin parametre tahmin yöntemleri

Bu çalışmada Weibull olasılık yoğunluk fonksiyonunun parametreleri çap dağılımlarının belirli yüzdelikleri kullanılarak hesaplanmıştır (Borders *et al.*, 1987). Çalışma kapsamında değerlendirmeye alınan eşitlikler aşağıda verilmektedir.

$$\text{Weibull-1} \quad \gamma = \frac{\text{Ln} \left(\frac{\text{Ln}(1-0,63)}{\text{Ln}(1-0,31)} \right)}{\text{Ln}(d_{\%63} - \alpha) - \text{Ln}(d_{\%31} - \alpha)} \quad \beta = \frac{d_{\%63} - \alpha}{(-\text{Ln}(1-0,63))^{\frac{1}{\gamma}}} \quad (78)$$

$$\text{Weibull-2} \quad \gamma = \frac{\text{Ln} \left(\frac{\text{Ln}(1-0,95)}{\text{Ln}(1-0,25)} \right)}{\text{Ln}(d_{\%95} - \alpha) - \text{Ln}(d_{\%25} - \alpha)} \quad \beta = \frac{d_{\%50} - \alpha}{(-\text{Ln}(1-0,50))^{\frac{1}{\gamma}}} \quad (79)$$

$$\text{Weibull-3} \quad \gamma = \frac{\text{Ln} \left(\frac{\text{Ln}(1-0,63)}{\text{Ln}(1-0,31)} \right)}{\text{Ln}(d_{\%63} - \alpha) - \text{Ln}(d_{\%31} - \alpha)} \quad \beta = \frac{d_{\%50} - \alpha}{(-\text{Ln}(1-0,50))^{\frac{1}{\gamma}}} \quad (80)$$

$$\text{Weibull-4} \quad \gamma = \frac{\text{Ln} \left(\frac{\text{Ln}(1-0,95)}{\text{Ln}(1-0,50)} \right)}{\text{Ln}(d_{\%95} - \alpha) - \text{Ln}(d_{\%50} - \alpha)} \quad \beta = \frac{d_{\%50} - \alpha}{(-\text{Ln}(1-0,50))^{\frac{1}{\gamma}}} \quad (81)$$

$$\text{Weibull-5} \quad \alpha = \frac{n^{0,3333} d_{min} - d_{\%50}}{n^{0,3333} - 1} \quad \gamma = \frac{2,343088}{Ln(d_{\%95} - \alpha) - Ln(d_{\%25} - \alpha)} \quad (82)$$

$$\beta = \frac{\alpha \Gamma_1}{\Gamma_2} + \sqrt{\left(\frac{\alpha}{\Gamma_2}\right)(\Gamma_1^2 - \Gamma_1) + \left(\frac{d_g^2}{\Gamma_2}\right)} \quad (83)$$

$$\Gamma_1 = \Gamma \left(1 + \frac{1}{\gamma}\right) \text{ ve } \Gamma_2 = \Gamma \left(1 + \frac{2}{\gamma}\right) \quad (84)$$

Bu eşitliklerde; n, örnek alanda ölçülen ağaç sayısını; d_{min} , örnek alandaki minimum çapı; $d_{\%25}$, $d_{\%31}$, $d_{\%50}$, $d_{\%63}$, $d_{\%95}$ 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 alanın orta çapını ve Γ , gamma dağılımını ifade etmektedir. Denklem (78-82)'de α değeri örnek alandaki minimum çapın yarısı olarak hesaplanmıştır (Poudel 2011).

Johnson's SB olasılık yoğunluk fonksiyonun parametreleri Knoebel and Burkhart (1991) tarafından geliştirilen yüzdelik yöntem ve Ogana *et al.* (2017) tarafından kullanılan moment yöntemi ile hesaplanmıştır.

$$\gamma = -\delta \ln \left(\frac{d_{\%50} - \xi}{\xi + \lambda - d_{\%50}} \right) \quad (85)$$

$$\text{Yüzdelik Yöntem} \quad \delta = \frac{Z_{95}}{\ln \left(\frac{d_{\%95} - \xi}{\xi + \lambda - d_{\%95}} \right)} \quad (86)$$

$$\xi = d_{min} - 1,3 \quad (87)$$

$$\lambda = d_{max} - \xi + 3,8 \quad (88)$$

$$\delta = \frac{\mu(1 - \mu)}{SD(x)} + \frac{SD(x)}{4} \left[\frac{1}{\mu(1 - \mu)} - 8 \right] \quad (89)$$

$$\text{Moment Yöntem} \quad \gamma = \delta \ln \left(\frac{1 - \mu}{\mu} \right) + \left(\frac{0,5 - \mu}{\delta} \right) \quad (90)$$

$$\xi = d_{min} - 1,3 \quad (91)$$

$$\lambda = d_{max} - \xi + 3,8 \quad (92)$$

$$SD(x) = \frac{\sigma_x}{\lambda} \quad (93)$$

$$\mu = \frac{d_{ort} - \xi}{\lambda} \quad (94)$$

Bu eşitliklerde; σ_x , dağılımın standart sapma değerini ifade etmektedir.

Geliştirilen çap dağılım modellerinin örnek alanlara uygulugu Kolmogorov-Smirnov (K-S) testi ile belirlenmiştir. K-S testi ile, geliştirilen modellerin örnek alanlara uygunluğu test edilirken, öncelikle her bir çap sınıfındaki gözlem değeri örnek alanın hektardaki değerine bölünerek bir oran belirlenir ve bu oranlar kümülatif olarak düzenlenir. Daha sonra, çap sınıfı düzeyinde elde edilen tahminler hektardaki tahmini değere oranlanır ve bu oranlar kümülatif olarak düzenlenir. Son aşamada kümülatif oranların farkı alınır ve maksimum sapma (D) belirlenir $D = |F_{gerçek} - F_{tahmin}|$. Maksimum sapmanın kabul edilebilir olup olmadığını test etmek için örneklem büyüklüğüne göre kritik bir eşik belirlenir (Massey 1951). Eğer örneklem büyüklüğü (örnek alandaki ağaç sayısı) $n > 35$ ise, testin kritik eşik değeri, $1,36/\sqrt{n}$ formülü hesaplanır. Örneklem büyüklüğü 35'ten küçükse, belirlenen önem düzeyine göre ilgili tablodan kritik eşik değeri belirlenir (Özdemir 2016). D değeri, kritik eşik değeri eşit ya da küçükse teorik dağılımın örnek dağılımından farksız olduğuna karar verilir.

Parametre tahmin yöntemlerinden en başarılı olanını belirlemek için ortalama hata, toplam hata, ortalama mutlak hata, hata kareler ortalamasının karekökü değerleri kıyaslanmıştır. Birden fazla model performans ölçütü kullanıldığından dolayı en başarılı model seçiminde Poudel and Cao (2013) tarafından önerilen model sıralama sistemi kullanılmıştır. Bu yöntemde, en başarılı yöntem 1 sıra numarası değerini alırken diğer yöntemler hata değerinin büyüklüğü nispetinde bir sayı değeri almaktadır. Bu yaklaşımda birbirine yakın sıra numarasına sahip yöntemler aynı grup içerisinde değerlendirilmektedir.

$$R_i = 1 + \frac{(m - 1)(S_i - S_{mak})}{S_{mak} - S_{min}} \quad (95)$$

Bu eşitlikte; R_i , her bir metodun oransal sıra numarasını; m , model sayısını; S_i , model hata değerini; $S_{\min}$, minimum hata değerini; $S_{\max}$, maksimum hata değerini ifade etmektedir.

2.2.6 Tek ağaç büyüme modeli

Tek ağaç büyüme modelleri, çap dağılım modellerinin çap sınıfı düzeyinde içerdiği bilgileri, tek ağaç düzeyinde üretebilen modellerdir. Bu bakımından hem meşcere hem de çap sınıfı modellerinden daha ayrıntılıdır. Meşcerelerde artım ve büyüme birçok faktörün karşılıklı etkileşiminin bir sonucu olduğundan dolayı, hassas bir şekilde meşcere gelişimlerini ortaya koymak için tek ağaç modellerine ihtiyaç duyulmaktadır. Söz konusu modeller ile, ağaçların bugünkü ve gelecekteki göğüs yüzeyi ve hacim artım değerleri tek ağaç, çap sınıfı ve meşcere bazında elde edilebilmektedir. Ayrıca, bu modeller kullanılarak, çap ile yüksek fonksiyonel ilişkiler gösteren meşcere elemanlarının da projeksiyonu, tek ağaç, çap sınıfı ve meşcere düzeyinde yapılabilmektedir. Bu çalışmada, üssel büyüme modeli yapısı kullanılarak doğrusal olmayan tek ağaç çap artım modeli geliştirilmiştir (Lee *et al.* 2004). Üssel modeller şekil parametresinin pozitif olduğu durumlarda S eğrisini; negatif olduğu durumlarda ters J eğrisini iyi bir şekilde açıklayabilmektedir. Tek ağaç modellerinde bağımsız değişken seti olarak genellikle ağaçların dendrometrik özellikleri, meşcere özellikleri ve yarışma durumlarından yararlanılmaktadır (Burkhardt and Tomé, 2012).

Tek ağaç modelleri, yarışma endekslerini hesaplama yöntemine göre iki gruba ayrılmaktadır. Eğer örnek alandaki bir ağacın yarışma endeks değeri, örnek alandaki ağaçların ortalama ya da maksimum değeriyle ($d_{ort}, d_{max}, G_{max}$) ilişkili ise uzaklıktan bağımsız tek ağaç çap artım modeli olarak isimlendirilmektedir. Eğer bir ağacın yarışma endeks değeri, komşu ağaçlarla aralarındaki mesafe ve yarışma halinde olan ağaçların dendrometrik özellikleri (çap ve göğüs yüzeyi) kullanılarak hesaplanıyorsa, uzaklığa bağlı tek ağaç çap artım modeli olarak isimlendirilmektedir (Burkhardt and Tomé, 2012). Eğer bir ağacın boyutları, ortalama meşcere boyutlarından daha büyükse, konu ağacın

genetik özellikleri ve yetiştirme ortamı koşullarının izin verdiği ölçüde sahip olduğu büyüme potansiyelini kullanabildiği anlamına gelmektedir. Bu çalışmada geliştirilen uzaklıktan bağımsız tek ağaç çap artım modellerinde kullanılan yarışma endeksleri aşağıda verilmektedir (Mısır 2003).

Konu ağaç göğüs çapını, örnek alan için hesaplanan göğüs yüzeyi orta ağacının çapına oranlayan yöntem;

$$ye_1 = \frac{d_i}{d_g} \quad (96)$$

Konu ağaç göğüs çapını, örnek alandaki en kalın çapa oranlayan yöntem;

$$ye_2 = \frac{d_i}{d_{mak}} \quad (97)$$

Konu ağaç göğüs yüzeyini, örnek alanın ortalama göğüs yüzeyine oranlayan yöntem;

$$ye_3 = \frac{g_i}{g_{ort}} \quad (98)$$

Konu ağaç göğüs yüzeyini, örnek alandaki en kalın çaplı ağacın göğüs yüzeyine oranlayan yöntem;

$$ye_4 = \frac{g_i}{g_{max}} \quad (99)$$

Konu ağaçtan daha kalın çaplı ağaçların göğüs yüzeyleri toplamını esas alan yöntem;

$$ye_5 = BAL_i = \frac{\pi}{4} \sum_{j=1}^n d_j^2 \quad d_j > d_i \quad (100)$$

Konu ağacın canlı tepesinin %66'sı yüksekliğinde meşceredeki tüm ağaçların tepe izdüşümü alanları toplamını yarışma endeksi kabul eden yöntem;

$$ye_6 = \sum T_{66i} \quad (101)$$

Bu eşitliklerde; ye_i ve BAL_i , konu ağacın yarışma değerini; d_i , konu ağacın göğüs yüksekliği çapını; d_g , örnek alanın orta çapını; d_{mak} , örnek alandaki en kalın çapa sahip ağacın göğüs yüksekliği çapını; g_i , konu ağacın göğüs yüzeyini; g_{ort} , örnek alanın göğüs yüzeyi ortalamasını; g_{max} , örnek alandaki en kalın ağacın göğüs yüzeyini; d_j , konu ağaçtan daha kalın çaplı ağaçların çaplarını; T_{66i} , Konu ağacın canlı tepesinin %66 yüksekliğinde meşceredeki diğer tüm ağaçların tepe izdüşümü alanlarını ifade etmektedir.

Bu çalışmada, tek ağaç çap artım modeli geliştirme aşamasında, ağaçların boyutları (d , $\ln(d)$, $1/d$ gibi), meşcere özellikleri (G , sd , $\ln(sd)$, be , $\ln(be)$ gibi) ve yarışma endeksleri (ye_1 , $\ln(ye_3)$) ile bunların çeşitli kombinasyonları ($d \times \ln(ye_1)$, $\ln(be) \times sd$, be/sd gibi) kullanmış olup bağımlı değişkendeki varyansı daha iyi açıklayan bağımsız değişkenler aşamalı regresyon analizi ile belirlenmiştir. Modelin pratik olması ve genel orman envanter verileri ile geliştirilebilmesi amacıyla meşcere yaşı değişkeni modele katılmamıştır. Üssel model yapısı, toplamsal (additive) ve çarpımsal (multiplicative) olarak yeni değişkenler eklenerek genişletilebilmektedir. Bu çalışmada, şekil parametresine toplamsal olarak yeni değişkenler eklenerek tek ağaç çap artım modeli geliştirilmiştir. Bu çalışmada kullanılan model yapısı $y = b_1 \times \exp(b_i X_i) + \varepsilon$ şeklinde olup, X_i açıklayıcı değişken setini, ε model hatasını ifade etmektedir.

BYSAM'nde ise tek ağaç düzeyinde geliştirilen üssel formdaki regresyon modelinin bağımlı ve bağımsız değişkenleri sırasıyla girdi ve çıktı değişkenleri olarak tanımlanmıştır. Regresyon modeli ile BYSAM'nin karşılaştırılmasında Denklem (21-23) kullanılmıştır.

Tek ağaçların beş veya on yıl önceki göğüs yüksekliği çapları, göğüs yüzeyleri ve hacimleri ile bu öğelere ilişkin artımların hesaplanmasında Denklem (73-83) kullanılmıştır. Tek ağaçların 5 veya 10 yıl öncesi çap artım değerlerini tahmin etmek için öncelikle kabuksuz çapları ve kabuk faktörünün hesaplanması gerekmektedir. Tek ağaçların kabuksuz göğüs yüksekliği çapları, göğüs yüksekliğinden ölçülen çift kabuk kalınlığı değerlerinden çıkarılarak hesaplanmaktadır. Kabuk faktörü ise, kabuklu göğüs yüksekliği çapının, hesaplanan kabuksuz göğüs yüksekliği çapına bölünmesiyle elde edilmektedir.

$$d_{kbksz} = d_{kbkl} - \text{çkk} \quad (102)$$

$$kf = \frac{d_{kbklu}}{d_{kbksz}} \quad (103)$$

Beş veya on yıl önceki kabuksuz ve kabuklu çaplar;

$$d_{5kbksz} = d_{kbksz} - \text{ç}a_5 \quad (104)$$

$$d_{5kbkl} = (d_{5kbksz})kf \quad (105)$$

$$d_{10kbksz} = d_{kbksz} - \text{ç}a_{10} \quad (106)$$

$$d_{10kbkl} = (d_{10kbksz})kf \quad (107)$$

Bu eşitliklerde; d_{kbksz} , Bugünkü kabuksuz göğüs yüksekliği çapını; d_{kbklu} , bugünkü kabuklu göğüs yüksekliği çapını; çkk , çift kabuk kalınlığını; kf , kabuk faktörünü; $d_{5-10kbksz}$, 5 ve 10 yıl önceki kabuksuz göğüs yüksekliği çapını; $\text{ç}a_{5-10}$, 5 ve 10 yıllık çap artımını ifade etmektedir.

Tek ağaçların göğüs yüzeyleri artımları, bugünkü ve 5 veya 10 yıl önceki kabuklu göğüs yüksekliği çapları kullanılarak hesaplanmıştır.

$$g_{kbklu} = \frac{\pi}{4} d_{kbklu}^2 \quad (108)$$

$$g_{5kbklu} = \frac{\pi}{4} d_{5kbklu}^2 \quad (109)$$

$$ga_{5kbklu} = g_{kbklu} - g_{5kbklu} \quad (110)$$

$$g_{10kbklu} = \frac{\pi}{4} d_{10kbklu}^2 \quad (111)$$

$$ga_{10kbklu} = g_{kbklu} - g_{10kbklu} \quad (112)$$

Bu eşitliklerde; g_{kbklu} , bugünkü kabuklu göğüs yüzeyini; $g_{5-10kbklu}$ 5 ve 10 yıl önceki kabuklu göğüs yüzeyini; $ga_{5-10kbklu}$, 5 ve 10 yıl önceki kabuklu göğüs yüzeyi artımını ifade etmektedir.

Tek ağaçların hacim artım değerleri, çalışma kapsamında geliştirilen tek girişli ağaç hacim denkleminde bugünkü ve 5 veya 10 yıl önceki kabuklu göğüs yüksekliği çapları kullanılarak hesaplanmaktadır. Hesaplanan bugünkü hacim değerinden 5 veya 10 yıl önceki hacim değeri çıkarılarak 5 veya 10 yıllık hacim artım değeri hesaplanmaktadır.

2.2.6.1 Tepe boyutlarının hesaplanması

Tek ağaçların çap artımlarının modellenmesinde, tepe çapı ve tepe başlangıç değerleri de açıklayıcı değişkenler olarak kullanılabilir. Tek ağaçların geçmiş yıllara ait çap artım değerleri kullanılarak, bir periyotta göğüs yüzeyi ve hacim olarak ne kadar gelişim gösterdikleri belirlenebilirken; tek ağaçların tepe gelişimiyle ilgili bir çıkarım yapılamamaktadır. Bu çalışmada söz konusu eksikliğin giderilmesi amacıyla, tepe boyutları, üssel model formu kullanılarak tek ağaçların göğüs yüksekliği çapı, bonitet endeksi ve sıklığın bir fonksiyonu olarak tahmin edilmiştir.

$$y_{tç} = b_1 \exp(b_2 \ln(d) + b_3 be + b_4 sd) \quad (113)$$

$$y_{tb} = b_1 \exp(b_2 \ln(d) + b_3 be + b_4 sd) \quad (114)$$

Bu eşitliklerde; y_{tc} , tek ağaçların tepe çaplarını; y_{tby} , tek ağaçların tepe başlangıç yüksekliklerini; d , tek ağaçların göğüs yüksekliği çaplarını; be , bonitet endeks değerini; sd , sıklık indeks değerini ifade etmektedir.

2.2.6.2 Tek ağaç büyüme modellerinin denetimi

Bu çalışmada geliştirilen üssel çap artım modelinin Ankara Orman Bölge Müdürlüğü sınırları içerisinde yayılış gösteren Anadolu karaçamı meşcerelerine uygunluğu denklik testi ile denetlenmiştir. Bu amaçla, tek ağaç çap artım verileri, model geliştirme verileri (%85, $n=1312$) ve model uygunluğunun testi için kullanılan (%15, $n=231$) veriler olmak üzere iki gruba ayrılmıştır. Model uygunluğunun hata terimleri üzerinden de analiz edilmesi modelin güvenilirliği açısından önemlidir. Model hata dağılımında değişen varyans problemi olmaması, diğer bir ifade ile model hata dağılımı x-ekseni boyunca sıfıra yakın homojen bir dağılım göstermesi beklenmektedir. Bu nedenle, geliştirilen tek ağaç çap artım modellerinin hata dağılımları ayrıca analiz edilmiştir.

3. BULGULAR

3.1 Parçalı Gövde Çapı Modellerine İlişkin Bulgular

Bu çalışmada, ağaçların değişik yüksekliklerindeki kabuklu gövde çaplarının tahmininde uyumlu parçalı gövde çapı modelleri (PGÇM 1-4) ve Bayesçi yapay sinir ağı modeli (BYSAM) kullanılmıştır. Model karşılaştırmalarının aynı düzeyde yapılabilmesi amacıyla bağımlı değişkenler $d_i/d_{1,3}$ şeklinde düzenlenmiştir. Clark (1991) modeli ile yakınsak çözümler elde edilememiştir. Diğer PGÇM'ne ilişkin bulgular Çizelge 3.1'de verilmektedir.

Çizelge 3.1. Parçalı gövde çapı modellerine ilişkin bulgular

Modeller	$R_{düz}^2$	HKOK	AIC	DW	Kİ
PGÇM-1	0.88	0.084	-7899.5	0.703	16.782
PGÇM-2	0.84	0.145	-2479.3	1.049	190.879
PGÇM-4	0.90	0.077	-8190.8	0.738	41.173


$R_{düz}^2$: düzeltilmiş belirtme katsayısı, HKOK: hata kareler ortalamasının karekökü, AIC: Akaike bilgi kriteri, DW: Durbin-Watson, Kİ: Koşul İndeksi

Model performans değerlerine göre en başarılı modelin PGÇM-4 olduğu anlaşılmıştır. Dolayısıyla, ağaçların değişik yüksekliklerindeki gövde çapları PGÇM-4 kullanılarak modellenmiştir. BYSAM ile geliştirilen gövde çapı modelinin parametre sayısı 25, momentum değeri 0,5, öğrenme oranı 0,1 ve ideal yakınsama değeri, 0,0072'dir. Model veri seti kullanılarak elde edilen model performans ölçütlerine ilişkin bulgular, Çizelge 3.2'de verilmektedir.

Çizelge 3.2 PGÇM-4 ve BYSAM'ne ilişkin model performans değerleri

Modeller	Parametre Sayısı	$R_{düz}^2$	HKOK	AIC
PGÇM-4	8	0,90	0.077	-8190.8
BYSAM	25	0,89	0,085	-7843,6

Model performans değerlendirme ölçütlerine göre, BYSAM ve PGÇM-4 birbirine yakın sonuçlar üretmiştir. Ancak tüm hata ölçütlerine göre PGÇM-4 az bir farkla daha başarılı bulunmuştur. Tahminlere karşı gözlemler ve çap sınıflarına karşı hata dağılımları incelendiğinde ise (Şekil 3.1), BYSAM ve PGÇM-4'ün benzer hata dağılımına sahip olduğu ve hatalarda değişen varyans probleminin olmadığı anlaşılmıştır.




Şekil 3.1 PGÇM-4 ve BYSAM'nin hata dağılımları ve tahmin-gözlem grafikleri

Bu çalışmada, aynı ağaç üzerinde 1 m ara ile gövde çapı verileri elde edilmiştir. Bu şekilde, seri halinde toplanmış verilerin ardışık değerleri arasında doğrusal bir ilişki bulunmaktadır. Literatürde, otokorelasyon olarak isimlendirilen bu problemin çözümü için otoregresif modelleme teknikleri önerilmektedir. Otoregresif parametreleri içeren modellere ilişkin bulgular Çizelge 3.3'te verilmiştir.

Çizelge 3.3 Otoregresif modellere ilişkin bulgular

Modeller	Otoregresif Parametreler	$R_{düz}^2$	HKOK	AIC	DW	Kİ
PGÇM-1	AR (1)	0.93	0.064	-8796.2	2.19	16.3
	CAR (1)	0.92	0.070	-8488.8	1.53	14.2
	CAR (2)	0.93	0.065	-8717.3	1.78	13.5
PGÇM-2	AR (2)	0.88	0.125	-6632.3	2.03	178.0
	CAR (1)	0.87	0.134	-6424.5	1.75	174.9
	CAR (2)	0.88	0.130	-6503.0	1.88	172.6
PGÇM-4	ARMA (1,1)	0.94	0.057	-9161.1	2.00	34.0
	CAR (1)	0.93	0.064	-8770.6	1.56	37.6
	CAR (2)	0.94	0.059	-9027.7	1.76	36.6

Çizelge 3.3'te verilen bulgulara göre, otokorelasyonun tahminler üzerindeki etkisinin minimize edilmesinde ARMA (1, 1)'in diğer otoregresif modellerden daha başarılı olduğu anlaşılmıştır (PGÇM-4 – ARMA (1, 1) için DW=2,00). CAR (3) otoregresif parametresi ile anlamlı sonuçlar elde edilememiştir. Otoregresif parametreleri içeren modellere ilişkin gecikmeli hata dağılımlarının koordinat ekseninin [0, 0] noktasında rasgele bir dağılım göstermesi beklenmektedir. Bu açıdan bakıldığında da ARMA otoregresif yapısının CAR otoregresif yapısından daha iyi olduğu anlaşılmıştır (Şekil 3.2). Otoregresif parametreleri içeren en başarılı model olan PGÇM & ARMA (1, 1)'in model veri seti kullanılarak elde edilen parametre tahminlerine, standart hata, t ve p değerlerine ilişkin bulgular Çizelge 3.4'te verilmiştir.



Şekil 3.2 Parçalı gövde çapı modellerinin gecikmeli hata dağılımları

Çizelge 3.4 PGÇM-4'ün ARMA (1, 1) ile çözümüne ilişkin parametre tahminleri, standart hata, t ve p değerleri

Parametre	Tahmin	Standart Hata	t değeri	p değeri
b_1	0,000013	0,0000	52,31	<0,0001
b_2	0,000038	0,0000	101,82	<0,0000
b_3	0,000035	0,0000	71,69	<0,0001
b_4	0,092464	0,0019	48,17	<0,0001
b_5	0,624734	0,0326	19,15	<0,0001
b_6	0,000057	0,0000	11,38	<0,0001
b_7	1,816665	0,0225	80,64	<0,0001
b_8	0,883169	0,0274	32,22	<0,0001
ρ_1^1	0,858719	0,0109	78,53	<0,0001
ρ_2^1	0,215259	0,0206	10,46	<0,0001

^xSAS kodlama dilinde; ρ_1^1 , %ar(y,1) ρ_2^1 , %ma(y,1)

3.1.1 Gövde çapı modellerinin denetimi

Bu çalışma kapsamında geliştirilen gövde çapı modellerinin verilerin toplandığı Ankara Orman Bölge Müdürlüğü saf karaçam meşcerelerine uygunluğu denklik testi ile denetlenmiştir. Denklik testi bulgularına göre, PGÇM-4 & ARMA (1, 1) ve BYSAM tahminleri, gerçek verilerle %95 benzeşmektedir (Çizelge 3.5). Bu yöntemde tahmin ve gözlem değerleri arasında basit doğrusal regresyon analizi kurulmakta (b_0+b_1X) ve tahmin ve gerçek değerlerin benzerliği sabit katsayı (b_0) ve eğim parametresi (b_1) ile belirlenmektedir. Belirlenen benzeşmezlik oranında her iki modelin b_0 ve b_1 parametresi 0,05 önem düzeyinde anlamlı elde edilmiştir ($p<0,05$).

Çizelge 3.5 Parçalı gövde çapı modelinin denetimine ilişkin bulgular

Modeller	b_0		Bootstrap b_0		H_0	b_1		Bootstrap b_1		H_0
	Alt	Üst	Alt	Üst		Alt	Üst	Alt	Üst	
	Limit	Limit	Limit	Limit		Limit	Limit	Limit	Limit	
PGÇM-4 & ARMA (1, 1)	25,6	26,1	25,6	25,9	Ret	0,95	1,05	0,99	1,03	Ret
BYSAM	25,6	26,1	25,6	26,0	Ret	0,95	1,05	0,98	1,02	Ret

3.2 Ağaç Hacim Modellerine İlişkin Bulgular

3.2.1 Tek ve çift girişli regresyon denklemlerine ilişkin bulgular

Tek ve çift girişli ağaç hacim denklemleri arasında Denklem (27) (AHD1), Denklem (30) (AHD4), Denklem (31) (AHD5) ve Denklem (32) (AHD6)' in tüm parametreleri 0,05 önem düzeyinde istatistiksel olarak anlamlı iken, diğer tek ve çift girişli ağaç hacim denklemlerinin parametrelerinin bazıları anlamsız bulunmuştur. Ancak, tüm parametreleri 0,05 önem düzeyinde istatistiksel olarak anlamlı bulunan AHD1 ve AHD6 ise, göğüs yüksekliği çapı 8 cm'den küçük ağaçlar için negatif hacim tahminleri verildiklerinden dolayı değerlendirmeye alınmamıştır. Dolayısıyla, bu çalışmada ağaç hacimlerinin tahmininde tek girişli AHD4 ve çift girişli AHD5 değerlendirmeye alınmıştır. Tek ve çift girişli ağaç hacim denklemlerine ilişkin parametre tahminleri

Çizelge 3.6’da verilmiştir. AHD4 ve AHD5’in model veri setindeki model performans değerlendirme değerleri Çizelge 3.7’de verilmektedir.

Çizelge 3.6 Tek ve çift girişli ağaç hacim modellerinin parametre tahminleri

Modeller	Parametre Tahminleri					
	b_0	b_1	b_2	b_3	b_4	b_5
AHD1	-0,090	0,001				
AHD2	-0151	0,004*	0,001			
AHD3	-0,102	0,001	0,134*			
AHD4	0,000198	2,355				
AHD5	0,042	0,000039				
AHD6	-0,112	0,000208	0,009	0,000028		
AHD7	0,118*	-0,024	0,001	-0,005*	0,001	0,000005*
AHD8	0,081*	-0,023	0,001	0,001	0,0000007*	
AHD9	-0,072	0,000332	0,000156*	0,000013*	0,000018*	
AHD10	0,118*	-0,024	0,001	-0,005*	0,001	0,000005*
AHD11	0,081	-0,023	0,001	0,001	0,000007	
AHD12	-0,093	0,001	0,000220	0,000013	0,0000004	
AHD13	0,016*	0,000139*	0,000036			

* 0,05 önem düzeyinde istatistiksel olarak anlamsız parametreyi ifade etmektedir.

Çizelge 3.7 Tek ve çift girişli ağaç hacim denklemlerinin model performans değerleri

Modeller	OH	OMH	THY	OMHY	$R_{düz}^2$
AHD4	0,0504	0,1885	5,3846	20,1483	0,8786
AHD5	-0,0124	0,1142	-1,3252	12,1999	0,9366

OH: ortalama hata, OMH: ortalama mutlak hata, THY: toplam hata yüzdesi, OMHY: ortalama mutlak hata yüzdesi

Bu çalışma kapsamında geliştirilen tek girişli ağaç hacim denklemi (AHD4) ve çift girişli ağaç hacim denklemi (AHD5) aşağıda verilmiştir.

$$V = 0,000198d^{2,355} \quad (115)$$

$$V = 0,042 + 0,000039d^2h \quad (116)$$

3.2.2 Görünüşte ilişkisiz regresyon modeline ilişkin bulgular

Bu çalışmada, temsil kabiliyeti daha güçlü olan, diğer bir ifade ile doğruluğu daha yüksek olan çift girişli ağaç hacim modellerini elde etmek için görünüşte ilişkisiz regresyon modeli (GİRM) kullanılarak PGÇM-4 ve PGÇM-4 & ARMA (1, 1)'e dayalı çift girişli ağaç hacim modelleri geliştirilmiştir. GİRM ile geliştirilen çift girişli ağaç hacim modellerine ilişkin model performans değerleri Çizelge 3.8'de verilmiştir.

Çizelge 3.8 GİRM ile geliştirilen çift girişli ağaç hacim modellerinin performans değerleri

Modeller	OH	OMH	THY	OMHY	$R_{düz}^2$	DW
AHD14	0,047	0,108	4,979	11,556	0,949	0,07
AHD15	0,030	0,104	-3,223	11,501	0,997	1,96

AHD14, PGÇM-4'nin GİRM'ne dayalı çözümü

AHD15, PGÇM-4 & ARMA (1, 1)'in GİRM'ne dayalı çözümü


Çizelge 3.8'e göre, otoregresif parametreleri içeren AHD15, otoregresif parametreleri içermeyen AHD14'ten daha başarılı bulunmuştur. Bu çalışma kapsamında geliştirilen tüm çift girişli regresyon modelleri (AHD5, AHD14 ve AHD15) karşılaştırıldığında ise, AHD15'in model performans değerlendirme değerlerine göre daha başarılı olduğu anlaşılmıştır.

$$V = 0,000202d^{1,602553}h^{0,969154} \quad (117)$$

3.2.3 Bayesçi yapay sinir ağı modeline ilişkin bulgular

Yalnızca göğüs yüksekliği çapının fonksiyonu olarak geliştirilen BYSAM (AHD16)'nin parametre sayısı 19, momentum değeri 0,5, öğrenme oranı 0,1 ve ideal yakınsama değeri 0,0044'tür. AHD16'nın model ve test (parantez içerisinde verilmektedir) veri setindeki performans değerlendirme değerleri şu şekildedir; $R_{düz}^2$: 0,90 (0,90), OH: -0,0127 (-0,0011), OMH: 0,1682 (0,2131), THY: -1,3622 (-2,8084) ve OMHY: 17,9757


(24,5381). Model performans değerlendirme değerlerine göre, AHD16'nın AHD4'ten daha başarılı olduğu anlaşılmıştır. Ayrıca, test veri setinde elde edilen başarı (yüksek $R_{düz}^2$ ve düşük hata değeri) ve geliştirilen yapay sinir ağı modeli ile tahmin edilen ağaç hacimlerinin çapa karşı sigmoid bir değişim göstermesi geliştirilen yapay sinir ağı modelinin aşırı uyum problemi taşımadığını göstermiştir (Şekil 3.3).



Şekil 3.3 Göğüs yüksekliği çapını esas alan BYSAM'nin simülasyon veri setindeki davranışı


Göğüs yüksekliği çapının ve toplam ağaç boyunun fonksiyonu olarak geliştirilen BYSAM (AHD17)'nin parametre sayısı 29, momentum değeri 0,5, öğrenme oranı 0,1 ve ideal yakınsama değeri, 0,0122'dir. AHD17'nin model ve test (parantez içerisinde verilmiştir) veri setindeki performans değerlendirme değerleri şu şekildedir; $R_{düz}^2$: 0,8473 (0,8140), OH: 0,0032 (-0,0038), OMH: 0,1078 (0,1111), THY: 0,3385 (-0,4344) ve OMHY: 11,5252 (12,7964). Ayrıca, AHD17'nin test veri setindeki başarısı (yüksek $R_{düz}^2$ ve düşük hata değeri) ve BYSAM ile elde edilen hacim tahminlerinin çapa ve boya karşı sigmoid bir yapıda olması, BYSAM'nin aşırı uyum problemi taşımadığını

göstermiştir (Şekil 3.4). Bu çalışma kapsamında geliştirilen çift girişli regresyon modeli ve çift girişli BYSAM kıyaslandığında hem otoregresif parametreleri içeren hem de otoregresif parametreleri içermeyen çift girişli regresyon modelleri daha başarılı bulunmuştur. Başka bir açıdan bakıldığında, regresyon modellerinin aksine açıklayıcı değişken sayısı arttığında BYSAM'nin başarısı azalmıştır.




Şekil 3.4 Göğüs yüksekliği çapını ve toplam ağaç boyunu esas alan BYSAM'nin simülasyon veri setindeki davranışı

Ağaç hacim modellerinin gözlemlere karşı tahminler ve çap sınıflarına karşı hata dağılımları sırasıyla Şekil 3.5 ve Şekil 3.6'da verilmiştir.



Şekil 3.5 Ağaç hacim modellerinin gözlemlere karşı tahminlerin dağılımları




Şekil 3.6 Ağaç hacim modellerinin çap sınıflarına göre hata dağılımları


Bu çalışmada geliştirilen tek girişli ağaç hacim modelinin (AHD4) Amenajman Planı ve Sun vd. (1978) ile grafiksel olarak karşılaştırılması Şekil 3.7’de verilmiştir. Grafik üzerinden yapılan değerlendirmeye göre bu çalışma kapsamında geliştirilen tek girişli ağaç hacim modelinin özellikle kalın çaplı ağaçların hacim tahminlerinde daha başarılı olduğu görülmektedir.

Bu çalışmada geliştirilen çift girişli ağaç hacim modelinin Gülen (1958) ile grafiksel karşılaştırılması ise Şekil 3.8’de verilmiştir. Grafik üzerinden yapılan değerlendirmeye göre hem bu çalışma kapsamında hem de Gülen (1958) tarafından geliştirilen çift girişli ağaç hacim modelleri gerçek hacim değerleriyle iyi bir uyum içerisinde olduğu anlaşılmıştır. Bununla birlikte, bu çalışma kapsamında geliştirilen AHD15’in Gülen vd. (1958)’den daha iyi asimptot özelliğine sahip olduğu anlaşılmıştır. Çünkü özellikle

göğüs çapı 70cm'den büyük değerler için Gülen (1958) üssel bir şekilde artmaya devam ederken AHD15 asimptotik bir davranış göstermiştir.



Şekil 3.7 Çalışma kapsamında geliştirilen tek girişli ağaç hacim modelinin amenajman planı ve Sun vd. (1978) ile karşılaştırılması



Şekil 3.8 Çalışma kapsamında geliştirilen çift girişli ağaç hacim modelinin Gülen (1958) ile karşılaştırılması

3.2.4 Ağaç hacim modellerinin örnek alanlara uygunluğunun testi

Denklik testi bulgularına göre, yalnızca göğüs yüksekliği çapını esas alan AHD4 ve AHD16'nın tahminleri gerçek verilerle %85 benzeşmektedir (Çizelge 3.9). Göğüs yüksekliği çapı ve toplam ağaç boyunu esas alan AHD5, AHD15 ve AHD17'nin tahminleri gerçek verilerle sırasıyla %80, %70 ve %80 benzeşmektedir. Söz konusu modellerin belirlenen benzeşmezlik oranında b_0 ve b_1 parametresi 0,05 önem düzeyinde anlamlı elde edilmiştir ($p < 0,05$).

Çizelge 3.9 Ağaç hacim modellerinin denetimi

Modeller	b_0		Bootstrap b_0		H_0	b_1		Bootstrap b_1		H_0
	Alt Limit	Üst Limit	Alt Limit	Üst Limit		Alt Limit	Üst Limit	Alt Limit	Üst Limit	
AHD4	0,715	0,975	0,80	0,95	Ret	0,85	1,15	0,91	1,12	Ret
AHD5	0,715	0,975	0,79	0,95	Ret	0,80	1,2	0,84	1,15	Ret
AHD15	0,715	0,975	0,79	0,95	Ret	0,70	1,3	0,95	1,29	Ret
AHD16	0,715	0,975	0,80	0,94	Ret	0,85	1,15	0,87	1,08	Ret
AHD17	0,715	0,975	0,80	0,94	Ret	0,80	1,2	0,90	1,17	Ret

3.3 Çap-Boy Modellerine İlişkin Bulgular

Bu çalışmada, ağaçların göğüs yüksekliği çapları ve çeşitli meşcere özellikleri kullanılarak boyları ölçülmeyen ağaçların boy değerleri tahmin edilmiştir. Bu amaçla

yedi değişik genelleştirilmiş çap-boy modelinden (ÇBM) yararlanılmıştır. Söz konusu modellerdeki üst boy açıklayıcı değişkeni modelin temsil kabiliyetini arttırmak için bu çalışmada bonitet endeksi olarak değiştirilmiştir. Parametre başlangıç değerleri çalışma kapsamında geliştirilen çözücü uygulaması ile belirlenmiştir. Model veri seti kullanılarak elde edilen parametre tahminleri ve test veri seti kullanılarak hesaplanan model performans değerlendirme değerleri (BYSAM ile karşılaştırılmasını yapmak için test veri setindeki başarısı verilmiştir) Çizelge 3.10’da verilmiştir.

Bu çalışmada, anlamsız parametre içeren ÇBM2 değerlendirmeye alınmamıştır. Kalan 6 model arasında model performans değerlendirme değerlerine göre ÇBM3 en başarılı olarak belirlenmiştir ($R_{düz}^2$: 0,8171, HKOK: 3,1228 ve AIC: 343,323). Ancak, bu çalışmada, örnek alanlarda boyları ölçülmeyen ağaçların boy tahminlerdeki hata miktarını azaltmak amacıyla model performans değerlendirme değerleri bakımından ÇBM3’ e yakın olan ve açıklayıcı değişken sayısı fazla olan ÇBM4 tercih edilmiştir ($R_{düz}^2$: 0,8154, HKOK: 3,1371 ve AIC: 344,660). Ağaçların boylarını tahmin etmek için geliştirilen BYSAM (ÇBM7)’nin parametre sayısı 31, momentum değeri 0,5, öğrenme oranı 0,1 ve ideal yakınsama değeri 0,0167’dir. ÇBM7’nin test veri setindeki $R_{düz}^2$: değeri 0,8090, HKOK değeri 3,0401 ve AIC değeri 387,466 olarak hesaplanmıştır. Test veri setindeki model performans değerlendirme ölçütlerine göre ÇBM4, ÇBM7’den daha başarılı bulunmuştur. Söz konusu modellerin test veri setindeki hata dağılımları ve tahminlere karşı gözlemleri Şekil 3.9’da verilmiştir. Çap-Boy modellerinin çap sınıflarına göre hata dağılımları Şekil 3.10’da verilmiştir


Çalışma kapsamında geliştirilen genelleştirilmiş çap-boy modeli aşağıda verilmiştir.

$$h = 1,3 + (5,476be^{0,547})(1 - e^{-0,042(N/G)^{-0,360}d})^{0,648} \quad (118)$$


Çizelge 3.10 Genelleştirilmiş çap-boy modellerine ilişkin bulgular

Modeller		Tahmin	Standart Hata	t değeri	p değeri	$R_{düz}^2$	HKOK	AIC
ÇBM1	b_1	0,022	0,002	14,483	0,000	0,5388	4,9585	470,666
ÇBM2	b_1	0,820	0,317	2,590	0,010	0,7859	3,3785	

	b_2	0,222	0,121	1,839	0,066			
	b_3	0,384	0,069	5,573	0,000			364,360
	b_4	0,174	0,055	3,163	0,002			
	b_1	-0,404	0,064	6,288	0,000			
ÇBM3	b_2	-0,014	0,003	4,346	0,000			
	b_3	0,022	0,004	6,091	0,000	0,8171	3,1228	343,323
	b_4	-0,027	0,006	4,305	0,000			
	b_5	-1,258	0,049	25,560	0,000			
	b_1	5,476	0,443	12,355	0,000			
ÇBM4	b_2	0,547	0,019	29,486	0,000			
	b_3	0,042	0,006	6,610	0,000	0,8154	3,1371	344,660
	b_4	-0,360	0,027	13,347	0,000			
	b_5	0,648	0,034	19,205	0,000			
	b_1	7,094	0,561	12,638	0,000			
ÇBM5	b_2	0,164	0,010	16,410	0,000	0,6490	4,3259	436,716
	b_3	0,654	0,027	24,492	0,000			
	b_4	-16,040	0,391	40,980	0,000			
ÇBM6	b_1	-1,466	0,105	-13,984	0,000	0,7946	3,3089	354,267
	b_2	0,179	0,010	18,639	0,000			




Şekil 3.9 Genelleştirilmiş çap-boy modellerine ilişkin hata dağılımları ve gözlem-tahmin grafikleri



Şekil 3.10 Genelleştirilmiş çap-boy modellerinin çap sınıflarına göre hata dağılımları

Çalışma kapsamında geliştirilen en başarılı genelleştirilmiş çap-boy modelinin Orman İşletme Müdürlüğü düzeyindeki ortalama hata dağılımı Şekil 3.11’de verilmiştir. Geliştirilen model orman işletme düzeyinde yaklaşık $\pm 1,5$ m hataya sahiptir. Söz konusu hata miktarı bilimsel ve pratik ormancılık çalışmaları için kabul edilebilir aralıktadır.




Şekil 3.11 Genelleştirilmiş çap-boy modellerinin orman işletme müdürlüklerine göre hata dağılımları

3.4 Meşcere Sıklığına İlişkin Bulgular

Bu çalışmada, SO-1- Curtis (1982) ve SO-2- Reineke (1933) tarafından geliştirilen meşcere sıklık ölçütleri değerlendirmeye alınmıştır. Reineke sıklık ölçütü geliştirilirken kullanılan orta çap ve ağaç sayısı verilerine ilişkin dağılım Şekil 3.12’de verilmiştir. Reineke modelinin b_1 ve b_2 parametresine ilişkin bulgular aşağıda verilmiştir.

$$N = 293632,9dg^{-1,761} \quad R_{düz}^2: 0,984 \quad (119)$$



Şekil 3.12 Kalıpsız (1963)’den elde edilen meşcere orta çapının meşcere ağaç sayısı ile ilişkisi

Meşcere modellerinin geliştirilmesinde her iki sıklık ölçütü ayrı ayrı açıklayıcı değişken olarak değerlendirilmiş ve daha başarılı sonuçlar elde edilen sıklık ölçütü ile meşcere sıklıkları belirlenmiştir. Çizelge 3.11’de örnek alanlar için hesaplanan sıklık değerleri verilmektedir. Bu çalışmada, Reinke sıklık ölçütüne göre 0.3 olan sıklık değeri Curtis sıklık ölçütünde yaklaşık olarak 3’e, 0,5 olan değer 5’e, 0,7 olan değer 7’ye ve 1,0 olan

değer 9'a karşılık gelmektedir. Dolayısıyla, bu çalışmada 9 değeri normal sıklık olarak kabul edilmiştir (Kapucu vd. 2012).

Çizelge 3.11 Örnek alanların sıklık değerlerine ilişkin bulgular

ÖAN	SO-1	SO-2	ÖAN	SO-1	SO-2	ÖAN	SO-1	SO-2
1	5,22	0,50	49	9,53	0,91	97	7,79	0,76
2	6,47	0,62	50	3,29	0,33	98	6,02	0,60
3	5,31	0,58	51	8,08	0,98	99	5,74	0,56
4	4,72	0,52	52	3,33	0,36	100	6,12	0,61
5	4,46	0,60	53	3,87	0,40	101	8,39	0,88
6	5,98	0,64	54	4,06	0,44	102	8,02	0,79
7	7,05	0,86	55	8,22	0,75	103	3,92	0,39
8	6,81	0,75	56	9,35	1,01	104	4,77	0,47
9	6,50	0,73	57	8,23	0,94	105	6,26	0,64
10	6,65	0,68	58	8,32	0,77	106	6,14	0,60
11	2,81	0,29	59	8,84	0,93	107	4,84	0,48
12	4,05	0,41	60	8,73	0,87	108	7,69	0,82
13	5,75	0,73	61	10,43	1,01	109	9,07	1,00
14	3,76	0,30	62	13,29	1,47	110	7,43	0,80
15	5,34	0,53	63	9,89	1,07	111	2,60	0,17
16	4,18	0,42	64	5,46	0,58	112	3,64	0,55
17	2,95	0,24	65	6,58	0,63	113	6,88	0,48
18	2,47	0,32	66	7,41	0,88	114	3,25	0,35
19	14,94	2,26	67	6,41	0,79	115	2,92	0,31
20	3,93	0,46	68	4,94	0,57	116	5,07	0,54
21	11,56	0,95	69	6,95	0,68	117	2,03	0,23
22	5,46	0,62	70	5,04	0,54	118	2,53	0,26
23	4,72	0,53	71	5,75	0,62	119	3,28	0,33
24	2,44	0,23	72	3,68	0,41	120	4,73	0,49
25	4,45	0,44	73	16,92	1,99	121	3,18	0,33
26	6,47	0,66	74	4,73	0,47	122	4,25	0,43
27	6,87	0,97	75	11,36	1,10	123	5,47	0,53
28	4,11	0,52	76	6,11	0,73	124	4,20	0,44
29	1,66	0,18	77	6,41	0,76	125	5,16	0,49
30	3,31	0,31	78	10,98	1,25	126	4,69	0,43
31	2,93	0,36	79	8,26	1,00	127	3,84	0,41
32	3,68	0,44	80	12,66	1,37	128	4,77	0,36
33	5,02	0,85	81	12,01	1,29	129	3,40	0,32
34	10,54	1,24	82	4,76	0,43	130	2,61	0,24
35	8,52	0,91	83	5,60	0,53	131	7,15	0,66
36	6,78	0,90	84	4,80	0,45	132	3,59	0,33
37	5,36	1,11	85	4,92	0,48	133	1,42	0,07
38	8,66	1,00	86	6,22	0,63	134	1,25	0,08
39	6,14	0,74	87	5,83	0,62	135	3,25	0,36
40	6,95	1,23	88	7,56	0,79	136	4,27	0,46
41	9,43	1,11	89	8,66	0,89	137	4,97	0,62
42	10,11	1,10	90	7,30	0,75	138	7,31	0,91
43	6,62	0,77	91	8,12	0,82	139	7,20	0,77
44	8,35	0,81	92	7,07	0,71	140	9,62	1,01
45	4,75	0,54	93	7,62	0,77	141	5,08	0,57
46	7,52	0,86	94	7,18	0,79	142	7,73	0,74


47	11,66	1,25	95	9,10	0,90	143	3,56	0,42
48	11,17	1,19	96	3,69	0,42	144	3,04	0,34

Çizelge 3.11'nin devamı

ÖAN	SO-1	SO-2	ÖAN	SO-1	SO-2	ÖAN	SO-1	SO-2
145	4,82	0,48	157	6,39	0,66	169	7,45	0,77
146	7,04	0,70	158	6,05	0,64	170	6,32	0,66
147	6,56	0,70	159	5,48	0,51	171	5,36	0,57
148	3,69	0,40	160	4,43	0,49	172	7,91	0,81
149	7,34	0,78	161	5,00	0,50	173	4,86	0,57
150	7,62	0,81	162	3,71	0,37	174	9,28	1,00
151	6,75	0,70	163	4,19	0,45	175	11,42	1,22
152	7,26	0,72	164	4,13	0,42	176	6,68	0,81
153	3,91	0,37	165	5,77	0,57	177	9,86	1,16
154	3,71	0,38	166	8,29	0,80	178	8,34	1,00
155	4,39	0,45	167	6,34	0,63	179	15,95	1,72
156	3,71	0,39	168	4,95	0,52	180	6,66	0,79


3.5 Asli Meşcere Elemanlarına İlişkin Bulgular

Bu çalışmada, saf karaçam meşcereleri örneklenmiş ve 180 noktada envanter çalışması yapılmıştır. Elde edilen verilerin meşcere yaşı değişkenine göre dağılımları Şekil 3.13'te ve bonitet, sıklık ve yaş sınıflarına göre frekansları Şekil 3.14'te verilmektedir.



Şekil 3.13 Meşcere elemanlarının meşcere yaşına göre dağılımları

Örnek alanların meşcere yaşı-bonitet-sıklık endeksi dağılımları Şekil 3.14’te verilmiştir.




Şekil 3.14 Örnek alanların yaş, bonitet ve sıklık dağılımları

3.5.1 Meşcere orta çapına ilişkin bulgular

Meşcere orta çapı tahminlerinde regresyon modelinin (RM-dg) parametreleri 0,05 önem düzeyinde anlamlı olup modelin parametre sayısı 5, $R_{düz}^2$ değeri 0,8690, HKOK değeri 0,1749 ve AIC değeri -617,7649’dır (Çizelge 3.12). BYSAM ile geliştirilen meşcere orta çapı modelinin (BYSAM-dg) parametre sayısı 31, momentum değeri 0,5, öğrenme oranı 0,001 ve logaritmik ideal yakınsama değeri 0,0139’dur. Modelin $R_{düz}^2$ değeri 0,8331, HKOK değeri 0,1790 ve AIC değeri -557,3148’dir. BYSAM-dg ve RM-dg modellerine ilişkin hata dağılımları ve gözlemlere karşı tahminler Şekil 3.15’te verilmiştir.

Çizelge 3.12 Meşcere orta çapı modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri

Modeller	Parametreler	Tahmin	Standart Hata	t	p	$R_{düz}^2$	HKOK	AIC
RM-dg	a_1	7,484	0,685	10,923	0,000	0,869	0,175	-617,765
	a_2	1,428	0,253	5,651	0,000			
	a_3	-0,527	0,137	3,833	0,000			
	a_4	23,388	3,042	7,689	0,000			
	a_5	-3,911	1,000	3,911	0,000			




Şekil 3.15 Meşcere orta çapı modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri

3.5.2 Meşcere orta boyuna ilişkin bulgular

Meşcere orta boyu tahmini için geliştirilen regresyon modelinin (RM-hg) parametreleri 0,05 önem düzeyinde anlamlı olup modelin parametre sayısı 5, $R_{düz}^2$ değeri 0,8981, HKOK değeri 0,1474 ve AIC değeri -678,4675'tir (Çizelge 3.13). BYSAM ile geliştirilen meşcere orta boyu modelinin (BYSAM-hg) parametre sayısı 36, momentum değeri 0.5, öğrenme oranı 0,001 ve logaritmik ideal yakınsama değeri 0,0097'dir. Modelin $R_{düz}^2$ değeri 0,8817, HKOK değeri 0,1415 ve AIC değeri -631,8652'dir. RM-hg ve BYSAM-hg modellerine ilişkin hata dağılımları ve gözlemlere karşı tahminler Şekil 3.16'da verilmiştir.

Çizelge 3.13 Meşcere orta boyu modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri

Modeller	Parametreler	Tahmin	Standart Hata	t	p	$R_{düz}^2$	HKOK	AIC
RM-hg	b_1	0,636	0,167	3,810	0,000	0,898	0,147	-678,467
	b_2	8,786	0,508	17,296	0,000			
	a_1	2,861	0,278	10,302	0,000			
	a_2	0,012	0,005	2,697	0,007			
	b_4	-79,406	10,606	7,487	0,000			




Şekil 3.16 Meşcere orta boyu modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri

3.5.3 Meşcere ağaç sayısına ilişkin bulgular

Meşcere ağaç sayısı tahminlerinde regresyon modelinin (RM-N) parametreleri 0,05 önem düzeyinde anlamlı olup modelin parametre sayısı 6, $R_{düz}^2$ değeri 0,8250, HKOK değeri 0,2826 ve AIC değeri -442,9230'dur (Çizelge 3.14). BYSAM ile geliştirilen ağaç sayısı modelinin (BYSAM-N) parametre sayısı 50, momentum değeri 0,5, öğrenme oranı 0,1 ve logaritmik ideal yakınsama değeri 0,0199'dur. Modelin $R_{düz}^2$ değeri 0,7708, HKOK değeri 0,2738 ve AIC değeri -366,2826'dur. RM-N ve BYSAM-N modellerine ilişkin hata dağılımları ve gözleme karşı tahminleri Şekil 3.17'de verilmiştir.

Çizelge 3.14 Meşcere ağaç sayısını modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri

Modeller	Parametreler	Tahmin	Standart Hata	t	p	$R_{düz}^2$	HKOK	AIC
RM-N	b_1	9,565	0,427	22,388	0,000	0,825	0,283	-442,923
	a_1	-1,111	0,325	3,415	0,000			
	a_2	-0,662	0,165	4,004	0,000			
	a_3	0,111	0,026	4,266	0,000			
	a_4	-0,340	0,058	5,857	0,000			
	b_3	-67,998	6,493	10,472	0,000			




Şekil 3.17 Meşcere ağaç sayısı modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri

3.5.4 Meşcere göğüs yüzeyine ilişkin bulgular

Meşcere göğüs yüzeyi tahmini için geliştirilen regresyon modelinin (RM-G) parametreleri 0,05 önem düzeyinde anlamlı olup modelin parametre sayısı 6, $R_{düz}^2$ değeri 0,957, HKOK değeri 0,122 ve AIC değeri -744,8732'dir (Çizelge 3.15). BYSAM ile geliştirilen meşcere göğüs yüzeyi modelinin (BYSAM-G) parametre sayısı 57, momentum değeri 0,5, öğrenme oranı 0,001 ve logaritmik ideal yakınsama değeri 0,0012'dir. Modelin $R_{düz}^2$ değeri 0,969, HKOK değeri 0,0856 ve AIC değeri -770,9591'dir. RM-G ve BYSAM-G modellerine ilişkin hata dağılımları ve gözlemlere karşı tahminler Şekil 3.18'de verilmiştir.

Çizelge 3.15 Meşcere göğüs yüzeyi modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri

Modeller	Parametreler	Tahmin	Standart Hata	t	p	$R_{düz}^2$	HKOK	AIC
RM-G	b_1	12,542	0,252	49,691	0,000	0,957	0,122	-744,873
	a_1	1,926	0,180	10,726	0,000			
	a_2	0,527	0,040	13,257	0,000			
	a_3	0,00004	0,000	4,0689	0,000			
	a_4	-0,0005	0,000	9,7649	0,000			
	b_3	-21,846	2,471	8,8406	0,000			




Şekil 3.18 Meşcere göğüs yüzeyi modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri

3.5.5 Meşcere hacmine ilişkin bulgular

Meşcere hacminin tahmini için geliştirilen regresyon modelinin (RM-V) parametreleri 0,05 önem düzeyinde anlamlı olup modelin parametre sayısı 6, $R_{düz}^2$ değeri 0.8481, HKOK değeri 0,3809 ve AIC değeri -335,4348'dir (Çizelge 3.16). BYSAM ile geliştirilen meşcere hacim modelinin (BYSAM-V) parametre sayısı 36, momentum değeri 0,5, öğrenme oranı 0,1 ve logaritmik ideal yakınsama değeri 0,0089'dir. Modelin $R_{düz}^2$ değeri 0,8047, HKOK değeri 0,3820 ve AIC değeri -271,6406'dür. RM-V ve BYSAM-V modellerine ilişkin hata dağılımları ve gözlemlere karşı tahminler Şekil 3.19'da verilmiştir.

Çizelge 3.16 Meşcere hacim modellerinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri


Modeller	Parametreler	Tahmin	Standart Hata	t	p	$R_{düz}^2$	HKOK	AIC
RM-V	b_1	19,732	0,808	24,412	0,000	0,848	0,381	-335,435
	a_1	2,214	0,382	5,790	0,000			
	a_2	0,129	0,054	2,400	0,000			
	a_3	0,001	0,001	1,832	0,000			
	a_4	-0,005	0,001	3,916	0,000			
	b_3	-54,144	16,150	3,352	0,000			




Şekil 3.19 Meşcere hacim modellerinin hata dağılımları ve gözlemlere karşı tahmin grafikleri

Bu çalışmada geliştirilen hem regresyon hem de Bayesçi ağ modellerinin veri sayısının az olduğu durumlardaki başarısını göstermek amacıyla I. Bonitet verileri kullanılarak aşağıdaki grafikler düzenlenmiştir. Bu çalışmada geliştirilen regresyon modelleri (RM)


ile elde edilen meşcere orta çapı (Şekil 3.20), meşcere orta boyu (Şekil 3.21), meşcere göğüs yüzeyi (Şekil 3.22), meşcere hacmi (Şekil 3.23) ve meşcere ağaç sayısına (Şekil 3.24) ait değerlerin değişik bonitet ve sıklık endekslerindeki grafikleri aşağıda verilmiştir.



Şekil 3.20 Meşcere orta çapının (cm) iyi bonitet sınıfında ($be=32m$) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi




Şekil 3.21 Meşcere orta boyunun (m) iyi bonitet sınıfında ($be=32m$) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi




Şekil 3.22 Meşçere göğüs yüzeyinin (m^2/ha) iyi bonitet sınıfında ($be=32m$) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşçerelerde yaş ve bonitet sınıfına göre (sağ) değişimi

Şekil 3.23 Meşçere hacminin (m^3/ha) iyi bonitet sınıfında ($be=32m$) yaş ve sıklık




derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşçerelerde yaş ve bonitet sınıfına göre (sağ) değişimi




Şekil 3.24 Meşcere ağaç sayısının (adet/ha) iyi bonitet sınıfında ($be=32m$) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi


BYSAM ile elde tahmin edilen meşcere orta çapı (Şekil 3.25), meşcere orta boyu (Şekil 3.26), meşcere göğüs yüzeyi (Şekil 3.27), meşcere hacmi (Şekil 3.28) ve meşcere ağaç sayısına (Şekil 3.29) ait değerlerin değişik bonitet ve sıklık endekslerindeki grafikleri aşağıda verilmiştir.




Şekil 3.25 Meşcere orta çapının (cm) iyi bonitet sınıfında ($be=32m$) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi




Şekil 3.26 Meşcere orta boyunun (m) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi



Şekil 3.27 Meşcere göğüs yüzeyinin (m^2/ha) iyi bonitet sınıfında (be=32m) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi



Şekil 3.28 Meşcere hacminin (m^3/ha) iyi bonitet sınıfında ($be=32m$) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi



Şekil 3.29 Meşcere ağaç sayısının (adet/ha) iyi bonitet sınıfında ($be=32m$) yaş ve sıklık derecelerine (sol) ve sıklık derecesi=9 (Normal Sıklık) olan meşcerelerde yaş ve bonitet sınıfına göre (sağ) değişimi

3.6 Ayrılan Meşcere Elemanlarına İlişkin Bulgular

Bu çalışmada, ayrılan meşcere hacmi belirlenirken, ilk olarak kalan meşcere orta çapı ve orta boyu ile ayrılan meşcere orta çapı ve orta boyu arasında fonksiyonel ilişkiler SPSS programının eğri uydurma (*curve estimation*) bölümündeki modeller kullanılarak araştırılmıştır. Geliştirilen fonksiyonel ilişkiden yararlanarak tahmin edilen ayrılan meşcerenin orta çap ve orta boy değerleri çalışma kapsamında geliştirilen çift girişli ağaç hacim modelinde (AHD15) yerlerine konularak ayrılan tek bir ağacın hacmi tahmin edilmiş daha sonra her bir periyotta ayrılan ağaç sayısı ile ayrılan tek ağaç hacmi çarpılarak toplam ayrılan meşcere hacmi hesaplanmıştır. Ayrılan meşcere orta çapı için S modeli en başarılı bulunmuştur. Modeldeki parametreler 0,05 önem düzeyinde anlamlıdır. Ayrılan meşcere orta boyu için Power modeli en başarılı bulunmuştur. Modeldeki parametreler 0,05 önem düzeyinde anlamlıdır.

$$dg_{ayrulan} = e^{\left(3,047 - \frac{21,208}{dg_{kalan}}\right)} \quad R_{düz}^2 = 0,401 \quad (120)$$

$$hg_{ayrulan} = 0,673(hg_{kalan})^{0,954} \quad R_{düz}^2 = 0,833 \quad (121)$$

Bu çalışma kapsamında Ankara Orman Bölge Müdürlüğünde yayılış gösteren saf karaçam meşcereleri için hem regresyon modeli (Çizelge 3.17-3.28) hem de BYSAM (Çizelge 3.29-3.40) kullanılarak sıklığa bağlı hasılat tabloları oluşturulmuştur.



Çizelge 3.17 Regresyon tekniği ile BE=32 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	9.9	10.1	893	17.4	70.2									
30	14.7	19.3	443	23.3	130.3	450	11.4	11.4	7.2	6.8	141.7	8.1	4.3	4.7
40	18.0	27.1	299	27.0	179.1	144	7.8	19.2	5.7	3.6	198.3	9.7	4.5	5.0
50	20.5	33.4	233	29.6	217.4	66	5.2	24.4	4.3	2.2	241.7	10.1	4.3	4.8
60	22.3	38.4	196	31.4	247.5	37	3.6	28.0	3.4	1.4	275.5	10.2	4.1	4.6
70	23.7	42.5	173	32.8	271.7	23	2.6	30.6	2.7	1.0	302.3	10.1	3.9	4.3
80	24.8	45.9	158	33.9	291.4	16	2.0	32.6	2.2	0.8	324.0	10.1	3.6	4.1
90	25.7	48.7	146	34.8	307.8	11	1.6	34.2	1.8	0.6	342.0	10.0	3.4	3.8
100	26.4	51.0	138	35.5	321.6	9	1.3	35.4	1.5	0.5	357.0	9.9	3.2	3.6
110	27.1	53.0	131	36.1	333.3	7	1.0	36.4	1.3	0.4	369.8	9.9	3.0	3.4
120	27.6	54.8	126	36.6	343.5	5	0.9	37.3	1.1	0.3	380.8	9.8	2.9	3.2
130	28.1	56.3	121	37.1	352.3	4	0.7	38.0	1.0	0.3	390.3	9.7	2.7	3.0
140	28.5	57.6	118	37.4	360.0	4	0.6	38.6	0.8	0.2	398.7	9.7	2.6	2.8
150	28.8	58.8	115	37.8	366.9	3	0.5	39.2	0.7	0.2	406.1	9.7	2.4	2.7

Çizelge 3.18 Regresyon tekniği ile BE=32 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	9.1	9.6	1930	35.3	164.9									
30	13.7	18.0	900	42.3	259.5	1029	21.4	21.4	11.6	5.2	280.9	7.6	8.7	9.4
40	17.0	25.1	569	46.3	326.5	332	15.2	36.6	8.2	2.7	363.1	10.1	8.2	9.1
50	19.4	30.8	421	48.9	375.1	148	10.1	46.7	5.9	1.6	421.8	11.1	7.5	8.4
60	21.3	35.4	340	50.7	411.6	80	7.0	53.6	4.3	1.1	465.2	11.5	6.9	7.8
70	22.7	39.0	291	52.1	439.9	49	5.0	58.7	3.3	0.8	498.5	11.8	6.3	7.1
80	23.8	42.0	258	53.1	462.4	33	3.7	62.4	2.6	0.6	524.8	11.9	5.8	6.6
90	24.7	44.5	235	53.9	480.7	23	2.9	65.3	2.1	0.4	546.0	12.0	5.3	6.1
100	25.5	46.7	218	54.6	495.8	17	2.3	67.6	1.7	0.4	563.4	12.0	5.0	5.6
110	26.2	48.5	204	55.1	508.6	13	1.9	69.5	1.5	0.3	578.1	12.0	4.6	5.3
120	26.7	50.0	194	55.6	519.5	11	1.5	71.0	1.2	0.2	590.6	12.0	4.3	4.9
130	27.2	51.4	185	56.0	529.0	9	1.3	72.3	1.1	0.2	601.3	12.0	4.1	4.6
140	27.6	52.6	178	56.3	537.2	7	1.1	73.4	0.9	0.2	610.6	12.0	3.8	4.4
150	28.0	53.6	172	56.6	544.4	6	1.0	74.4	0.8	0.2	618.8	12.0	3.6	4.1

Çizelge 3.19 Regresyon tekniği ile BE=32 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	8.6	9.2	3264	52.3	387.7									
30	13.1	17.2	1535	58.6	510.8	1729	31.4	31.4	15.5	3.3	542.3	5.8	17.0	18.1
40	16.4	23.9	943	62.0	586.7	592	24.3	55.7	10.0	1.8	642.4	8.7	14.7	16.1
50	18.8	29.3	678	64.2	637.7	266	16.5	72.1	7.5	1.2	709.8	10.2	12.8	14.2
60	20.6	33.5	535	65.7	674.1	143	11.4	83.5	5.3	0.8	757.6	11.0	11.2	12.6
70	22.1	36.9	448	66.8	701.5	87	8.1	91.6	3.9	0.6	793.1	11.6	10.0	11.3
80	23.2	39.7	391	67.6	722.7	57	6.1	97.7	2.9	0.4	820.4	11.9	9.0	10.3
90	24.1	42.0	350	68.2	739.6	40	4.7	102.4	2.3	0.3	842.0	12.2	8.2	9.4
100	24.9	44.0	321	68.7	753.5	30	3.7	106.1	1.9	0.2	859.5	12.3	7.5	8.6
110	25.6	45.7	298	69.2	765.0	23	3.0	109.0	1.5	0.2	874.1	12.5	7.0	7.9
120	26.1	47.1	280	69.5	774.8	18	2.5	111.5	1.3	0.2	886.3	12.6	6.5	7.4
130	26.6	48.4	266	69.8	783.1	14	2.1	113.6	1.1	0.1	896.7	12.7	6.0	6.9
140	27.0	49.5	254	70.1	790.3	12	1.7	115.3	0.9	0.1	905.6	12.7	5.6	6.5
150	27.4	50.5	244	70.3	796.7	10	1.5	116.8	0.8	0.1	913.4	12.8	5.3	6.1

Çizelge 3.20 Regresyon tekniği ile BE=32 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	8.3	9.0	4594	70.9	387.7									
30	12.7	16.7	2243	75.4	510.8	2351	38.5	38.5	16.2	3.4	549.4	7.0	17.0	18.3
40	15.9	23.1	1374	77.7	586.7	870	32.8	71.3	11.4	2.0	658.0	10.8	14.7	16.5
50	18.4	28.1	974	79.2	637.7	399	23.0	94.3	8.4	1.3	732.0	12.9	12.8	14.6
60	20.2	32.2	758	80.1	674.1	216	16.0	110.3	5.9	0.9	784.4	14.1	11.2	13.1
70	21.6	35.4	627	80.8	701.5	131	11.5	121.8	4.3	0.6	823.3	14.8	10.0	11.8
80	22.8	38.0	541	81.4	722.7	86	8.6	130.4	3.3	0.5	853.1	15.3	9.0	10.7
90	23.7	40.2	481	81.8	739.6	61	6.6	137.1	2.6	0.3	876.7	15.6	8.2	9.7
100	24.5	42.1	436	82.1	753.5	44	5.2	142.3	2.0	0.3	895.8	15.9	7.5	9.0
110	25.2	43.7	402	82.4	765.0	34	4.2	146.5	1.7	0.2	911.5	16.1	7.0	8.3
120	25.7	45.1	376	82.6	774.8	27	3.5	149.9	1.4	0.2	924.7	16.2	6.5	7.7
130	26.2	46.2	354	82.8	783.1	21	2.9	152.8	1.2	0.2	935.9	16.3	6.0	7.2
140	26.6	47.3	337	83.0	790.3	17	2.4	155.3	1.0	0.1	945.6	16.4	5.6	6.8
150	27.0	48.2	322	83.2	796.7	15	2.1	157.4	0.9	0.1	954.0	16.5	5.3	6.4

Çizelge 3.21 Regresyon tekniği ile BE=22 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	5.9	7.0	1531	11.2	20.9									
30	9.6	13.9	722	16.0	47.2	809	6.6	6.6	3.3	8.8	53.8	12.2	1.6	1.8
40	12.5	20.2	464	19.2	73.0	258	6.1	12.7	3.2	5.1	85.7	14.8	1.8	2.1
50	14.8	25.3	348	21.5	95.6	116	4.7	17.4	2.9	3.3	113.0	15.4	1.9	2.3
60	16.6	29.5	285	23.2	114.7	63	3.5	20.9	2.4	2.2	135.6	15.4	1.9	2.3
70	18.1	32.9	246	24.5	130.8	39	2.7	23.6	2.0	1.6	154.4	15.3	1.9	2.2
80	19.2	35.8	220	25.5	144.5	26	2.1	25.7	1.6	1.2	170.1	15.1	1.8	2.1
90	20.2	38.2	202	26.3	156.1	19	1.7	27.3	1.4	0.9	183.4	14.9	1.7	2.0
100	21.0	40.2	188	27.0	166.2	14	1.4	28.7	1.2	0.7	194.8	14.7	1.7	1.9
110	21.7	42.0	177	27.6	174.9	11	1.1	29.8	1.0	0.6	204.7	14.6	1.6	1.9
120	22.3	43.5	168	28.0	182.5	9	0.9	30.7	0.9	0.5	213.3	14.4	1.5	1.8
130	22.8	44.8	161	28.5	189.3	7	0.8	31.5	0.8	0.4	220.8	14.3	1.5	1.7
140	23.3	46.0	156	28.8	195.2	6	0.7	32.2	0.7	0.4	227.5	14.2	1.4	1.6
150	23.7	47.0	151	29.1	200.6	5	0.6	32.8	0.6	0.3	233.4	14.1	1.3	1.6

Çizelge 3.22 Regresyon tekniği ile BE=22 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	5.5	6.7	2898	22.1	44.7									
30	9.0	13.1	1354	28.6	89.9	1544	9.9	9.9	5.5	7.6	99.9	10.0	3.0	3.3
40	11.9	18.8	836	32.5	129.4	518	10.2	20.2	4.9	4.3	149.5	13.5	3.2	3.7
50	14.1	23.4	604	35.2	161.5	232	8.0	28.1	4.2	2.8	189.7	14.8	3.2	3.8
60	15.9	27.2	479	37.1	187.6	125	6.0	34.1	3.4	1.9	221.7	15.4	3.1	3.7
70	17.3	30.3	403	38.5	208.8	76	4.5	38.7	2.7	1.4	247.5	15.6	3.0	3.5
80	18.5	32.9	353	39.6	226.4	50	3.5	42.2	2.2	1.0	268.6	15.7	2.8	3.4
90	19.5	35.0	318	40.5	241.2	35	2.8	45.0	1.8	0.8	286.1	15.7	2.7	3.2
100	20.3	36.8	292	41.2	253.7	26	2.3	47.2	1.5	0.6	300.9	15.7	2.5	3.0
110	21.0	38.4	271	41.8	264.4	20	1.9	49.1	1.3	0.5	313.5	15.7	2.4	2.9
120	21.6	39.7	256	42.3	273.7	16	1.6	50.7	1.1	0.4	324.4	15.6	2.3	2.7
130	22.1	40.9	243	42.7	281.9	13	1.3	52.0	1.0	0.3	333.9	15.6	2.2	2.6
140	22.6	42.0	232	43.1	289.1	10	1.1	53.1	0.9	0.3	342.2	15.5	2.1	2.4
150	23.0	42.9	224	43.4	295.4	9	1.0	54.1	0.8	0.3	349.5	15.5	2.0	2.3

Çizelge 3.23 Regresyon tekniği ile BE=22 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	5.3	6.5	4442	32.4	69.3									
30	8.7	12.6	2158	39.3	129.0	2284	12.6	12.6	7.2	6.9	141.5	8.9	4.3	4.7
40	11.5	17.9	1321	43.4	177.6	837	14.5	27.1	6.1	3.8	204.6	13.2	4.4	5.1
50	13.7	22.3	938	46.0	215.6	383	11.8	38.9	5.3	2.6	254.5	15.3	4.3	5.1
60	15.5	25.8	731	47.9	245.7	207	9.0	47.8	4.2	1.8	293.5	16.3	4.1	4.9
70	16.9	28.7	605	49.2	269.8	126	6.8	54.7	3.3	1.3	324.4	16.8	3.9	4.6
80	18.1	31.1	523	50.3	289.5	83	5.3	60.0	2.7	0.9	349.4	17.2	3.6	4.4
90	19.0	33.1	465	51.1	305.8	58	4.2	64.2	2.2	0.7	370.0	17.3	3.4	4.1
100	19.8	34.8	422	51.8	319.5	43	3.4	67.6	1.8	0.6	387.1	17.5	3.2	3.9
110	20.5	36.2	389	52.4	331.3	32	2.8	70.3	1.5	0.5	401.6	17.5	3.0	3.7
120	21.1	37.5	364	52.8	341.4	25	2.3	72.7	1.3	0.4	414.0	17.6	2.8	3.5
130	21.7	38.6	343	53.2	350.2	20	2.0	74.6	1.1	0.3	424.8	17.6	2.7	3.3
140	22.1	39.5	327	53.6	357.9	17	1.7	76.3	1.0	0.3	434.2	17.6	2.6	3.1
150	22.5	40.4	313	53.9	364.7	14	1.5	77.8	0.9	0.2	442.5	17.6	2.4	3.0

Çizelge 3.24 Regresyon tekniği ile BE=22 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	5.1	6.4	5843	43.7	98.5									
30	8.4	12.2	2994	50.5	171.6	2849	13.9	13.9	8.7	6.1	185.5	7.5	5.7	6.2
40	11.2	17.3	1848	54.2	227.9	1146	18.0	31.9	7.0	3.4	259.8	12.3	5.7	6.5
50	13.4	21.5	1306	56.7	270.7	542	15.3	47.2	6.1	2.4	317.8	14.8	5.4	6.4
60	15.1	24.8	1010	58.3	303.7	297	11.9	59.1	4.8	1.6	362.8	16.3	5.1	6.0
70	16.6	27.5	829	59.6	329.8	181	9.2	68.2	3.8	1.2	398.1	17.1	4.7	5.7
80	17.7	29.8	710	60.5	350.9	119	7.1	75.4	3.0	0.9	426.3	17.7	4.4	5.3
90	18.7	31.7	626	61.2	368.3	83	5.7	81.0	2.5	0.7	449.3	18.0	4.1	5.0
100	19.5	33.3	565	61.8	382.9	61	4.6	85.6	2.0	0.5	468.4	18.3	3.8	4.7
110	20.2	34.7	518	62.3	395.2	47	3.8	89.4	1.7	0.4	484.5	18.4	3.6	4.4
120	20.8	35.8	482	62.7	405.8	36	3.1	92.5	1.4	0.4	498.3	18.6	3.4	4.2
130	21.3	36.9	453	63.1	415.0	29	2.7	95.1	1.2	0.3	510.1	18.7	3.2	3.9
140	21.8	37.8	429	63.4	423.0	24	2.3	97.4	1.1	0.3	520.4	18.7	3.0	3.7
150	22.2	38.6	409	63.7	430.1	20	2.0	99.4	0.9	0.2	529.5	18.8	2.9	3.5

Çizelge 3.25 Regresyon tekniği ile BE=12 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	2.5	4.2	3351	5.7	15.5									
30	3.9	8.7	1579	8.7	36.3	1772	1.2	1.2	2.2	8.3	37.5	3.2	1.2	1.3
40	5.4	12.9	970	11.0	57.7	609	2.3	3.5	2.3	4.7	61.2	5.7	1.4	1.5
50	6.9	16.6	696	12.7	76.8	274	2.5	6.0	2.2	3.1	82.8	7.2	1.5	1.7
60	8.1	19.6	549	14.0	93.4	147	2.2	8.2	1.9	2.2	101.6	8.0	1.6	1.7
70	9.2	22.2	459	15.0	107.6	89	1.9	10.0	1.6	1.6	117.6	8.5	1.5	1.7
80	10.2	24.3	400	15.8	119.7	59	1.6	11.6	1.4	1.2	131.3	8.8	1.5	1.6
90	11.0	26.1	358	16.5	130.1	42	1.3	12.9	1.2	1.0	143.0	9.0	1.4	1.6
100	11.7	27.7	328	17.0	139.1	31	1.1	14.1	1.0	0.8	153.2	9.2	1.4	1.5
110	12.3	29.0	304	17.5	147.0	23	1.0	15.0	0.9	0.6	162.0	9.3	1.3	1.5
120	12.9	30.2	286	17.9	154.0	18	0.8	15.8	0.8	0.5	169.8	9.3	1.3	1.4
130	13.4	31.2	271	18.3	160.1	15	0.7	16.6	0.7	0.4	176.6	9.4	1.2	1.4
140	13.8	32.1	259	18.6	165.5	12	0.6	17.2	0.6	0.4	182.7	9.4	1.2	1.3
150	14.2	33.0	249	18.8	170.4	10	0.6	17.7	0.6	0.3	188.2	9.4	1.1	1.3

Çizelge 3.26 Regresyon tekniği ile BE=12 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	2.4	4.1	5148	10.4	32.1									
30	3.7	8.2	2565	14.9	68.1	2583	1.3	1.3	3.7	7.4	69.4	1.9	2.3	2.3
40	5.2	12.1	1574	18.0	101.1	990	3.0	4.3	3.4	4.0	105.4	4.1	2.5	2.6
50	6.6	15.4	1114	20.2	128.9	460	3.4	7.7	3.1	2.6	136.6	5.6	2.6	2.7
60	7.8	18.2	864	21.9	151.9	250	3.1	10.7	2.6	1.9	162.6	6.6	2.5	2.7
70	8.9	20.5	712	23.1	170.9	152	2.7	13.4	2.2	1.4	184.3	7.3	2.4	2.6
80	9.8	22.4	612	24.1	186.8	100	2.3	15.7	1.9	1.0	202.5	7.7	2.3	2.5
90	10.6	24.0	542	24.9	200.2	70	1.9	17.6	1.6	0.8	217.8	8.1	2.2	2.4
100	11.3	25.4	490	25.6	211.7	51	1.6	19.2	1.3	0.6	230.9	8.3	2.1	2.3
110	12.0	26.6	451	26.2	221.6	39	1.4	20.6	1.2	0.5	242.2	8.5	2.0	2.2
120	12.5	27.7	420	26.6	230.2	31	1.2	21.8	1.0	0.4	252.0	8.7	1.9	2.1
130	13.0	28.6	396	27.0	237.7	25	1.0	22.8	0.9	0.4	260.6	8.8	1.8	2.0
140	13.4	29.4	376	27.4	244.4	20	0.9	23.7	0.8	0.3	268.2	8.9	1.7	1.9
150	13.8	30.1	359	27.7	250.4	17	0.8	24.6	0.7	0.3	274.9	8.9	1.7	1.8

Çizelge 3.27 Regresyon tekniği ile BE=12 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	2.4	4.0	6812	14.7	49.0									
30	3.6	7.9	3645	20.2	96.9	3167	1.3	1.3	4.9	6.7	98.3	1.4	3.2	3.3
40	5.1	11.6	2278	23.7	138.2	1367	3.5	4.8	4.3	3.6	143.0	3.4	3.5	3.6
50	6.4	14.7	1612	26.2	171.5	666	4.2	9.0	3.7	2.3	180.6	5.0	3.4	3.6
60	7.6	17.3	1243	28.0	198.4	369	4.0	13.1	3.1	1.7	211.5	6.2	3.3	3.5
70	8.7	19.4	1016	29.4	220.3	226	3.5	16.6	2.6	1.2	236.9	7.0	3.1	3.4
80	9.6	21.2	866	30.4	238.3	150	3.0	19.6	2.2	0.9	257.9	7.6	3.0	3.2
90	10.4	22.7	762	31.3	253.4	105	2.6	22.2	1.8	0.7	275.6	8.0	2.8	3.1
100	11.1	24.0	685	32.0	266.2	77	2.2	24.4	1.5	0.6	290.6	8.4	2.7	2.9
110	11.7	25.1	626	32.6	277.2	58	1.9	26.2	1.3	0.5	303.4	8.6	2.5	2.8
120	12.3	26.1	580	33.1	286.7	46	1.6	27.9	1.1	0.4	314.5	8.9	2.4	2.6
130	12.8	27.0	544	33.5	294.9	37	1.4	29.3	1.0	0.3	324.2	9.0	2.3	2.5
140	13.2	27.7	514	33.9	302.2	30	1.2	30.5	0.9	0.3	332.7	9.2	2.2	2.4
150	13.6	28.4	489	34.2	308.7	25	1.1	31.6	0.8	0.3	340.3	9.3	2.1	2.3

Çizelge 3.28 Regresyon tekniği ile BE=12 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					AYRILAN MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	2.3	3.9	8132	19.4	68.9									
30	3.6	7.7	4649	25.6	128.4	3483	1.3	1.3	6.1	6.1	129.6	1.0	4.3	4.3
40	5.0	11.2	2977	29.4	176.8	1672	3.8	5.0	5.0	3.2	181.9	2.8	4.4	4.5
50	6.3	14.2	2122	32.1	214.8	856	4.9	9.9	4.2	2.1	224.7	4.4	4.3	4.5
60	7.5	16.6	1636	33.9	244.8	486	4.8	14.7	3.5	1.5	259.5	5.7	4.1	4.3
70	8.5	18.7	1334	35.3	268.9	301	4.3	19.0	2.9	1.1	287.9	6.6	3.8	4.1
80	9.4	20.4	1134	36.4	288.6	201	3.7	22.7	2.4	0.9	311.2	7.3	3.6	3.9
90	10.2	21.8	993	37.3	304.9	141	3.2	25.8	2.0	0.7	330.7	7.8	3.4	3.7
100	10.9	23.0	889	38.0	318.6	104	2.7	28.6	1.7	0.5	347.2	8.2	3.2	3.5
110	11.6	24.1	810	38.6	330.3	79	2.3	30.9	1.4	0.4	361.2	8.6	3.0	3.3
120	12.1	25.0	748	39.1	340.4	62	2.0	32.9	1.2	0.4	373.3	8.8	2.8	3.1
130	12.6	25.8	699	39.6	349.2	49	1.8	34.7	1.1	0.3	383.9	9.0	2.7	3.0
140	13.0	26.5	659	40.0	356.9	40	1.5	36.2	0.9	0.3	393.2	9.2	2.5	2.8
150	13.4	27.2	625	40.3	363.8	34	1.4	37.6	0.8	0.2	401.3	9.4	2.4	2.7

Çizelge 3.29 Bayesçi yapay sinir ağı ile BE=32 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	6,9	9,0	3071	10,0	52,3									
30	13,1	18,9	1091	13,9	119,1	1980	43,5	43,5	11,0	10,3	162,7	26,8	4,0	5,4
40	18,2	27,0	625	16,8	176,5	466	25,2	68,7	8,3	5,1	245,2	28,0	4,4	6,1
50	22,1	33,2	449	18,8	221,7	176	14,8	83,5	6,0	2,9	305,2	27,3	4,4	6,1
60	25,1	37,9	362	20,3	257,1	87	9,5	92,9	4,5	1,8	350,0	26,6	4,3	5,8
70	27,4	41,6	312	21,5	285,2	50	6,5	99,5	3,5	1,3	384,6	25,9	4,1	5,5
80	29,3	44,6	279	22,5	307,9	33	4,8	104,2	2,7	0,9	412,1	25,3	3,8	5,2
90	30,8	47,0	257	23,2	326,6	23	3,6	107,8	2,2	0,7	434,4	24,8	3,6	4,8
100	32,1	49,0	240	23,8	342,2	16	2,8	110,7	1,8	0,5	452,8	24,4	3,4	4,5
110	33,2	50,7	228	24,4	355,4	13	2,3	112,9	1,6	0,4	468,3	24,1	3,2	4,3
120	34,1	52,2	218	24,8	366,7	10	1,9	114,8	1,3	0,4	481,6	23,8	3,1	4,0
130	34,9	53,4	210	25,2	376,6	8	1,6	116,4	1,1	0,3	492,9	23,6	2,9	3,8
140	35,6	54,5	204	25,5	385,1	6	1,3	117,7	1,0	0,3	502,9	23,4	2,8	3,6
150	36,3	55,4	198	25,8	392,7	5	1,1	118,9	0,9	0,2	511,6	23,2	2,6	3,4

Çizelge 3.30 Bayesçi yapay sinir ağı ile BE=32 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	6,5	7,9	4892	14,3	81,5									
30	12,3	16,6	1944	20,7	181,1	2948	46,2	46,2	14,6	9,4	227,2	20,3	6,0	7,6
40	16,9	23,8	1139	25,2	263,2	805	33,6	79,7	11,6	4,8	343,0	23,2	6,6	8,6
50	20,3	29,3	817	28,3	326,3	322	21,6	101,3	8,5	2,8	427,6	23,7	6,5	8,6
60	23,0	33,6	654	30,6	374,8	163	14,4	115,7	6,3	1,8	490,6	23,6	6,2	8,2
70	25,0	37,0	558	32,3	413,0	96	10,2	125,9	4,8	1,2	538,9	23,4	5,9	7,7
80	26,7	39,7	496	33,7	443,6	62	7,5	133,4	3,8	0,9	576,9	23,1	5,5	7,2
90	28,0	41,9	453	34,8	468,5	43	5,7	139,1	3,1	0,7	607,6	22,9	5,2	6,8
100	29,1	43,7	421	35,7	489,3	32	4,5	143,6	2,5	0,5	632,9	22,7	4,9	6,3
110	30,1	45,3	397	36,4	506,8	24	3,6	147,3	2,1	0,4	654,1	22,5	4,6	5,9
120	30,9	46,6	378	37,0	521,8	19	3,0	150,3	1,8	0,3	672,1	22,4	4,3	5,6
130	31,6	47,7	363	37,6	534,7	15	2,5	152,8	1,5	0,3	687,5	22,2	4,1	5,3
140	32,2	48,7	351	38,1	546,0	12	2,1	154,9	1,3	0,2	700,9	22,1	3,9	5,0
150	32,7	49,6	340	38,5	555,9	10	1,8	156,8	1,2	0,2	712,6	22,0	3,7	4,8

Çizelge 3.31 Bayesçi yapay sinir ağı ile BE=32 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	6,3	7,4	6484	18,9	108,8									
30	11,7	15,5	2808	27,7	236,3	3677	47,2	47,2	17,5	8,9	283,5	16,7	7,9	9,5
40	15,9	22,3	1697	33,6	338,5	1110	39,4	86,7	14,2	4,6	425,1	20,4	8,5	10,6
50	19,0	27,6	1230	37,6	415,5	467	27,0	113,7	11,6	3,0	529,1	21,5	8,3	10,6
60	21,3	31,6	987	40,5	474,1	243	18,7	132,3	8,6	1,9	606,4	21,8	7,9	10,1
70	23,2	34,8	842	42,7	519,8	145	13,4	145,8	6,4	1,3	665,5	21,9	7,4	9,5
80	24,6	37,4	747	44,3	556,2	95	10,0	155,7	5,0	0,9	711,9	21,9	7,0	8,9
90	25,8	39,5	681	45,7	585,8	66	7,7	163,5	4,0	0,7	749,3	21,8	6,5	8,3
100	26,8	41,3	633	46,7	610,4	49	6,1	169,6	3,2	0,5	779,9	21,7	6,1	7,8
110	27,6	42,8	595	47,6	631,0	37	4,9	174,5	2,7	0,4	805,5	21,7	5,7	7,3
120	28,3	44,0	566	48,4	648,6	29	4,1	178,6	2,3	0,4	827,2	21,6	5,4	6,9
130	28,9	45,1	543	49,0	663,8	24	3,4	182,0	1,9	0,3	845,8	21,5	5,1	6,5
140	29,5	46,1	523	49,6	677,0	19	2,9	184,9	1,7	0,2	861,9	21,5	4,8	6,2
150	29,9	46,9	507	50,0	688,6	16	2,5	187,4	1,5	0,2	876,0	21,4	4,6	5,8

Çizelge 3.32 Bayesçi yapay sinir ağı ile BE=32 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	6,1	7,1	7883	24,2	137,6									
30	11,2	14,9	3643	35,6	292,4	4240	47,0	47,0	20,2	8,5	339,4	13,9	9,7	11,3
40	15,1	21,4	2267	42,7	413,2	1376	43,2	90,2	16,8	4,5	503,4	17,9	10,3	12,6
50	17,9	26,4	1664	47,5	502,9	603	31,1	121,3	13,3	2,8	624,2	19,4	10,1	12,5
60	20,0	30,4	1343	50,8	570,5	321	22,1	143,4	9,9	1,8	714,0	20,1	9,5	11,9
70	21,7	33,5	1150	53,2	622,9	194	16,1	159,5	7,4	1,2	782,4	20,4	8,9	11,2
80	23,0	36,0	1022	55,1	664,4	128	12,2	171,7	5,8	0,9	836,1	20,5	8,3	10,5
90	24,1	38,0	932	56,6	698,1	90	9,4	181,1	4,6	0,7	879,3	20,6	7,8	9,8
100	24,9	39,7	865	57,7	726,0	66	7,5	188,7	3,7	0,5	914,6	20,6	7,3	9,1
110	25,7	41,1	814	58,7	749,3	51	6,1	194,8	3,1	0,4	944,1	20,6	6,8	8,6
120	26,3	42,3	774	59,5	769,2	40	5,1	199,8	2,6	0,3	969,0	20,6	6,4	8,1
130	26,9	43,4	742	60,2	786,3	32	4,3	204,1	2,2	0,3	990,4	20,6	6,0	7,6
140	27,3	44,3	715	60,8	801,2	27	3,6	207,7	1,9	0,2	1008,9	20,6	5,7	7,2
150	27,7	45,1	693	61,3	814,2	22	3,1	210,9	1,7	0,2	1025,0	20,6	5,4	6,8

Çizelge 3.33 Bayesçi yapay sinir ağı ile BE=22 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	4,9	6,8	3439	7,8	30,0									
30	9,3	14,3	1242	11,2	69,5	2197	18,3	18,3	5,8	9,8	87,8	20,8	2,3	2,9
40	12,8	20,6	712	13,6	105,2	530	13,3	31,6	5,4	5,7	136,8	23,1	2,6	3,4
50	15,6	25,5	511	15,4	134,2	202	8,6	40,2	4,2	3,4	174,5	23,1	2,7	3,5
60	17,7	29,3	411	16,7	157,5	100	5,9	46,1	3,2	2,1	203,6	22,6	2,6	3,4
70	19,4	32,3	353	17,7	176,3	58	4,2	50,3	2,5	1,5	226,5	22,2	2,5	3,2
80	20,8	34,7	315	18,5	191,7	37	3,1	53,4	2,0	1,1	245,0	21,8	2,4	3,1
90	21,9	36,7	289	19,2	204,4	26	2,4	55,8	1,6	0,8	260,2	21,4	2,3	2,9
100	22,8	38,4	270	19,7	215,2	19	1,9	57,7	1,3	0,6	272,9	21,1	2,2	2,7
110	23,6	39,8	256	20,2	224,4	14	1,5	59,2	1,1	0,5	283,6	20,9	2,0	2,6
120	24,3	41,0	245	20,6	232,3	11	1,3	60,5	0,9	0,4	292,8	20,7	1,9	2,4
130	24,9	42,0	236	20,9	239,1	9	1,1	61,6	0,8	0,3	300,7	20,5	1,8	2,3
140	25,4	42,9	228	21,2	245,1	7	0,9	62,5	0,7	0,3	307,7	20,3	1,8	2,2
150	25,8	43,7	222	21,4	250,5	6	0,8	63,3	0,6	0,3	313,8	20,2	1,7	2,1

Çizelge 3.34 Bayesçi yapay sinir ağı ile BE=22 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	4,6	6,0	5410	11,9	47,0									
30	8,7	12,5	2196	17,6	108,1	3214	17,3	17,3	7,8	9,1	125,5	13,8	3,6	4,2
40	12,0	18,0	1295	21,5	161,7	901	16,5	33,9	7,1	5,0	195,6	17,3	4,0	4,9
50	14,5	22,4	930	24,3	204,4	365	12,0	45,8	5,9	3,1	250,2	18,3	4,1	5,0
60	16,5	25,8	744	26,4	238,1	186	8,6	54,4	4,6	2,0	292,5	18,6	4,0	4,9
70	18,0	28,5	635	27,9	265,1	110	6,3	60,7	3,6	1,4	325,8	18,6	3,8	4,7
80	19,2	30,7	564	29,1	287,0	71	4,8	65,5	2,8	1,0	352,4	18,6	3,6	4,4
90	20,2	32,5	514	30,1	305,1	49	3,7	69,2	2,3	0,8	374,2	18,5	3,4	4,2
100	21,0	34,0	478	30,9	320,2	36	3,0	72,2	1,9	0,6	392,4	18,4	3,2	3,9
110	21,7	35,3	450	31,5	333,0	28	2,4	74,6	1,6	0,5	407,6	18,3	3,0	3,7
120	22,3	36,4	429	32,1	344,1	22	2,0	76,6	1,3	0,4	420,7	18,2	2,9	3,5
130	22,8	37,3	411	32,6	353,6	17	1,7	78,3	1,2	0,3	432,0	18,1	2,7	3,3
140	23,3	38,1	397	33,0	362,0	14	1,5	79,8	1,0	0,3	441,8	18,1	2,6	3,2
150	23,7	38,9	385	33,3	369,4	12	1,3	81,0	0,9	0,2	450,5	18,0	2,5	3,0

Çizelge 3.35 Bayesçi yapay sinir ağı ile BE=22 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	4,4	5,6	7112	16,2	63,3									
30	8,3	11,7	3148	24,2	144,0	3964	16,8	16,8	9,7	8,7	160,7	10,4	4,8	5,4
40	11,4	16,9	1921	29,6	213,0	1227	18,7	35,4	8,6	4,6	248,4	14,3	5,3	6,2
50	13,7	21,0	1397	33,2	267,2	524	14,6	50,0	7,3	2,9	317,2	15,8	5,3	6,3
60	15,5	24,2	1123	35,8	309,5	274	10,8	60,9	5,7	1,9	370,3	16,4	5,2	6,2
70	16,9	26,8	958	37,7	343,0	164	8,2	69,0	4,4	1,3	412,0	16,8	4,9	5,9
80	18,0	28,9	851	39,2	370,1	108	6,3	75,3	3,5	1,0	445,4	16,9	4,6	5,6
90	18,9	30,6	775	40,4	392,4	75	4,9	80,2	2,9	0,7	472,7	17,0	4,4	5,3
100	19,6	32,0	720	41,4	411,0	55	4,0	84,2	2,4	0,6	495,2	17,0	4,1	5,0
110	20,2	33,2	677	42,2	426,7	42	3,3	87,5	2,0	0,5	514,3	17,0	3,9	4,7
120	20,8	34,3	644	42,8	440,2	33	2,7	90,2	1,7	0,4	530,5	17,0	3,7	4,4
130	21,2	35,2	617	43,4	451,9	27	2,3	92,6	1,4	0,3	544,5	17,0	3,5	4,2
140	21,6	35,9	595	43,9	462,1	22	2,0	94,5	1,3	0,3	556,6	17,0	3,3	4,0
150	22,0	36,6	576	44,3	471,1	18	1,7	96,2	1,1	0,2	567,3	17,0	3,1	3,8

Çizelge 3.36 Bayesçi yapay sinir ağı ile BE=22 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	4,3	5,4	8599	21,3	80,9									
30	8,1	11,2	4060	31,7	181,6	4539	16,1	16,1	11,7	8,4	197,7	8,1	6,1	6,6
40	10,9	16,2	2553	38,3	265,8	1507	19,9	36,0	10,0	4,3	301,9	11,9	6,6	7,5
50	13,1	20,1	1884	42,6	331,0	670	16,5	52,5	8,5	2,8	383,5	13,7	6,6	7,7
60	14,7	23,2	1524	45,6	381,4	359	12,6	65,1	6,7	1,8	446,5	14,6	6,4	7,4
70	15,9	25,7	1306	47,8	421,1	218	9,7	74,8	5,2	1,3	495,9	15,1	6,0	7,1
80	16,9	27,7	1162	49,4	453,1	145	7,5	82,3	4,2	0,9	535,4	15,4	5,7	6,7
90	17,8	29,3	1060	50,8	479,2	102	6,0	88,3	3,4	0,7	567,6	15,6	5,3	6,3
100	18,4	30,7	984	51,8	501,0	75	4,9	93,2	2,8	0,6	594,2	15,7	5,0	5,9
110	19,0	31,9	926	52,7	519,4	58	4,0	97,2	2,3	0,5	616,6	15,8	4,7	5,6
120	19,5	32,9	881	53,4	535,1	46	3,4	100,6	2,0	0,4	635,7	15,8	4,5	5,3
130	19,9	33,8	844	54,0	548,7	37	2,9	103,5	1,7	0,3	652,1	15,9	4,2	5,0
140	20,3	34,5	814	54,6	560,5	30	2,5	105,9	1,5	0,3	666,4	15,9	4,0	4,8
150	20,6	35,2	788	55,0	571,0	25	2,1	108,0	1,3	0,2	679,0	15,9	3,8	4,5

Çizelge 3.37 Bayesçi yapay sinir ağı ile BE=12 ve SD=3 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	2,6	4,4	4564	5,7	14,0									
30	4,7	9,0	1730	8,5	31,3	2834	2,7	2,7	2,0	8,4	34,0	7,9	1,0	1,1
40	6,4	13,0	1000	10,5	47,6	730	3,3	6,0	1,9	4,6	53,6	11,2	1,2	1,3
50	7,7	16,2	715	11,9	61,3	285	2,7	8,7	1,7	3,0	70,0	12,5	1,2	1,4
60	8,7	18,8	573	12,9	72,5	143	2,1	10,8	1,4	2,1	83,3	13,0	1,2	1,4
70	9,5	20,8	490	13,8	81,7	83	1,6	12,4	1,1	1,5	94,1	13,2	1,2	1,3
80	10,2	22,5	436	14,4	89,3	54	1,3	13,7	0,9	1,1	103,0	13,3	1,1	1,3
90	10,7	23,9	399	14,9	95,8	37	1,0	14,7	0,8	0,8	110,5	13,3	1,1	1,2
100	11,2	25,0	372	15,3	101,2	27	0,8	15,5	0,6	0,7	116,7	13,3	1,0	1,2
110	11,5	26,0	351	15,7	105,9	21	0,7	16,2	0,6	0,5	122,1	13,3	1,0	1,1
120	11,9	26,9	335	16,0	110,0	16	0,6	16,8	0,5	0,4	126,8	13,2	0,9	1,1
130	12,1	27,6	322	16,2	113,5	13	0,5	17,3	0,4	0,4	130,8	13,2	0,9	1,0
140	12,4	28,3	311	16,5	116,7	11	0,4	17,7	0,4	0,3	134,4	13,2	0,8	1,0
150	12,6	28,8	302	16,6	119,5	9	0,4	18,1	0,3	0,3	137,5	13,1	0,8	0,9

Çizelge 3.38 Bayesçi yapay sinir ağı ile BE=12 ve SD=5 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	2,5	3,9	6958	9,1	21,3									
30	4,5	7,9	2990	13,9	48,9	3968	2,0	2,0	3,0	8,2	51,0	4,0	1,6	1,7
40	6,2	11,4	1801	17,2	74,5	1189	3,5	5,5	2,8	4,3	80,0	6,9	1,9	2,0
50	7,5	14,2	1303	19,5	95,8	498	3,4	8,9	2,5	2,9	104,6	8,5	1,9	2,1
60	8,5	16,5	1045	21,1	113,1	258	2,8	11,7	2,1	2,0	124,7	9,4	1,9	2,1
70	9,3	18,3	891	22,3	127,2	154	2,3	14,0	1,7	1,4	141,2	9,9	1,8	2,0
80	10,0	19,8	790	23,3	138,9	100	1,8	15,8	1,4	1,0	154,7	10,2	1,7	1,9
90	10,5	21,0	720	24,1	148,6	70	1,5	17,3	1,2	0,8	166,0	10,4	1,7	1,8
100	11,0	22,0	669	24,7	156,9	52	1,3	18,6	1,0	0,6	175,5	10,6	1,6	1,8
110	11,4	22,9	629	25,2	164,0	39	1,1	19,6	0,8	0,5	183,6	10,7	1,5	1,7
120	11,7	23,7	598	25,6	170,1	31	0,9	20,5	0,7	0,4	190,6	10,8	1,4	1,6
130	12,0	24,3	573	26,0	175,4	25	0,8	21,3	0,6	0,4	196,7	10,8	1,3	1,5
140	12,2	24,9	553	26,3	180,1	20	0,7	22,0	0,5	0,3	202,1	10,9	1,3	1,4
150	12,4	25,4	536	26,6	184,3	17	0,6	22,6	0,5	0,3	206,8	10,9	1,2	1,4

Çizelge 3.39 Bayesçi yapay sinir ağı ile BE=12 ve SD=7 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	2,4	3,6	8972	13,0	28,5									
30	4,4	7,4	4202	19,8	65,9	4770	1,7	1,7	3,9	8,1	67,7	2,6	2,2	2,3
40	6,1	10,6	2632	24,2	100,2	1570	3,6	5,4	3,6	4,2	105,6	5,1	2,5	2,6
50	7,4	13,3	1938	27,1	128,4	694	3,9	9,2	3,2	2,7	137,6	6,7	2,6	2,8
60	8,4	15,4	1566	29,2	151,2	371	3,4	12,6	2,7	1,9	163,8	7,7	2,5	2,7
70	9,2	17,1	1341	30,7	169,7	225	2,9	15,5	2,2	1,4	185,2	8,4	2,4	2,6
80	9,8	18,5	1192	31,9	184,9	149	2,4	17,9	1,8	1,0	202,8	8,8	2,3	2,5
90	10,3	19,7	1087	32,8	197,6	105	2,0	19,9	1,5	0,8	217,4	9,1	2,2	2,4
100	10,8	20,6	1009	33,6	208,3	78	1,7	21,5	1,3	0,6	229,8	9,4	2,1	2,3
110	11,1	21,5	950	34,2	217,4	60	1,4	22,9	1,1	0,5	240,4	9,5	2,0	2,2
120	11,4	22,2	903	34,7	225,3	47	1,2	24,1	0,9	0,4	249,5	9,7	1,9	2,1
130	11,7	22,8	865	35,1	232,2	38	1,0	25,2	0,8	0,4	257,4	9,8	1,8	2,0
140	11,9	23,4	834	35,5	238,2	31	0,9	26,1	0,7	0,3	264,3	9,9	1,7	1,9
150	12,2	23,8	808	35,9	243,6	26	0,8	26,9	0,6	0,3	270,5	9,9	1,6	1,8

Çizelge 3.40 Bayesçi yapay sinir ağı ile BE=12 ve SD=9 değeri için oluşturulan sıklığa bağlı hasılat tablosu

Meşcere Yaşı	KALAN MEŞCERE					ARA MEŞCERE			YILLIK CARİ ARTIM		GENEL MEŞCERE		ORTALAMA ARTIM	
	Orta Boy (m)	Orta Çap (cm)	Ağaç Sayısı (adet/ha)	Göğüs Yüzeyi (m ² /ha)	Hacim (m ³ /ha)	Ağaç Sayısı (adet/ha)	Hacim (m ³ /ha)	Hacim Toplamı (m ³ /ha)	V(m ³)	%	m ³	Ara Hasılat Yüzdesi (%)	Kalan Meşcere (m ³)	Genel Meşcere (m ³)
20	2,4	3,5	10705	17,7	36,4									
30	4,4	7,1	5334	26,4	84,4	5371	1,5	1,5	5,0	8,1	86,0	1,8	2,8	2,9
40	6,0	10,2	3451	31,7	127,8	1883	3,7	5,2	4,5	4,2	133,0	3,9	3,2	3,3
50	7,3	12,7	2584	35,1	163,2	867	4,2	9,4	3,9	2,6	172,6	5,5	3,3	3,5
60	8,2	14,7	2109	37,5	191,5	475	3,9	13,3	3,3	1,8	204,8	6,5	3,2	3,4
70	9,0	16,4	1816	39,2	214,4	293	3,3	16,6	2,7	1,3	231,0	7,2	3,1	3,3
80	9,6	17,7	1620	40,6	233,2	196	2,8	19,4	2,2	1,0	252,6	7,7	2,9	3,2
90	10,1	18,8	1480	41,6	248,8	139	2,4	21,8	1,8	0,8	270,6	8,0	2,8	3,0
100	10,5	19,8	1377	42,4	261,9	104	2,0	23,8	1,5	0,6	285,7	8,3	2,6	2,9
110	10,9	20,6	1297	43,1	273,1	80	1,7	25,5	1,3	0,5	298,6	8,5	2,5	2,7
120	11,2	21,2	1234	43,7	282,8	63	1,5	27,0	1,1	0,4	309,7	8,7	2,4	2,6
130	11,4	21,8	1182	44,2	291,2	51	1,3	28,3	1,0	0,3	319,4	8,8	2,2	2,5
140	11,7	22,4	1140	44,6	298,5	42	1,1	29,4	0,9	0,3	327,9	9,0	2,1	2,3
150	11,9	22,8	1104	44,9	305,0	36	1,0	30,4	0,8	0,3	335,4	9,1	2,0	2,2

3.7 Çap Dağılım Modellerine İlişkin Bulgular

Bu çalışmada örnek alanların çap dağılımları dört parametrelili Johnson SB olasılık yoğunluk fonksiyonu, üç parametrelili Weibull olasılık yoğunluk fonksiyonu ve BYSAM kullanılarak oluşturulmuştur. Moment ve yüzdelik yöntem ile hesaplanan Johnson SB'nin parametreleri EK-1'de verilmiştir. Yüzdelik yöntem ile hesaplanan Weibull fonksiyonunun parametreleri ise EK-2'de verilmiştir.

Johnson SB fonksiyonuna ait parametrelerin tahmin edilmesinde moment yöntemi, yüzdelik yöntemden daha başarılı bulunmuştur. Nispi sıra numaralarına göre yapılan karşılaştırmada, toplam hata değeri esas alındığında moment yönteminin nispi sıra değeri toplamı 250 ve yüzdelik yöntemin 248'dir. Ortalama hata değeri esas alındığında moment yönteminin nispi sıra değeri toplamı 266 ve yüzdelik yöntemin 232'dir. Ortalama mutlak hata değeri esas alındığında, moment yönteminin nispi sıra değeri toplamı 166 ve yüzdelik yöntemin 260'tır. Hata kareler ortalamasının karekökü esas alındığında moment yönteminin nispi sıra değeri toplamı 224 ve yüzdelik yöntemin 274'tür. Her bir hata ölçütündeki sıra numaraları toplandığında, moment yönteminin nispi sıra numarası toplamı 1130 ve yüzdelik yöntemin 1288'dir (EK-3).

Weibull fonksiyonuna ait parametrelerin tahmin edilmesinde Weibull-3 isimli yöntem en başarılı olarak bulunmuştur. Nispi sıra numaralarına göre yapılan karşılaştırmada; Toplam Hata değeri esas alındığında, Weibull-1'in nispi sıra değeri toplamı 409, Weibull-2'nin 661, Weibull-3'ün 403, Weibull-4'ün 336 ve Weibull-5'in 496'dır. Ortalama Hata değeri esas alındığında, Weibull-1'in nispi sıra değeri toplamı 294, Weibull-2'nin 488, Weibull-3'ün 311, Weibull-4'ün 772 ve Weibull-5'in 379'dır. Ortalama Mutlak Hata değeri esas alındığında, Weibull-1'in nispi sıra değeri toplamı 490, Weibull-2'nin 612, Weibull-3'ün 310, Weibull-4'ün 344 ve Weibull-5'in 606'dır. Hata Kareler Ortalamasının Karekökü esas alındığında, Weibull-1'in nispi sıra değeri toplamı 488, Weibull-2'nin 622, Weibull-3'ün 291, Weibull-4'ün 358 ve Weibull-5'in 621'dir. Her bir hata ölçütündeki sıra numaraları toplandığında, Weibull-1'in nispi sıra numarası toplamı 1680, Weibull-2'nin 2383, Weibull-3'ün 1316, Weibull-4'ün 1810 ve Weibull-5'in 2103'tür. Özetle, hata ölçütlerine göre Weibull parametre yöntemleri


başarı sırasına göre Weibull-3>Weibull-1>Weibull-4>Weibull-5>Weibull-2 şeklinde sıralanmaktadır (EK-4).

Bu çalışmada, öncelikle Johnson SB ve Weibull karşılaştırılmış ve daha başarılı olan modelin bağımlı ve bağımsız değişkenleri ile BYSAM geliştirilmiştir. Weibull parametre tahmin yöntemlerinden en başarılı olan Weibull-3 (Çizelge 3.49’da W3 ile gösterilmektedir) ile Johnson SB parametre tahmin yöntemlerinden Moment Yöntemi daha başarılı bulunmuştur. İkisi arasında yapılan karşılaştırmada Johnson SB daha başarılı elde edilmiştir. Dolayısıyla, BYSAM’de girdi ve çıktı değişkenleri olarak Johnson SB’nin bağımlı ve bağımsız değişkenleri kullanılmıştır. Çizelge 3.49’da Weibull-3, Johnson SB-Moment ve BYSAM’ın Toplam Hata, Ortalama Hata, Ortalama Mutlak Hata ve Hata Kareler Ortalamasının Kareköküne göre nispi sıra numaraları verilmiştir. Nispi sıra numaralarına göre yapılan karşılaştırmada; Toplam Hata değeri esas alındığında, Weibull-3’ün nispi sıra değeri toplamı 340, Johnson SB-Moment’in 293 ve BYSAM’nin 359’dır. Ortalama Hata değeri esas alındığında, Weibull-3’ün nispi sıra değeri toplamı 340, Johnson SB-Moment’in 293 ve BYSAM’nin 359’dur. Ortalama Mutlak Hata değeri esas alındığında, Weibull-3’ün nispi sıra değeri toplamı 313, Johnson SB-Moment’in 299 ve BYSAM’nin 370’tir. Hata Kareler Ortalamasının Karekökü esas alındığında, Weibull-3’ün nispi sıra değeri toplamı 325, Johnson SB-Moment’in 314 ve BYSAM’nin 354’tür. Her bir hata ölçütündeki sıra numarası toplandığında, Weibull-3’ün nispi sıra değeri toplamı 1307, Johnson SB-Moment’in 1210 ve BYSAM’nin 1443’tür. Özetle, çap dağılım modelleri başarı sırasına göre Johnson SB (JSB)>Weibull-3 (W3) >BYSAM şeklinde sıralanmaktadır (EK-5).


Çap dağılımlarını modellemek üzere geliştirilen Weibull-3, Johnson SB ve BYSAM’ın çalışmanın yapıldığı örnek alanlara uygunluğu Kolmogorov-Smirnov Testi ile denetlenmiştir (EK-6). Test sonuçlarına göre 0,05 önem düzeyinde Weibull-3 139, Johnson SB 177 ve BYSAM 66 örnek alan için uygun bulunmuştur.

Çalışma kapsamında geliştirilen çap dağılım modellerinin çap sınıfları düzeyindeki başarısını gösteren grafikler örnek alanların standart sapma değerleri dikkate alınarak


oluşturulmuştur. Model performans karşılaştırmasını daha iyi yansıtacağı düşüncesi ile göğüs yüksekliği çapı esas alınarak hesaplanan standart sapması yüksek, orta ve düşük olan üç örnek alan verisi ile modeller karşılaştırılmıştır (Şekil 3.30-32). Çap dağılım modellerinin çap sınıfı düzeyinde karşılaştırılması oransal birikimli mutlak hatalar üzerinden yapılmıştır. Şekil 3.30-32 incelendiğinde, JSBM'nin değişik meşcere yapılarında diğer iki modelden daha üstün olduğu görülmüştür. Çap dağılım modellerinin yaş sınıflarına ve örnek alanda ölçülen ağaç sayısına göre hata dağılımları Şekil 3.33 ve Şekil 3.34'te verilmiştir. Ayrıca rasgele seçilen iki örnek alanda çap dağılım modellerinin davranışı Şekil 3.35'te verilmiştir.




Şekil 3.30 66 numaralı örnek alanda çap dağılım modellerinin birikimli oransal mutlak hataları




Şekil 3.31 8 numaralı örnek alanda çap dağılım modellerinin birikimli oransal mutlak hataları




Şekil 3.32 132 numaralı örnek alanda çap dağılım modellerinin birikimli oransal mutlak hataları



Şekil 3.33 Çap dağılım modellerinin yaş sınıflarına göre hata dağılımları



Şekil 3.34 Çap dağılım modellerinin veri sayısına göre hata dağılımları



Şekil 3.35 Standart sapması yüksek olan iki örnek alanda çap dağılım modellerinin davranışı

3.8 Tek Ağaç Çap Artım Modeline ilişkin Bulgular

3.8.1 Tepe boyutlarına ilişkin bulgular

Bu çalışmada tepe çapı ve tepe başlangıç yükseklerinin bazı meşcere özelliklerinin fonksiyonu olarak tahmin edilmesinde üssel model yapısı kullanılmıştır. Modeller yer alan açıklayıcı değişkenler göğüs yüksekliği çapının logaritması, bonitet endeksi ve Curtis sıklık oranıdır. Tepe çapı modelinin parametrelerine ve model performans değerlendirme değerlerine ilişkin bulgular Çizelge 3.41’de, tepe başlangıç modelinin değerleri ise Çizelge 3.42’de verilmiştir.

Çizelge 3.41 Tepe çapı modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri

Parametre	Tahmin	Standart Hata	t-değeri	p-değeri	$R_{üz}^2$	HKOK
b_1	0,889	0,074	11,968	0,000	0,466	1,6
b_2	0,665	0,025	25,931	0,000		
b_3	-0,010	-0,002	6,450	0,000		
b_4	-0,011	-0,004	2,697	0,007		

Çizelge 3.42 Tepe başlangıç modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri

Parametre	Tahmin	Standart Hata	t-değeri	p-değeri	$R_{üz}^2$	HKOK
b_1	0,715	0,042	16,686	0,000	0,557	1,7
b_2	0,725	0,018	39,526	0,000		
b_3	-0,010	0,001	8,041	0,000		
b_4	-0,010	0,003	3,226	0,001		

Bu çalışmada, tek çap artım modeli üssel fonksiyon yöntemi kullanılarak geliştirilmiştir. Modelin genel orman envanterinde ölçülen değişkenlerle geliştirilebilmesi amaçlanmıştır. Bu nedenle, meşcere yaşı değişkeni ve ağacın tepe boyutları gibi değişkenler modele dahil edilmemiştir. Modelde yer alan değişkenler göğüs yüksekliği çapı, meşcere orta çapı, meşcere sıklığının logaritması, bonitet endeksi, göğüs yüzeyi ve

göğüs yüzeyinden türetilen yarışma endeksi (BAL) olarak belirlenmiştir. Test veri seti kullanılarak elde edilen model parametre tahminleri ve model performans değerlendirme değerleri Çizelge 3.43'te verilmiştir.


Çizelge 3.43 Tek ağaç çap artım modelinin model performans değerleri ile parametre tahminleri, standart hata, t ve p değerleri

Parametre	Tahmin	Standart Hata	t-değeri	p-değeri	$R_{düz}^2$	HKOK	AIC
b_1	1,8504	0.1713	10,8030	0,0000			
b_2	-0,0616	0,0038	16,0657	0,0000			
b_3	0.0385	0.0019	20.4169	0,0000			
b_4	-0,1582	0,0771	2,0510	0,0405	0,4955	0,8813	-167,137
b_5	0,0504	0,0044	11,3939	0,0000			
b_6	-0,0367	0,0025	14,7470	0,0000			
b_7	0,0149	0,0029	5,0763	0,0000			

Geliştirilen tek ağaç çap artım modeli aşağıda verilmiştir.


$$id_{10} = 1,8504 \times \exp(-0,06163d_{1,3} + 0,0385be - 0,1582 \ln(sd) + 0,0504d_g - 0,0367BAL + 0,0149G) \quad (122)$$

Tek ağaç çap artımlarını tahmin etmek için geliştirilen regresyon modelinin (RM-id) parametreleri 0,05 önem düzeyinde anlamlı olup modelin parametre sayısı 7, $R_{düz}^2$ değeri 0,4955, HKOK değeri 0,8813 ve AIC değeri -164,1371'dir. BYSAM ile geliştirilen tek ağaç çap artım modelinin (BYSAM-id) parametre sayısı 23, momentum değeri 0,05, öğrenme oranı 0,01 ve ideal yakınsama değeri 0,0574'tür. Modelin test veri setindeki düzeltilmiş belirtme katsayı değeri 0,4925, HKOK değeri 0,9167 ve AIC değeri -249.2929'dir. RM-id ve BYSAM-id'nin tahminlere karşı hata dağılımları ve gözlemlere karşı tahminler Şekil 3.36'da verilmiştir.




Şekil 3.36 Tek ağaç çap artım modellerinin çap sınıfları düzeyinde hata dağılımları ve gözlemlere karşı tahmin grafikleri


Geliştirilen tek ağaç modellerinin büyüme kanuniyetlerine uygunluğu denetlenmiş ve grafiksel olarak aşağıda verilmiştir (Şekil 3.37-3.42).




Şekil 3.37 BYSAM ile elde edilen tek ağaç çap artımlarının sıklığa göre değişimi
(Meşcere özellikleri $be=32m$, $dg=30\text{ cm}$, $BAL=40\text{ m}^2$ ve $G=30\text{ m}^2/ha$)




Şekil 3.38 BYSAM ile elde edilen tek ağaç çap artımlarının bonitete göre değişimi
(Meşcere özellikleri $sd=9$, $dg=30\text{ cm}$, $BAL=40\text{ m}^2$ ve $G=30\text{ m}^2/ha$)




Şekil 3.39 BYSAM ile elde edilen tek ağaç çap artışlarının BAL değişkenine göre değişimi (Meşcere özellikleri $be=32m$, $dg=30\text{ cm}$, $sd=9$ ve $G=30\text{ m}^2/ha$)



Şekil 3.40 RM ile elde edilen tek ağaç çap artışlarının sıklığa göre değişimi (Meşcere özellikleri $be=32m$, $dg=30\text{ cm}$, $BAL=40\text{ m}^2$ ve $G=30\text{ m}^2/ha$)



Şekil 3.41 RM ile elde edilen tek ağaç çap artımlarının bonitete göre değişimi (Meşcere özellikleri $sd=9$, $dg=30$ cm, $BAL=40$ m² ve $G=30$ m²/ha)



Şekil 3.42 RM ile elde edilen tek ağaç çap artımlarının BAL değişkenine göre değişimi (Meşcere özellikleri $be=32$ m, $dg=30$ cm, $sd=9$ ve $G=30$ m²/ha)

3.8.2 Tek ağaç çap artım modellerinin denetimi

Bu çalışma kapsamında geliştirilen tek ağaç çap artım modellerinin verilerin toplandığı alanlara uygunluğu denklik testi ile denetlenmiştir. Denklik testi bulgularına göre, RM-id ve BYSAM-id tahminleri, sırasıyla gerçek verilerle %85 ve %95 benzeşmektedir (Çizelge 3.44). Belirlenen benzeşmezlik oranında her iki modelin b_0 ve b_1 parametresi 0,05 önem düzeyinde anlamlı elde edilmiştir ($p<0,05$).

Çizelge 3.44 Tek ağaç çap artım modellerinin denetimine ilişkin bulgular

Modeller	b_0	Bootstrap b_0	H_0	b_1	Bootstrap b_1	H_0
----------	-------	-----------------	-------	-------	-----------------	-------

	Alt Limit	Üst Limit	Alt Limit	Üst Limit		Alt Limit	Üst Limit	Alt Limit	Üst Limit	
RM-id	1,87	2,53	2,11	2,29	Ret	0,85	1,15	0,92	1,11	Ret
BYSAM-id	1,87	2,53	2,10	2,18	Ret	0,95	1,05	0,986	1,04	Ret



4. TARTIŞMA

4.1 Regresyon Modellerine İlişkin Tartışma

4.1.1 Gövde çapı modelleri

Gövde çapı verileri aynı ağaç üzerinde belirli aralıklarla çok sayıda ölçüm yapılarak toplandığından dolayı, verilerin birbirini takip eden değerleri arasında doğrusal bir bağlantı oluşmakta ve dolayısıyla regresyon modellerinin temel varsayımlarından birisi olan gözlemlerin birbirinden bağımsız olması varsayımı yerine getirilememektedir. Bu problem, literatürde otokorelasyon problemi olarak adlandırılmaktadır (Kozak 1997). Otokorelasyon probleminin gövde çapı modellerinin parametre tahminleri ve dolayısıyla model sonuçları üzerinde olumsuz etkileri bulunmaktadır (Garber and Maquire 2003). Gövde çapı modellerinin geliştirilmesinde karşılaşılan otokorelasyon problemine çözüm olarak karışık etkili modelleme (Özçelik and Alkan 2020) ve otoregresif modelleme teknikleri önerilmektedir (Tasissa and Burkhart 1998, Rojo *et al.* 2005, Ung *et al.* 2013, Shahzad *et al.* 2020, Alkan and Özçelik 2020). Karışık etkili modelleme ile otokorelasyon etkisinin giderilememesi durumunda (ıraksak çözüm) otoregresif modelleme yöntemi kullanılabilir (Garber and Maquire 2003). Bu çalışmada, karışık etkili modelleme ile yakınsak çözümler elde edilemediğinden dolayı otoregresif parametreler kullanılarak otokorelasyon etkisi belirli ölçüde giderilmeye çalışılmıştır. Benzer bir bulgu Garber and Maquire (2003) tarafından raporlanmıştır. İlgili çalışmada, gövde çapı verilerinde otokorelasyon etkisinin giderilmesi konusunda karışık etkili modelleme yönteminin yeterli olmadığı otoregresif modelleme yönteminin etkili olduğunu belirtilmiştir. Literatürde model geliştirme sürecinde eğer veriler sürekli olarak belirli aralıkla ölçülmediyse sürekli otoregresif parametrelili modeller (Gregoire *et al.* 1995, Shahzad *et al.* 2020) ve eğer veriler sürekli olarak belirli aralıklarla ölçüldüyse n. dereceden otoregresif modeller (Ung *et al.* 2013, Zhao *et al.* 2019) kullanılmaktadır. Bu çalışmada elde edilen veriler gövde boyunca sabit olarak 1m ara ile elde edildiğinden dolayı her iki otoregresif model yapısının kullanılması mümkün olmuştur. Ayrıca, ağaçlar arası rekabet ve yetiştirme ortamı koşulları gibi faktörlerden kaynaklanan ağaçların gövde formlarındaki farklılar (Ung *et al.* 2013) hata terimlerinde değişen

varyans problemine ve dolayısıyla parametre tahminlerinde standart hatanın artmasına neden olabilmektedir. Bu nedenle, bu çalışmada söz konusu varyans kaynakları, n. dereceden otoregresif model, AR (1) ve n. dereceden hareketli ortalama modeli, MA (1), kombine edilerek oluşturan otoregresif hareketli ortalama modeli ile modelleme sürecine dahil edilmiştir. Bu açıdan değerlendirildiğinde, bu çalışmada elde edilen bulgular literatürle benzeşmektedir. PGÇM-4 için hesaplan Durbin-Watson (DW) katsayısı 0,73 olarak hesaplanmışken ARMA (1, 1) modeli için 2,00 olarak hesaplanmıştır. DW değerinin ikiye yakın olması bu çalışmada otokorelasyon etkisinin kontrol altına alındığını göstermektedir. Ayrıca, hem 1. ve 2. dereceden sürekli otoregresif modeli hem de 1.dereceden otoregresif hareketli ortalama modeli otoregresif parametreler içermeyen modelden daha başarılı bulunmuştur (Çizelge 3.3).

Gövde çapı modelleri model performans değerlerine göre kıyaslandığında (Çizelge 3.1) Fang *et al.* (2000) tarafından geliştirilen model (PGÇM-4), diğer parçalı gövde çapı modellerinden daha başarılı bulunmuştur. Literatürde Clark (1991) modelleri başarı ölçütlerine göre (goodness-of-fit statistics) başarılı olarak ifade edilirken bu çalışma kapsamında model parametrelerinden bazıları anlamsız elde edilmiş ve yakınsak çözümler sağlanamamıştır. Söz konusu bu modelin karmaşık yapıda olması, çalışma kapsamında geliştirilen çözücü uygulaması ile model başlangıç parametre tahminlerinin iyi bir şekilde belirlenmesini engellemiştir. Bu nedenle, Clark (1991) modeli için literatürde söz konusu denklemi kullanmış ve yakınsak çözümler üretmiş çalışmalardan parametre başlangıç değerleri sağlanmıştır. Ancak, bu çalışmada kullanılan veri aralığının kaynak alınan çalışmalarda kullanılan veri aralıklarından farklı olması uyumsuzluğa sebep olmuş ve yakınsak çözümler elde edilememiştir.

Fang *et al.* (2000) modelinin çap sınıflarına göre hata dağılımları incelendiğinde (Şekil 3.1) ince çap sınıflarında düşük hata miktarı hesaplanırken kalın çap sınıflarında yüksek hata miktarı hesaplanmıştır. Bu bulgular, genç ağaçlarda gövde boyunca çap değişiminin (çap düşüşünün) az olmasıyla ilişkili olabilmektedir. Bu bağlamda özellikle kalın çap sınıflarında gövde boyunca çap düşüşü yetiştirme ortamı koşulları ve ağaçlar arası rekabetten dolayı büyük farklılıklar gösterebilmekte ve dolayısıyla büyük hatalara sebep olabilmektedir. Benzer bulgular Garber and Maquire (2003), Diéguez-Aranda *et*

al. (2006) ve de-Miguel *et al.* (2012) tarafından bulunmuştur. Model başarısı ve güvenilirliği açısından bir değerlendirme yapıldığında, çap sınıflarına karşı hata dağılımları modelin çap düşüşündeki değişimi iyi bir şekilde açıklayabildiğini ve modelin güvenilirliği konusunda olumsuz bir durum olmadığını göstermiştir. Bağımsız veri grubu üzerinden yapılan değerlendirmede, geliştirilen gövde çapı modelinin Ankara Orman Bölge Müdürlüğü sınırları içerisinde yayılış gösteren saf karaçam meşcerelerinde kullanılabileceği sonucuna varılmıştır (Çizelge 3.5).

4.1.2 Ağaç hacim modelleri

Bu çalışma kapsamında bölgesel düzeyde ağaç hacim denklemlerinin geliştirilmesi amaçlanmıştır. Geliştirilen tek girişli ağaç hacim denklemleri hacimdeki değişkenliğin %88'ni; çift girişli ağaç hacim denklemleri hacimdeki değişkenliğin en az %94 en fazla %99'nu açıklamıştır. Diğer bir ifade ile, çift girişli modellerin hacimdeki değişkenliğin açıklanmasına olan katkısı en az %7 en çok %13 düzeyindedir. Geliştirilen bir ağaç hacim modelinin çalışma alanına uygunluğunu, diğer bir ifade ile doğruluğunu, Fonweban *et al.* (1995) model hatalarına ilişkin güven aralığı üzerinden değerlendirmektedir. Fonweban *et al.* (1995)'e göre eğer model hatalarına ilişkin hesaplanan güven aralığı sıfır değerini içeriyorsa modeller yanlı tahminler üretmektedir. Bu çalışmada geliştirilen AHD4'ün alt ve üst sınırı 0,0108-0,0900, AHD5'in -0,0373-0,0125, AHD14'ün 0,0220-0,0712 ve AHD15'in 0,0409-0,0963'tür. Bu açıdan bakıldığında AHD5 hariç diğer modeller güvenilir tahminler üretmiştir. Yukarıdaki kriterler ve model performans değerleri (Çizelge 3.7) üzerinden bir değerlendirme yapıldığında, tek girişli ağaç hacim modeli olan AHD4'ün ve çift girişli ağaç hacim modeli olan AHD15'in kullanılmasına karar verilmiştir. Söz konusu modellerin denklik testi bulgularına göre de AHD4 ve AHD15'in Ankara Orman Bölge Müdürlüğü'nde yayılış gösteren saf karaçam meşcereleri için uygun olduğu sonucuna varılmıştır (Çizelge 3.9). Bu çalışma kapsamında meşcere hacminin hesaplanmasında AHD15 modeli kullanılmıştır.

Tek ve çift girişli geleneksel ağaç hacim modelleri ince çaplı ağaçlardaki toplam hacim miktarını yeterince iyi bir şekilde açıklayabilirken özellikle kalın çap sınıflarında hatalı

tahminler üretmektedir (Şekil 3.6). Bu durumun temel sebebi gövde formlarındaki varyansın artmasıdır. Diğer bir ifade ile nayloid, silindir ve koni gövde formu kalın çap sınıflarında daha belirgin olarak izlenmektedir. Dolayısıyla geleneksel modellerden özellikle tek ağaç modelleri hem boydaki hem de gövde formlarındaki farklılıkları iyi bir şekilde yansıtamadığından dolayı gerçek hacmi açıklamada yetersiz kalmaktadır. Çift girişli geleneksel ağaç hacim modelleri genel olarak gerçek hacimlere yakın tahmin vermesine karşın söz konusu modeller ile sadece toplam ağaç hacmi elde edilebilmektedir. Daha ayrıntılı ve doğru ağaç hacim tahminlerine olan ihtiyacın artması nedeniyle günümüzde genellikle uyumlu gövde çapı-hacim modellerinden yararlanılmaktadır. (Fang *et al.* 2000, Jiang *et al.* 2005, Diéguez-Aranda *et al.* 2006, Corral-Rivas *et al.* 2007, Crecente-Campo *et al.* 2010, Tamarit Urías *et al.* 2014, Tang *et al.* 2016, Zhao *et al.* 2019, López- Martínez 2020). Bu çalışmada elde edilen bulgular literatürü desteklemektedir. Fang *et al.* (2000) tarafından geliştirilen uyumlu gövde çapı-hacim modelleri ile hem ağaçların değişik yüksekliklerindeki gövde çapları hem de ağaç hacimleri tahmin edilmiştir (AHD15). Şekil 3.6 incelendiğinde, Fang *et al.* (2000) modeli ile geliştirilen çift girişli ağaç hacim modelinin geleneksel çift girişli ağaç hacim modelinden özellikle kalın çap sınıflarında daha doğru tahminler ürettiği görülmektedir. Literatürde yer alan bazı çalışmalarda Fang *et al.* (2000)'ne (otoregresif modelleme içeriyorlar) ilişkin bulunan hata kareler ortalaması karekökü değeri (ilgili çalışmalarda, rmse olarak ifade ediliyor) bu çalışmada hesaplanan değerden yaklaşık olarak 1 cm daha küçüktür. Bu durumun olası sebepleri arasında söz konusu çalışmalarda kullanılan veri aralıklarının bu çalışmada elde edilen veri aralığında çok daha dar olmasıdır (bu çalışmada veri aralığı 85,2 cm ve HKOK değeri 1,9). Örneğin Diéguez-Aranda *et al.* (2006) çalışmasında raporlanan veri aralığı (range) 27,8 cm ve HKOK değeri 0,9 ve Tamarit *et al.* (2014)'ün 36,7 ve HKOK değeri 1,2. Ancak daha geniş veri aralığına sahip bazı çalışmalar bu çalışmada öne sürülen iddiayı desteklemektedir. Örneğin Corral-Rivas *et al.* (2007) çalışmasının veri aralığı 58,8 ve HKOK değeri 1,6, Crecente-Campo *et al.* (2010)'un veri aralığı 58,8 ve HKOK değeri 1,6'dır.

4.1.3 Genelleştirilmiş çap-boy modelleri

Farklı meşcerelerde gelişen ağaçların çap-boy ilişkisini sıklık, verim gücü, ağaçlar arası rekabet gibi meşcere ve tek ağaç özellikleri ile çok sayıda çevresel faktör kontrol etmektedir (Tewari 2007, Sharma and Zang 2004, Mensah *et al.* 2018). Ayrıca, çap-boy ilişkisini etkileyen bir meşcere özelliği bakımından benzer olan örnek alanlar başka bir meşcere özelliğine göre farklılık gösterebilmektedir. Örneğin aynı meşcere orta çapına sahip iki örnek alan meşcere sıklığı bakımından farklılık gösterebilmektedir. Tersini düşünüldüğünde de aynı sıklığa sahip meşcereler farklı orta çapa sahip olabilmektedir. Yukarıda verilen örnek üzerinden değerlendirme yapılacak olursa bu çalışmada olduğu gibi çok geniş bir alan için geliştirilen bir çap-boy modelinin meşcere sıklığını ya da sıklığın bir göstergesini (ağaç sayısı) içermesi model geçerliliğini, diğer bir ifade ile, model esnekliğini artıracaktır (Sánchez *et al.* 2003). Bu çalışmada başarı ölçütlerine göre d , dg ve be değişkenlerini içeren model çok az bir farkla d , G , N ve be değişkenlerini içeren modelden daha başarılı bulunmuş ancak özellikle meşcere yapılarındaki değişkenliği daha iyi temsil edebilmek için daha fazla meşcere değişkenini içeren modelin kullanılmasına karar verilmiştir. Literatürde bulunan bulgular bu çalışmada savunulan düşünceyi desteklemektedir. Örneğin, Schröder and González (2001) meşcere sıklığının bir göstergesi olan meşcere ağaç sayısı ya da meşcere göğüs yüzeyi değişkenlerinin çap-boy modelinin başarısına katkı sağladığını ifade etmişlerdir. Mısır (2010) meşcere ağaç sayısı ve bonitet değişkenlerinin çap-boy modelinin başarısını arttığını ifade etmiştir. Mensah *et al.* (2018) Güney Amerika’da bulunan oldukça kompleks bir yapıya sahip ormanlarda kullanılan çap-boy modelinin yetersizliğini meşcere sıklığı ve verim gücü değişkenlerini içermemesine bağlamaktadır. Seki (2020) benzer şekilde d , G , N ve üst boy açıklayıcı değişkenlerini içeren modeli en başarılı bulmuştur.

Bu çalışma kapsamında bölgesel düzeyde geliştirilen genelleştirilmiş çap-boy modelinin çap sınıflarına göre hata dağılımları modelin güvenilir olduğunu göstermektedir (Şekil 3.10). Çap sınıflarına göre hata miktarları, 0-7.9 cm için 0,32m, 8-15.9 için 0,02m, 16-23.9 için -0,27m, 24-31.9 için -0,04m, 32-39.9 için 0,5m, 40-47.9 için 0,56m, 48-55.9 için -0,37m, 56-63.9 için -0,8m ve 64-82 için 1,08m’dir. Söz konusu model tüm çap sınıflarında sıfıra yakın homojen bir dağılım göstermiştir. Benzer durum boy sınıflarında da gözlemlenmiştir. 0-3,9m boy sınıfı için hesaplanan hata miktarı 1,29m,

4-7,9 için 1,33m, 8-11,9 için 0,91m, 12-15,9 için 0,41m, 16-19,9 için -0,04m, 20-23,9 için -0,94m, 24-27,9 için -1,99m, 28-31,9 için -1,96m ve >30m için -3,20m'dir. Özellikle 30m ve üstü boy sınıfında model hata miktarı artmıştır. Bu durumun olası sebebi, iyi bonitete sahip ($h > 30$ m) meşcerelerin bu çalışmada yeterince iyi bir şekilde temsil edilememesidir ($n=40$).

4.1.4 Meşcere modelleri

Bu çalışma kapsamında çok geniş coğrafik alanda envanter çalışmaları yapılmış ve her yetiştirme ortamı yeterli düzeyde örneklenmeye çalışılmıştır. Çizelge 2.2'de verilen bilgiler incelendiğinde farklı meşcere yapılarının yeterli düzeyde temsil edildiği görülmektedir.

Envanter çalışmaları öncesi farklı yaş-sıklık-bonitete sahip alanlar orman amenajman planlarında yer alan meşcere tipleri haritaları üzerinden tespit edilmiştir. Ancak bu bölgede bazı Orman İşletme Müdürlükleri için plan yenileneme dönemi başladığı için özellikle meşcere haritalarında genç olarak görülen alanlar (Çka3) plan dönemi içerisinde bir sonraki çap sınıfına geçiş yaptığı gözlemlenmiştir (Çkb1-2-3). Bu nedenle 0-20 ($n=2$) ve 130-150 ($n=6$) yaş aralıkları bu çalışma kapsamında yeterli düzeyde temsil edilememiştir. Dolayısıyla bu çalışma kapsamında oluşturulan sıklığa bağlı hasılat tabloları kullanılırken söz konusu yaş aralıklarında verilen değerlere ihtiyatla yaklaşılması gerekmektedir.

Çalışma kapsamında geliştirilen meşcere modellerinin yaş sınıflarına göre hata dağılımları incelendiğinde açık bir trend gözlemlenmemiştir. Bu nedenle çalışma kapsamında geliştirilen sıklığa bağlı hasılat tablolarının kullanılmasında bir sakınca olmadığı görülmüştür. Ayrıca hem model performans değerleri hem de hata dağılımları üzerinden yapılan inceleme sonucunda geliştirilen modellerin farklı meşcere yapılarını iyi bir şekilde temsil edebildiği anlaşılmıştır. Dolayısıyla geliştirilen modeller silvikültürel müdahale seçeneklerinin oluşturulmasında da güvenli bir altlık olabilecek düzeydedir.

Çalışma kapsamında geliştirilen modellerinin değişik sıklık ve değişik bonitet değerleri için polimorfizm özelliği göstermesi beklenmiştir. Ayrıca, aynı bonitet endeksi fakat değişik sıklık derecesinde ve aynı sıklık derecesi fakat değişik bonitet endeksinde büyüme eğrilerinin değişken olması beklenmiştir. Sözü edilen değişkenliğin elde edilebilmesi için Gompertz modeline ilişkin her bir parametrenin bonitet ve sıklık değişkenini içermesi beklenmektedir (Yavuz vd. 2010). Ancak, bu çalışmada olduğu gibi verilerin geçici örnek alanlardan alınması yıldan yıla değişen büyüme eğrilerindeki farklılığın tam olarak ortaya konulmasını kısıtlayabilmektedir. Böyle veri tiplerinde geliştirilen modellerin parametreleri sıklık ve bonitet endeksini içerecek şekilde yeniden düzenlendiğinde modelin ideal çözüme ulaşması (bu çalışmada yakınsama limiti $1e-08$ olarak belirlenmiştir) çok zor gerçekleşmektedir (Garcia 1988). Bu nedenle Gompertz modelinin modifiye edilmesi yoluna gidilmiş ve modelin iyi bir sonuç verebilmesi için model parametre başlangıç değerleri çalışma kapsamında tasarlanan çözücü uygulaması ile elde edilmiştir. (Archontoulis and Miguez 2015). Modifiye edilen modeller ile meşcere ağaç sayısı, göğüs yüzeyi ve hacmi için oluşturulan eğrilerde bonitet ve sıklığa göre büyüme oranlarında fark edilebilir değişikliğin olduğu gözlemlenmiştir. Örneğin meşcere göğüs yüzeyi modelinin $be=32$ ve $sd=3-5-7-9$ için hesaplanan oranları sırasıyla 0,833, 0,896, 0,934 ve 0,964'tür. Meşcere hacminin hesaplanan oranları sırasıyla 0,842, 0,871, 0,890 ve 0,906'dır. Meşcere ağaç sayısının hesaplanan oranları ise 1,200, 1,265, 1,316 ve 1,353'tür.

4.1.5 Çap dağılım modelleri

Çalışma alanında aynı yaşta olan meşcerelere uygulanan farklı şiddetteki silvikültürel müdahaleler meşcere yapılarında değişiklikler meydana getirmiştir. Geliştirilen modellerden Weibull ve özellikle Johnson SB olasılık yoğunluk fonksiyonunun sonuçları incelendiğinde, söz konusu modellerin farklı orman ekosistemlerinden elde edilen değişik meşcereleri temsil etme kabiliyetinin kabul edilebilir olduğu ve güvenle kullanılabileceği anlaşılmıştır. Johnson SB-Moment ve Weibull-3 ilişkin bulgular gerçek çap dağılımlarıyla sırasıyla %98 ve %77 düzeyinde uyum içindedir (EK-6).

Bu çalışmada, genç meşcerelerdeki hata miktarı diğer yaş sınıflarına nispeten daha fazla elde edilmiştir. Bu durum belirlenen örnek alan büyüklükleri ile toplumun yeterince temsil edilememesiyle ve genç yaşlarda görülen sağa çarpık dağılımın baskın olmasıyla açıklanabilmektedir (Shiver 1988, Nord-Larsen and Cao 2006).

Diğer taraftan, bu çalışmada örnek alanda kaydedilen veri sayısı ve veri sayısına bağlı olarak artan standart sapma çap dağılım modellerindeki hata miktarını artırmıştır. Bu durum olası sebepleri arasında çalışma kapsamında 8 cm'den küçük örnek ağaçların örneklenmesi gösterilebilmektedir (Liu *et al.* 2004). Çünkü 8 cm'den küçük ağaçların örneklenen toplum içindeki yüzdesi dikkate alınacak büyüklüktedir (~%14). 8 cm'den küçük ağaçların ölçülmesinin bu çalışmada çap dağılım modelleri özelinde oluşturduğu dezavantajlardan bir diğeri silvikültürel müdahalelerin geciktirildiği ve gençleştirmeye hazırlanan sahalarda gözlemlenmiştir. Silvikültürel müdahalelerin geciktirilmesi örnek alanlarda değişik çap sınıflarından ağaçların bir arada olmasına sebep olmuş ve oldukça değişken meşcere yapıları meydana getirmiştir. Gençleştirmeye ayrılan meşcerelerde ise çok kalın çaplı ağaçların yanında 8 cm'den küçük çok sayıda ağacın olması oldukça değişken meşcere yapıları meydana getirmiştir. Diğer bir ifade ile söz konusu böyle meşcerelerde çap dağılımlarında iki tepe (peak) ve iki çukur (valley) gözlemlenmiştir (Şekil 3.35).

4.1.6 Tek ağaç çap artım modelleri

Bu çalışmada üssel model yapısı kullanılarak uzaklıktan bağımsız tek ağaç modeli geliştirilmiştir. Geliştirilen tek ağaç çap artım modelindeki açıklayıcı değişkenler BAL, ağaçların göğüs yüksekliği çapı ve yetiştirme ortamıyla ilişkili olan bonitet endeksi, sıklık oranı, meşcere orta çapı ve meşcere göğüs yüzeyidir. Bu çalışmada kullanılmasına karar verilen değişkenler, literatürde yer alan açıklayıcı değişken setiyle benzerlik göstermektedir (Monserud and Sterba 1996, Rivas *et al.* 2005, Adame *et al.* 2008a, Kuehne *et al.* 2019). Geliştirilen model, büyüme kanuniyetleri ile uyumlu bulunmuştur (Şekil 3.37). Örneğin, bonitet endeksinin etkisini gösteren parametrenin işareti pozitif ve sıklık oranının etkisini gösteren parametrenin işareti negatif elde edilmiştir (Adame

et al. 2008a). Geliştirilen üssel model, tek ağaç çap artımındaki değişkenliğin %50'sini açıklamış olup modelin kabul edilebilir doğrulukta olduğu anlaşılmıştır (Monserud and Sterba 1996). Söz konusu yüzde içerisinde her bir değişkenin katkısı değerlendirildiğinde, (Monserud and Sterba 1996) tek ağaçların göğüs yüksekliği çapı %18,38, bonitet endeksi %4,96, sıklık oranı %1,14, meşcere orta çapı %10,10, BAL yarışma endeksi %7,79 ve meşcere göğüs yüzeyi %6,35'tir. Dolayısıyla tek ağaçların çap artımı üzerinde en çok etkili olan faktörün göğüs yüksekliği çapı ve en az etkili olanın ise meşcere sıklık oranı olduğu anlaşılmıştır. Bu durum çalışma kapsamında örneklenen meşcere yapılarıyla açıklanabilmektedir. Şöyle ki, çap dağılım modelleri başlığı altında açıklandığı üzere, bu bölgede yer alan meşcereler çap çeşitliliği bakımından oldukça değişken bir yapıdadır. Dolayısıyla ağaçların boyutları ile yetiştirme ortamını kullanım potansiyeli yakından ilişkili olmaktadır (Cannell *et al.* 1984, Weiner 1990). Diğer bir ifade ile göğüs yüzeyi büyük olan ağaçlar nispeten küçük olanlardan daha çok çap artımı yapacaktır. Dolayısıyla ağaçların boyutları ile yüksek korelasyon gösteren BAL ve meşcere orta çapı değişkenleri bu çalışmada önemli açıklayıcı değişkenler olarak belirlenmiştir (Sánchez-González *et al.* 2006).

Geliştirilen modelin çap sınıflarına göre hata dağılımları incelendiğinde değişen varyans probleminin olmadığı anlaşılmıştır. Ancak, kalın çaplı meşcerelerde nispeten hata miktarı bir miktar fazla bulunmuştur. Bu durum, ilgili çaplarda artım çok yavaşladığından dolayı ağaçlardan elde edilen artım kalemleri üzerinde yapıla ölçüm hatalarıyla açıklanabilmektedir (Sánchez-González *et al.* 2006). Ayrıca, modele ilişkin koşul indeksi değerinin 38 olması bağımsız değişkenler arasındaki çoklu doğrusal bağlantının tahminler üzerinde ciddi bir etkisinin olmadığını göstermektedir. Bağımsız veri grubu üzerinden yapılan denklik testi bulguları geliştirilen çap artım modelinin gerçek verilerle iyi bir uyum içerisinde olduğunu göstermiştir (Çizelge 3.48).

4.2 Bayeşçi Yapay Sinir Ağı Modellerine İlişkin Tartışma

Son yıllarda yapay sinir ağı yaklaşımı artım ve büyüme modelleri (Vinícius Oliveira Castro *et al.* 2013, Ashraf *et al.* 2013, Hamidi *et al.* 2021), çap dağılım modelleri (Yang and Yue 2014, Diamantopoulou *et al.* 2015), çap-boy modelleri (Özçelik *et al.* 2013,

Shen *et al.* 2020, Ercanlı 2020) ve gövde çapı modelleri (Sakıcı and Özdemir 2018, Şenyurt and Ercanlı 2019, Özçelik *et al.* 2019) olmak üzere ormancılığın diğer birçok alanında (Mosaffaei and Jahani 2020, Günlü and Ercanlı 2020, Sothe *et al.* 2020) sıklıkla kullanılmaktadır. Bu çalışmada, Bayesçi yapay sinir ağı modeli (BYSAM) kullanılarak gövde çapı modeli, ağaç hacim modeli, meşcere modeli, çap sınıfı modeli ve tek ağaç çap artım modeli geliştirilmiştir.

Yapay sinir ağı modelleri değişik regresyon modelleri ile karşılaştırılmış ve genellikle iyi bir performans sergilemiştir. Örneğin, yapay sinir ağı modelleri, doğrusal regresyon modeliyle (Liu and Zang 2005), doğrusal olmayan regresyon modeliyle (Diamantopoulou *et al.* 2012), doğrusal olmayan karışık etkili modelleme tekniğiyle (Özçelik *et al.* 2019), otoregresif modelleme tekniğiyle, (Hill *et al.* 1994) ve olasılık yoğunluk fonksiyonuyla (Diamantopoulou *et al.* 2015) ile kıyaslanmış ve istatistiksel modellerden daha başarılı olduğu ifade edilmiştir.

Yapay sinir ağı modellerinin belirli varsayımlara bağlı olmaması büyük bir avantaj sağlamaktadır. Yapay sinir ağı modelleri ile kıyaslandığında, regresyon modellerinin parametre tahminleri ve sonuçları istatistiki birçok faktörden ciddi derecede etkilenmektedir (Zuur *et al.* 2010). Söz konusu faktörler arasında ormancılıkta sıklıkla karşılaşılan bağımsız değişkenler arasındaki korelasyon (çoklu doğrusal bağlantı problemi), ölçümlerin ardışık serileri arasındaki zamansal korelasyon ve populasyon ve ağaç düzeyindeki konumsal korelasyon (örneğin, çap-boy verileri) regresyon modellerinin geliştirilmesini ve kullanımını kısıtlamaktadır (Kozak 1997, Sönmez *et al.* 2009, Meng *et al.* 2012, Alkan ve Özçelik 2020). Şöyle ki, Fang *et al.* (2000) hariç diğer gövde çapı modellerine ilişkin parametreleri 0,05 önem düzeyinde istatistiksel olarak anlamsız bulunması çoklu doğrusal bağlantı probleminden kaynaklanabilmektedir.

Yapay sinir ağı modelleri artım ve büyüme çalışmaları kapsamında değerlendirdiğinde, ağ tasarımı girdi değişkeni olarak tanımladığımız açıklayıcı değişkenlere ilişkin bir çıkarım yapılamaması yapay sinir ağı modellerinin dezavantajı olarak belirtilmektedir (Yee *et al.* 1993). Ancak, açıklayıcı değişken setinin belirlenmesi (ileri aşamalı

regresyon) ya da gruplandırılması (temel bileşen analizi) gibi uygulamalar yapay sinir ağı modelleri kapsamında da kullanılabilmektedir (Maier and Dandy 2000). Bu çalışmada ileri aşamalı değişken seçimi baz alınarak her değişkenin modele katkısı ortaya konulmuştur. Bu amaçla ağın performansını küçük de olsa etkileyen ağırlıkların rasgele belirlenen başlangıç değerleri sabit tutularak (setdemorandstream, MATLAB) değişkenlerin katkısı ortaya konulmuştur. Regresyon modellerinde olduğu gibi çap artımındaki değişkenliğin açıklanmasına en çok katkıyı göğüs yüksekliği çapı (%14) ve en az katkıyı sıklık (%3) değişkenleri yapmıştır. Diğer açıklayıcı değişkenlerden meşcere göğüs yüzeyi %5, bonitet endeksi %7, meşcere orta çapı %8 ve yarışma indeksi BAL %9 katkı sağlamıştır. Burada dikkat edilmesi gereken bir diğer husus, bağımlı değişkendeki varyansı açıklamaya katkı sağlayan değişkenlerin hangi yönde katkı sağladığının belirlenmesidir. Diğer bir anlatımla, örneğin meşcere göğüs yüzeyine bonitet ve sıklık pozitif yönlü katkı sağlarken meşcere orta çapını bonitet pozitif sıklık negatif yönlü etkilemektedir. Yapay sinir ağı modellerinin parametreleri ile böyle çıkarımların yapılamaması dezavantaj gibi görünse de bu çalışmada olduğu gibi geliştirilen yapay sinir ağı modellerinin davranışları hipotetik verilerle hazırlanmış simülasyon veri setlerinde denetlenebilmektedir. Böylece hangi değişkenin ne yönde katkı sağladığı belirlenebilmektedir (Şekil 3.20-29 ve Şekil 3.37-42).

Yapay sinir ağı modelleri yeni değişkenler eklenerek kolayca geliştirilebilirken regresyon modellerinde yeni değişkenler eklenerek modellerin yakınsak çözüme ulaşması kısıtlı kalmaktadır. Çünkü, açıklayıcı değişkenler arasındaki doğrusal ilişkiler regresyon modellerinin sonuçları üzerinde ciddi etkiler yapmaktadır. Başka bir açıdan değerlendirildiğinde özellikle doğrusal olmayan modellere yeni değişkenler eklenerek modellerin yakınsak çözüm sunması başlangıç parametre değerlerinin belirlenmesindeki zorluklardan dolayı kısıtlı kalmaktadır (Desta *et al.* 1999). Diğer bir açıdan bakıldığında, bu çalışmada geliştirilen ağaç hacim modellerine ilişkin bulgulara benzer şekilde yapay sinir ağı modeline yeni değişkenlerin eklenmesi her durum için olumlu etki yapmamakta ya da hata değerlerinde önemsiz değişiklikler yapabilmektedir (Maier *et al.* 1998, Gevrey *et al.* 2003, Liu and Zhang 2005). Veriye ve amaca uygun bir yapay sinir ağı modelinin tasarlanması genellikle deneme-yanılma yoluyla gerçekleşmekte ve her problem için farklı bir ağın tasarlanmasına ihtiyaç duyulmaktadır. Burada dikkat

edilmesi gereken bir diğer husus, yapay sinir ağı modeline yeni değişkenlerin eklenmesi ya da çıkarılması ve ağı parametre (nöron ve gizli katman sayısı) sayısının artırılması ya da azaltılması, diğer bir ifade ile ağın yeterli büyüklükte tasarlanmaması, öğrenme kaybına yol açabileceği gibi aşırı uyum problemine de sebep olabilmektedir (Merkel and Hasaneur 1998).

Aşırı uyum problemi (overfitting) yapay sinir ağı modellerinin en büyük dezavantajı olarak gösterilmektedir (Özçelik *et al.* 2010). Aşırı uyum probleminden kaçınmanın yolları, verilerin dengeli bir şekilde eğitim, test ve validasyon olarak ayrılmasına, ağı yeniden birkaç kez eğitilmesine, uygun transfer fonksiyonunu seçilmesine, seçilen transfer fonksiyonuna göre verilerin ölçeklendirilmesine ($[0,1]$, $[-1, 1]$) ağı erken durdurma kriterine (early stopping), öğrenme oranının (learning rate) ve momentum değerinin belirlenmesine sıkı sıkıya bağlıdır (Maier and Dandy 2000, Diamantopoulou *et al.* 2009). Diamantopoulou *et al.* (2009) özellikle öğrenme oranının, momentum değerinin ve erken durdurma değerinin önemine vurgu yapmıştır. Yukarıda belirtilen kriterlere literatürde çok az bir çalışma değinmiştir. Bu çalışmalardan birisi olan Liu and Zang (2005) öğrenme oranının 0,1-0,7 aralığında ve momentum değerinin 0,2-0,8 aralığında belirlenmesi önermiştir. Diğer bir çalışma ise Maier and Dandy (2000) öğrenme oranının 0,1-0,95 ve momentum değerinin 0,05-0,9 aralığında bir değer seçilmesini tavsiye etmiştir. Artım ve büyüme çalışmalarında yapay sinir ağlarını konu edinen çalışmaların neredeyse tamamı yukarıdaki kriterler hakkında bilgi vermemiştir. Bu anlamda, bu çalışma literatürü hem destekler hem de katkı sağlar nitelikte bilgiler sunmaktadır. Bu çalışmada öğrenme oranı genellikle 0,01-0,1 ve momentum değeri 0,05-0,1 aralığında belirlenmiştir. Ancak en iyi çözümler genellikle öğrenme oranının 0,1 ve momentum değerinin 0,5 olduğu durumlarda elde edilmiştir. Bu çalışmada ağı performansı üzerinde etkili olduğu belirlenen bir diğer faktör transfer fonksiyonu ve verilerin ölçeklendirilmesidir. Veriler $[0, 1]$ aralığında ölçeklendirildiğinde, veriler dar bir aralık içinde yığıldığından dolayı geliştirilen ağı değerler 1'e yaklaştıkça açıklayıcı değişkenlerdeki değişikliğe tepki verememektedir. Bu nedenle bu çalışmada, verilerin daha geniş bir aralık olan $[-1, 1]$ aralığında ölçeklendirilmesi önerilmektedir. Artım ve büyüme olayları genellikle S eğrisine (sigmoid) benzediğinden dolayı söz konusu çalışmalarda lojistik ve tanjant sigmoid fonksiyonlarının kullanılması ağı performansı

olumlu yönde etkileyecektir. Ancak, lojistik sigmoid fonksiyonu çok hızlı asimptota ulaştığından dolayı artım ve büyüme konularında bu fonksiyonun kullanılması öğrenme kaybına yol açacaktır (Fathi and Shoja 2018). Bu nedenle bu çalışmada sürekli değişkenlerin modellenmesinde tanjant sigmoid transfer fonksiyonunun kullanılması önerilmektedir. Das (2013) girdi ve gizli katman arasındaki bağlantıyı sayılan fonksiyon ile gizli ve çıktı katmanı arasındaki bağlantıyı sağlayan fonksiyonun aynı olması ağ performansını olumlu etkilediğini belirtmiştir. Ancak, bu çalışmada çok genç ve 130+ yaşında meşcereler yeterince temsil edilememiş olmasına rağmen simülasyon veri seti 10 ile 150 yaş aralığında düzenlenmiştir. Bu nedenle geliştirilen bayesçi yapay sinir ağı modelinin söz konusu değerlerde iyi bir performans göstermesi için, diğer bir ifade ile, gerçeğe yakın bir enterpolasyonu sağlamak amacıyla, girdi katmanı ve gizli katman arasındaki bağlantı tanjant sigmoid ve gizli katman ile çıktı katmanı arasındaki bağlantı purelin fonksiyonu ile yapılmıştır (Maier and Dandy, 2000). Bu çalışmada ayrıca, özellikle meşcere elemanlarını modellerken kullanılan verilerin az olmasından dolayı (n=180) ağın genelleştirme kabiliyetini geliştirmek amacıyla ağ nöron sayısı değiştirilmeden tekrar tekrar eğitilmiştir (resampling). Burada temel alınan nokta, verilerin az olduğu durumlarda parametre tahminlerinin daha tutarlı olması amacıyla kullanılan bootstrap metodudur (Ivănescu *et al.* 2006). Bu çalışmada söz konusu yöntemin kullanılmasıyla, ağın genel performansı ile bireysel performansları karşılaştırılmış ve geliştirilen ağın genelleştirme kabiliyeti değerlendirilmiştir. Ağın aşırı uyum problemi göstermemesi için bu çalışmada dikkate alınan diğer husus, ağın ideal yakınsama değerine ulaştığı performans ölçütüdür. Bu amaçla ortalama mutlak hata, hata kareler toplamı ve hata kareler ortalaması kullanılabilir. Hata varyansını daha iyi yansıttığı için bu çalışmada erken durdurma kriteri olarak hata kareler ortalaması değeri dikkate alınmıştır. Bu çalışmada Bayesçi yapay sinir ağları kullanılarak geliştirilen meşcere modellerinin logaritmik ideal yakınsama değerleri; N için 0,0199, G için 0,0012, V için 0,0085, dg için 0,0139 ve hg için 0,0097'dir. Gövde çapı modeli için hesaplanan ideal yakınsama değeri 0,0047 ve tek ve çift girişli ağaç hacim modelleri için sırasıyla 0,0044 ve 0,0122 olarak hesaplanmıştır. Söz konusu değerler gelecekte yapılacak benzer çalışmalar için bir karşılaştırma kriteri niteliğindedir.

Bu çalışma basit bir yapay sinir ağı modelinin, diğer bir ifade ile tek gizli katmana (yalnızca tek ağaç çap artım modeli iki nöronlu iki gizli katmana sahip) ve genellikle 10'dan az nöron sayısına sahip yapay sinir ağı modelinin, orman hasılatı ve dendrometri alanlarındaki problemleri çözümlemesindeki gücünü göstermiştir. Regresyon modelleri ile kıyaslandığında yapay sinir ağı modelleri çok fazla parametre içermekte ancak yapay sinir ağlarının bu yapısı doğrusal olmayan problemleri çözümlemesine katkı sağlamaktadır (Guan *et al.* 1997). Başka bir açıdan bakıldığında, regresyon yöntemleri dikkate alındığında, gövde çapı için ayrı, ağaç hacmi için ayrı, meşcere elemanları ve tek ağaç artımı için ayrı ayrı çok sayıda matematiksel fonksiyona ihtiyaç duyulmakta ve her birinin çözülmesi ayrı bir süreci kapsamaktadır. Emek-zaman bakımından kıyaslandığında bu çalışmada olduğu gibi regresyon modelleriyle benzer sonuçlar üreten ve nispeten daha az emek-zaman gerektiren yapay sinir ağı modellerinin kullanılması önerilmektedir. Model kullanıcılar açısından bir değerlendirme yapıldığında ise, belli bir amaç için geliştirilen ulusal ya da bölgesel bir regresyon modelinin kullanıcının sorumlu olduğu alan için kullanılması mümkün olmadığı durumlarda yeni bir regresyon modeli geliştirmek yeni bir yapay sinir ağı modeli geliştirilmesinden çok daha zor olacaktır (Leduc 2001). Çünkü, tutarlı ve istatistiksel anlamda kabul edilebilir bir regresyon modelinin geliştirilmesi birçok istatistiksel kuralı dikkate almayı gerektirmektedir. Oysaki, yapay sinir ağı modellerinde böyle bir kısıtlamaya olmayıp dikkate alınacak kriter daha azdır.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında sıklığa bağlı hasılat tablolarının, çap dağılım modellerinin ve tek ağaç çap artım modelinin oluşturulmasında 180 adet örnek alan verisinden yararlanılmıştır. Bu örnek alanlar Ankara Orman Bölge Müdürlüğü sınırları içerisinde yayılış gösteren değişik yaş, bonitet ve sıklıktaki saf Anadolu karaçamı meşcerelerinden alınmıştır. Örneklemeye çalışmalarında dairesel örneklemeye şekli benimsenmiş olup örnek alan büyüklükleri örnek alanın kapalılık durumuna göre 200, 400, 600 ve 800 m² olarak belirlenmiştir. Ayrıca, ağaçların gövde çapları ve hacimlerini hesaplamak için değişik çap ve boy sınıflarından olmak üzere toplam 300 adet ağaç kesilmiş ve gövde boyunca 1m ara ile gövde çapları ölçülmüştür.

Gövde hacimlerinin hesaplanması için öncelikle ağaçların gerçek hacimleri hesaplanmıştır. Gerçek hacim değerleri ile ağaçların göğüs çapı ve toplam boyu arasındaki fonksiyonel ilişkiler literatürde yer alan çeşitli tek ve çift girişli regresyon denklemleri ile belirlenmiştir. Geleneksel yöntemlere ek olarak günümüzde güncel bir yöntem olan görünüşte ilişkisiz regresyon tekniği ile gövde çapları ve gövde hacimleri eş zamanlı olarak tahmin edilmiştir. Regresyon teknikleri yanında istatistiki varsayımlara bağlı olmayan yapay sinir ağları tekniği ile hem gövde çapları hem de gövde hacimleri tahmin edilmiştir. Yalnızca göğüs çapı değişkeninin fonksiyonu olarak geliştirilen ağaç hacim modellerinden tek girişli regresyon modeli ve yapay sinir ağları hacimdeki değişkenliğin sırasıyla %88 ve %90'ını açıklayabilmiştir. Geriye kalan %10-12'lik açıklanamayan kısım ağaç boyu ve gövde şekil farklılıklarından kaynaklanmıştır. Göğüs çapı ve toplam ağaç boyunun fonksiyonu olarak geliştirilen çift girişli modellerden çift girişli ağaç hacim denklemi, görünüşte ilişkisiz regresyon tekniği ve yapay sinir ağları hacimdeki değişkenliğin sırasıyla %94, %99 ve %85'ni açıklamıştır. Geliştirilen çift girişli modeller arasında görünüşte ilişkisiz regresyon tekniği ile elde edilen tahminlerin orman amenajman planlarının yapım sürecinde ve dikili satış uygulamalarında kullanılması önerilmektedir.

Gövdenin farklı yüksekliklerdeki gövde çapları çeşitli parçalı gövde çapı modelleri ve yapay sinir ağları tahmin edilmiştir. Parçalı gövde çapı modelleri arasında Fang *et al.*

(2000) tarafından geliştirilen model en başarılı bulunmuş ve bu model gövde çapındaki değişkenliğin %95’ni açıklamıştır. Gövde çapı verilerinin birbirini takip eden değerleri arasında doğrusal korelasyon olması nedeniyle modellerde otokorelasyon problemi oluşmaktadır. Bu problemin neden olduğu olumsuz etkilerin kontrol altına alınması amacıyla AR, MA ve CAR gibi otoregresif parametreler modelleme sürecine dahil edilmiştir. Gövde çapı verilerinin birbirini takip eden değerleri arasındaki korelasyonun etkisi AR parametresi ile çevresel koşulların ve ağaçlar arası rekabetin gövde şekillerinde meydana getirdiği değişkenliğin etkisi MA parametresi ile modellemeye dahil edildiğinde otokorelasyon problemi kontrol altına alınmış (Durbin-Watson değeri 2,00) ve böylece gövde çapındaki değişkenliğin %98’ni açıklanabilmiştir. Yapay sinir ağları da oldukça yüksek bir açıklayıcılığa sahip olmasına rağmen ($R_{düz}^2$ 0,95) regresyon tekniği daha başarılı bulunmuştur.

Ağaç boyları, tek ağaç ve meşcere düzeyinde geliştirilen büyüme modellerinde en önemli değişkenlerden birisidir. Bu değişkenin ölçülmesinin zaman alıcı olması ve göğüs çapına göre nispeten fazla ölçüm hatasının yapılabilmesi nedeniyle, ağaç boyları genelleştirilmiş çap-boy modelleri kullanılarak tahmin edilmektedir. Bu tez çalışmasında çeşitli genelleştirilmiş çap-boy modeli geliştirilmiştir. Ağaç boylarındaki değişkenliğin %82’sini açıklayabilen en başarılı çap-boy modeli göğüs çapı, meşcere ağaç sayısı, meşcere göğüs yüzeyi ve bonitet endeks değişkenini içermektedir. Aynı değişkenlerden faydalanarak geliştirilen yapay sinir ağı modeli ise ağaç boylarındaki değişkenliğin %81’ni açıklayabilmiştir. Bu tez çalışmasında geliştirilen genelleştirilmiş çap-boy modelinin çeşitli meşcere özelliklerini içermesi ve çap sınıfları düzeyinde homojen bir hata dağılımına sahip olması nedeniyle temsil kabiliyetinin iyi olduğu ve Ankara Orman Bölge Müdürlüğü sınırları içerisinde yayılış yapan Anadolu karaçamına ilişkin araştırmalarda güvenle kullanılabileceği sonucuna varılmıştır.

Bu tez çalışmasında doğrusal olmayan regresyon tekniği ve yapay sinir ağları ile meşcere büyüme modelleri geliştirilmiştir. Meşcere büyüme modellerinin geliştirilmesi amacıyla kullanılan verilerin geçici örnek alanlardan alınması modellerin genelleştirilebilmesini kısıtlamıştır. Özellikle örnekleme çalışmalarında yeterince temsil edilemeyen genç ve yaşlı meşcerelerde model hataları nispeten fazla elde edilmiştir.

Değişik yetişme ortamı koşullarında gelişen meşcere gelişimlerin daha doğru bir şekilde ortaya konulabilmesi amacıyla Genelleştirilmiş Cebirsel Fark Yaklaşımına dayalı doğrusal olmayan modelleme tekniğinin kullanılması gerekmektedir. Ancak bu modeller periyodik ve devamlı örnekleme verilerine ihtiyaç duymaktadır. Bu nedenle ülkemizde periyodik veya devamlı deneme alanlarının tesis edilmesi büyük önem arz etmektedir. Asli meşcere elemanlarının tahmininde doğrusal olmayan regresyon tekniği ve yapay sinir ağları birbirine yakın başarı ölçütlerine sahip olmasına karşın doğrusal olmayan regresyon tekniği daha başarılı bulunmuştur. Doğrusal olmayan regresyon tekniği orta çap, orta boy, ağaç sayısı, göğüs yüzeyi ve hacimdeki değişkenliğin sırasıyla %87, %90, %83, %96 ve %85’ni açıklayabilirken yapay sinir ağları sırasıyla %83, %88, %77, %97 ve %84’nü temsil edebilmiştir.

Normal ve Sıklığa Bağlı Tablolarında bir meşcereden elde edilebilecek servet meşcerenin bir hektarı için elde edilebilmektedir. Ancak, çap sınıfları düzeyinde meşcere servetinin elde edilebilmesi için çap dağılım modellerine ihtiyaç duyulmaktadır. Bu tez çalışmasında çap dağılımlarının modellenmesinde Weibull ve Johnson SB olasılık yoğunluk fonksiyonları ile yapay sinir ağları kullanılmıştır. Bu modeller arasında Johnson SB dağılım fonksiyonu Kolmogorov-Smirnov testine göre örneklenen 180 noktanın 177’sine uygun bulunmuştur. Ancak model karşılaştırılmalarının aynı temelde yapılabilmesi için yapay sinir ağları yönteminde girdi değişkeni olarak regresyon tekniğinde kullanılan değişkenlerin kullanılması yapay sinir ağlarının başarısını düşürmüştür. Benzer konularda yapılacak çalışmalarda bu tez çalışmasında kullanılan değişkenlere ek olarak hektardaki ağaç sayısı gibi başka değişkenlerin kullanılması model başarısını arttıracakı düşünülmektedir.

Tek ağaç modelleri meşcere büyüme modelleri ve çap dağılım modellerine kıyasla meşcere gelişimlerini daha ayrıntılı bir şekilde açıklayabilmektedir. Bu tez çalışmasında üssel modelleme tekniği ve yapay sinir ağları kullanılarak uzaklıktan bağımsız tek ağaç çap artım modelleri geliştirilmiştir. Çap artımlarının tahmin edilmesinde açıklayıcı (girdi) değişkenler olarak göğüs çapı, meşcere orta çapı, meşcere sıklığının logaritması, bonitet endeksi, göğüs yüzeyi ve göğüs yüzeyinden türetilen yarışma endeksi (BAL) kullanılmış ve çap artımındaki değişkenliğin %50’si açıklanabilmiştir. Geliştirilen çap

artım modellerinin ap sınıflarına gre hata daėılımlarında bir trend gzlemlenmemiř ve denklik testine gre ap artım tahminlerinin gerek verilerle %85 (ssel model)-%95 (yapay sinir aėları) benzer olduėu sonucuna varılmıřtır. Bu nedenle alıřma kapsamında geliřtirilen ap artım modellerinin gvenle kullanılabileceėi sonucuna varılmıřtır.

Regresyon tekniklerinin gvenle kullanılabilmesi iin bazı istatistiki varsayımların yerine getirilmesi gerekmektedir. Ancak, artım ve byme alıřmalarında elde edilen verilerin zamansal ya da konumsal olarak birbiri ile iliřkili olması temel varsayımlardan birisi olan verilerin birbirinden baėımsız olması ilkesinin ihlal edilmesine sebep olmaktadır. Bu durumun model tahminleri zerindeki olumsuz etkilerini minimize etmek amacıyla karıřık etkili ve otoregresif modelleme tekniėi nerilmektedir. Ancak, sz konusu yntemlerin her rnek durumda otokorelasyon problemini tam anlamıyla zebildiėi konusunda bir fikir birliėi olmamakla birlikte karıřık etkili ve otoregresif modellerin geliřtirilmesi ve bulgularının yorumlanması gl bir istatistik alt yapısı da gerektirmektedir. Bu kısıtlar nedeniyle, gnmzde istatistiki varsayımlara baėlı olmayan, verilerin iřlenmesinde herhangi bir matematiksel modele ihtiya duymayan ve karmařık problemlerin zmnde olduka bařarılı olan yapay sinir aėları tekniėi nem kazanmaktadır.

Yapay sinir aėlarının bařarısı ve rnekleri temsil edebilme potansiyeli birok kriterin gereėince belirlenmesine baėlı olarak deėiřmektedir. rneėin, aėa hacimlerinin ve asli meřcere elemanlarının tahminlerinde modelin S eėrisine benzer bir davranıř gstermesi beklenmektedir. Bunu saėlayabilmek amacıyla, ėrenmek srecini kontrol eden faktrlerden nron sayısı, gizli katman sayısı, verilerin ayırımı, verilerin leklendirilmesi, eėitim fonksiyonu, ėrenme oranı, momentum terimi, transfer fonksiyonu, reglarizasyon parametresi, erken durdurma kriterinin dikkatle deėerlendirilmesi aėın iyi bir genelleřtirme kabiliyeti kazanması ve ařırı uyum problemine sahip olmaması bakımından olduka nem arz etmektedir. Bununla birlikte, aėın yeterli byklkte tasarlanması, diėer bir ifade ile en uygun girdi, nron ve gizli katman sayısının belirlenmesi, aėın bařarısı bakımından dikkate alınması gereken kriterlerdendir. Bu alıřmada genellikle az sayıda nron ($n < 10$) kullanılmıř, 1 gizli katman yeterli grlmř ve veriler rasgele ayrılacak řekilde bir dzenleme yapılmıřtır.

Bayesçi eğitim fonksiyonu esas alınarak genellikle 0,001 ile 0,1 arasında değişen öğrenme oranı ve 0,05 ile 1 arasında değişen momentum değeri belirlenmiştir. Verilerin katmanlar arası geçişini kontrol eden transfer fonksiyonları olarak giriş katmanında tanjant sigmoid ve çıkış katmanında linear fonksiyon kullanılmıştır. Regülerizasyon parametresi olarak karesel ortalama hata belirlenmiştir. Eğitim süreci içerisinde validasyon veri seti kullanılarak hesaplanan karesel ortalama hata miktarı 0 (sıfır)'ı aştığında ağın erken durdurulması sağlanmış ve optimal çözümler üretebilecek nöron ve iterasyon sayısı otomatik olarak yeniden belirlenmiştir. Bu tez çalışmasında elde edilen bulgular geliştirilen yapay sinir ağı modellerinin regresyon teknikleri ile yarışabilecek düzeyde olduğunu göstermiştir. Ayrıca, yapay sinir ağı modeline iyi bir genelleştirme kabiliyeti kazandırılmış ve böylece tasarlanan ağın büyüme kanuniyetlerine uygun davranışlar sergilemesi sağlanmıştır. Sonuç olarak bu tez çalışmasında elde edilen bulgular gelecek çalışmalar için önerilen parametre uyarlamalarının güvenle kullanılabileceğini göstermiştir. Tasarlanan ağlar ile elde edilen bulguların tablolar halinde (örneğin bu çalışmada üretilen hasılat tabloları gibi) uygulamacılara sunulması ile yapay sinir ağlarının kullanım etkinliği artırılabilir.

KAYNAKLAR

- Adame, P., Hynynen, J., Canellas, I. and del Río, M. 2008a. Individual-tree diameter growth model for rebollo oak (*Quercus pyrenaica* Willd.) coppices. *Forest Ecology and Management*, 255(3-4), 1011-1022.
- Adame, P., del Río, M. and Canellas, I. 2008b. A mixed nonlinear height-diameter model for pyrenean oak (*Quercus pyrenaica* Willd.). *Forest Ecology and Management*, 256(1-2), 88-98.
- Akalp, T. 1978. Türkiye'deki doğu ladini (*Picea orientalis* Lk. Carr) ormanlarında hasılat araştırmaları. Doktora Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Alemdağ, İ.Ş. 1962. Türkiye'deki kızılçam ormanlarının gelişimi, hasılat ve amenajman esasları. Ormancılık Araştırma Enstitüsü, Teknik Bülten No: 11, Ankara, 160 s.
- Alemdağ, İ.Ş. 1967. Türkiye'deki sarıçam ormanlarının kuruluşu, verim gücü ve bu ormanların işletilmesinde takip edilecek esaslar. Ormancılık Araştırma Enstitüsü Teknik Bülten No: 20, Ankara, 160s.
- Alkan, O. 2019. Toros göknarı (*Abies cilicica* Carr.) meşcereleri için gövde çapı, çap-boy, çap dağılım ve bonitet endeks modellerinin geliştirilmesi. Doktora Tezi, Isparta Uygulamalı Bilimler Üniversitesi Lisansüstü Eğitim Enstitüsü. Isparta.
- Alkan, O. and Özçelik, R. 2020. Stem taper equations for diameter and volume predictions of *Abies cilicica* Carr. in the Taurus Mountains, Turkey. *Journal of Mountain Science*, 17(12), 3054-3069.
- Archontoulis, S.V. and Miguez, F.E. 2015. Nonlinear regression models and applications in agricultural research. *Agronomy Journal*, 107(2), 786-798.
- Asan, Ü. 1984. Kazdağı göknarı (*Abies equi-trojani* Aschers et Sinten) ormanlarının hasılat ve amenajman esasları üzerine araştırmalar. İstanbul Üniversitesi Orman Fakültesi Dergisi, B Serisi, Cilt 43, Sayı 1-2, s. 31-44, İstanbul.
- Asan, Ü. 2013. Ormancılığımızın sektörel planlaması 50. yıla girerken orman amenajmanı temel kavramlarında ortaya çıkan yeni yaklaşımlar. Ormancılıkta Sektörel Planlamanın 50. Yılı Uluslararası Sempozyumu, 26-28, Antalya.
- 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. 2004. Değişik yaşlı doğu kayını (*Fagus orientalis* Lipsky.) ormanlarında tek ağaç büyümesi. İstanbul Üniversitesi Orman Fakültesi Dergisi, 54(2), 51-70.
- Başkent, E.Z. 2005. Orman amenajman planlarının ekosistem tabanlı ve çok amaçlı planlanması (ETÇAP) ve uygulanmasına yönelik eylemler. Türk Ormancılığında Uluslararası Süreçte Acil Eyleme Dönüştürülmesi Gereken Konular-Mevzuat ve Yapılanmaya Yansımaları, Orman Mühendisleri Odası Sempozyumu, 22-24, Antalya.
- Batu, F. ve Kapucu, F. 1995. Doğu Karadeniz Bölgesi kızıl ağaç meşcerelerinde bonitet endeksi ve hasılat tablosunun düzenlenmesi. I. Ulusal Karadeniz Ormancılık Kongresi Bildirileri, 4. Cilt, s. 349-362.
- Bilgili, F. 2007. Titrek kavak (*Populus tremula* L.) meşcereleri için normal hasılat tablosu. Yüksek Lisans Tezi, Karadeniz Tek Üniversitesi, Fen Bilimleri Enstitüsü, 71 s., Trabzon.

- Bilgili, M. 2011. The use of artificial neural networks for forecasting the monthly mean soil temperatures in Adana, Turkey. Turkish Journal of Agriculture and Forestry, 35(1), 83-93.
- Birler, A.S. 1983. I-214 Melez kavağı plantasyonlarında hasılat araştırmaları. Kavak ve Hızlı Gelişen Yabancı Tür Orman Ağaçları Enstitüsü Yayını, No: 125.
- Birler, A.S. ve Yüksel, Y. 1983. Sahil çamı ağaçlandırma meşcerelerinde hasılat araştırması. Kavak ve Hızlı Gelişen Yabancı Tür Orman Ağaçları Enstitüsü Yayınları, No: 25
- Birler, A.S. Koçar, S., Avcıoğlu, E., Diner, A., Gürses, K. ve Gülbaba, A.G., 1995. Ökaliptus ağaçlandırmalarında hacim ve kuru madde hasılatı. Kavak ve Hızlı Gelişen Yabancı Tür Orman Ağaçları Enstitüsü Yayını, No: 66.
- 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 işletme şefliği içerisindeki meşcereler için çap dağılım modellerinin geliştirilmesi. Çankırı Karatekin Üniversitesi, Fen Bilimleri Enstitüsü, 85 s. Çankırı.
- Bolat, İ. and Ercanlı, İ. 2016. Using artificial neural network in describing diameter distribution in an even-aged forest. International Forestry Symposium (pp. 7-10), Kastamonu.
- Bond, B.J., Czarnomski, N.M., Cooper, C., Day, M.E. and Greenwood, M.S. 2007. Developmental decline in height growth in Douglas-fir. Tree Physiology, 27(3), 441-453.
- Borders, B.E., Souter, R.A., Bailey, R.L. and Ware, K.D. 1987. Percentile-based distributions characterize forest stand tables. Forest Science, 33(2), 570-576.
- Burkhart, H.E. and Tomé, M. 2012. Modeling forest trees and stands. Springer Science & Business Media.
- Cañadas, N., García, C. and Montero, G. 1999. Relación altura-diámetro para *Pinus pinea* L. en el Sistema Central. In Congreso de Ordenación y Gestión Sostenible de Montes, Santiago de Compostela (Vol. 1, pp. 139-153).
- Cannell, M.G.R., Rothery, P. and Ford, E.D. 1984. Competition within stands of *Picea sitchensis* and *Pinus contorta*. Annals of Botany, 53(3), 349-362.
- Carus, S. 1996. Aynı yaşlı doğu kayını (*Fagus orientalis* Lipsky.) meşcerelerinde çap dağılımının bonitet ve yaşa göre değişimi. İstanbul Üniversitesi Orman Fakültesi Dergisi, 46(2), 171-181.
- Carus, S. 1998. Aynı yaşlı doğu kayını (*Fagus orientalis* Lipsky) ormanlarında artım ve büyüme. Doktora Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, 356 s., İstanbul,
- Carus, S. 2004. Isparta-Sütçüler yöresi boylu ardıç (*Juniperus excelsa* Bieb.) meşcerelerinde artım ve büyüme. Türkiye Ormancılık Dergisi, 5(1), 19-36.
- Carus, S. ve Çiçek, E. 2007. Adapazarı-Süleymaniye dışbudak plantasyonlarında (*Fraxinus angustifolia* Vahl.) tek ağaçlar için bir çap artım modeli. Türkiye Ormancılık Dergisi, 8(1), 34-48.
- Carus, S. ve Çatal, Y. 2008. Kızılçam (*Pinus brutia* Ten.) meşcerelerinde 7-ağaç örnek nokta yöntemiyle meşcere ağaç sayısının çap basamaklarına dağılımının belirlenmesi. Süleyman Demirel Üniversitesi Orman Fakültesi Dergisi, 9(2), 158-169.

- Castaño-Santamaría, J., Crecente-Campo, F., Fernández-Martínez, J.L., Barrio-Anta, M. and Obeso, J.R. 2013. Tree height prediction approaches for uneven-aged beech forests in northwestern Spain. *Forest Ecology and Management*, 307, 63-73.
- Castedo Dorado, F., Dieguez-Aranda, U., Barrio Anta, M., Sánchez Rodríguez, M. and von Gadow, K. 2006. A generalized height-diameter model including random components for radiata pine plantations in northwestern Spain. *Forest Ecology and Management*, 229(1-3), 202-213.
- Castellanos, A., Martinez Blanco, A. and Palencia, V. 2007. Applications of radial basis neural networks for area forest, 14, 218-222.
- Che, S., Tan, X., Xiang, C., Sun, J., Hu, X., Zhang, X., Duan, A. and Zhang, J. 2019. Stand basal area modelling for Chinese fir plantations using an artificial neural network model. *Journal of Forestry Research*, 30(5), 1641-1649.
- Clark, A. 1991. Stem profile equations for southern tree species (Vol. 282). Southeastern Forest Experiment Station.
- Clutter, J.L. and Bennett, F.A. 1965. Diameter distributions in old-field slash pine plantations. Georgia Forest Research Council, Report No: 13.
- Corne, S.A., Carver, S.J., Kunin, W.E., Lennon, J.J. and van Hees, W.W.V. 2004. Predicting forest attributes in southeast Alaska using artificial neural networks. *Forest Science*, 50(2), 259-276.
- Corral-Rivas, J.J., Diéguez-Aranda, U., Rivas, S.C. and Dorado, F.C. 2007. A merchantable volume system for major pine species in El Salto, Durango (Mexico). *Forest Ecology and Management*, 238(1-3), 118-129.
- Crecente-Campo, F., Soares, P., Tomé, M. and Diéguez-Aranda, U. 2010. Modelling annual individual-tree growth and mortality of scots pine with data obtained at irregular measurement intervals and containing missing observations. *Forest Ecology and Management*, 260(11), 1965-1974.
- Curtis, R.O., Clendenen, G.W. and DeMars, D.J. 1981. A new stand simulator for coast Douglas-fir: DFSIM user's guide. General Technical Report PNW-128. USDA Forest Service, Pacific Northwest Research Station, Portland, OR.
- Curtis, R.O. 1982. A simple index of stand density for Douglas-fir. *Forest Science*, 28(1), 92-94.
- Çatal, Y. 2009. Batı Akdeniz Bölgesi kızılçam (*Pinus brutia* Ten.) meşcerelerinde artım ve büyüme. Doktora Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta, 281 s.
- Çatal, Y., Eler, Ü., Carus, S., Özçelik, R. ve Alkan, O. 2014. Tek ağaçta çap artımı tahmini üzerine artımın ölçüldüğü periyot süresi ve meşcere sıklığının etkisinin incelenmesi. II. Ulusal Akdeniz Orman ve Çevre Sempozyumu, 170-178 s., Isparta
- Çatal, Y. ve Güneş, S. 2016. Isparta yöresi kızılçam meşcerelerinde çap dağılımının örnek alan ağaç sayısına göre modellenmesi. *Turkish Journal of Forestry*, 17(2), 166-173.
- Dal, E. 2019. Kastamonu Yöresi sarıçam meşcerelerinde çap dağılımlarının modellenmesi. Yüksek Lisans Tezi, Kastamonu Üniversitesi Fen Bilimleri Enstitüsü, 189s., Kastamonu.
- Das, S.K. 2013. Artificial neural networks in geotechnical engineering: modeling and application issues. *Metaheuristics in Water, Geotechnical and Transport Engineering*, 45, 231-267.

- de-Miguel, S., Mehtatalo, L., Shater, Z., Kraid, B. and Pukkala, T. 2012. Evaluating marginal and conditional predictions of taper models in the absence of calibration data. *Canadian Journal of Forest Research*, 42(7), 1383-1394.
- Desta, F., Mac Siurtain, M.P. and Colbert, J.J. 1999. Parameter estimation of nonlinear growth models in forestry. *Silva Fennica*, 33(4), 327-336.
- Diamantopoulou, M.J. 2006. Tree-bole volume estimation on standing pine trees using cascade correlation artificial neural network models. *Agricultural Engineering International: CIGR Journal*.
- Diamantopoulou, M.J., Milios, E., Doganos, D. and Bistinas, I. 2009. Artificial neural network modeling for reforestation design through the dominant trees bole-volume estimation. *Natural Resource Modeling*, 22(4), 511-543.
- Diamantopoulou, M.J. and Milios, E. 2010. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. *Biosystems engineering*, 105(3), 306-315.
- Diamantopoulou, M.J. and Özçelik, R. 2012. Evaluation of different modeling approaches for total treeheight estimation in Mediterranean Region of Turkey. *Forest Systems*, 21(3), 383-397.
- Diamantopoulou, M.J., Özçelik, R., Crecente-Campo, F. and Eler, Ü. 2015. Estimation of Weibull function parameters for modelling tree diameter distribution using least squares and artificial neural networks methods. *Biosystems Engineering*, 133, 33-45.
- Diéguez-Aranda, U., Castedo-Dorado, F., Álvarez-González, J.G. and Rojo, A. 2006. Compatible taper function for Scots pine plantations in northwestern Spain. *Canadian Journal of Forest Research*, 36(5), 1190-1205.
- Doğdaş, İ. 2014. Burdur-Ağlasun Yöresi kızılçam ormanlarında meşçere ağaç sayısı, hacim ve hacim artımının çap basamaklarına dağılımının modellenmesi. Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, 109 s., Isparta.
- Durkaya, B., 2004. Zonguldak Orman Bölge Müdürlüğü sarıçam (*Pinus sylvestris* L.)-Uludağ göknarı (*Abies bornmülleriana* Mattf.) - doğu kayını (*Fagus orientalis* Lipsky) karışık meşçerelerinde artım-büyüme ilişkileri. Doktora Tezi, Z.K.Ü Fen Bilimleri Enstitüsü, 226 s., Bartın.
- Eler, Ü. 1986. Türkiye’de boylu ardıç (*Juniperus excelsa* Bieb.) ormanlarında hasılat araştırmaları. Ormancılık Araştırma Enstitüsü Teknik Bülten No: 192, Ankara.
- Elmas, Ç. 2013. Yapay sinir ağları (kuram, mimari, eğitim, uygulama). Seçkin Yayıncılık, ISBN: 975 347 612 4.
- Elizondo, D., Hoogenboom, G. and McClendon, R. W. 1994. Development of a neural network model to predict daily solar radiation. *Agricultural and Forest Meteorology*, 71(1-2), 115-132.
- Ercanlı, İ. 2003. Artvin orman işletme şefliği sınırları içerisindeki doğu ladini (*Picea orientalis* (L.) Link.) meşçerelerinde sıklığa bağlı hasılat tablosunun düzenlenmesi, Yüksek Lisans Tezi, KTÜ Fen Bilimleri Enstitüsü, 103 s., Trabzon.
- Ercanlı, İ., Keleş, S., Sivrikaya, F., Çakır, G., Günlü, A., Karahalil, U., Kadioğulları, A., Başkent, E.Z. ve Köse, S. 2007a. Sarıçam (*Pinus sylvestris* L.) meşçereleri için yöresel (Yalnızçam ve Uğurlu orman işletme şeflikleri) sıklığa bağlı hasılat tablosunun düzenlenmesi. Süleyman Demirel Üniversitesi Orman Fakültesi Dergisi, 2, 78-101.

- Ercanlı, İ., Altun, L., Yılmaz, M., Usta, A., Yılmaz, F. ve Günlü, A. 2007b. Sinop yöresi ağaçlandırmalarına ilişkin yöresel sıklığa bağlı hasılat tablosunun düzenlenmesi. Düzce Üniversitesi Ormancılık Dergisi, 3(1), 35-55.
- Ercanlı, İ., Sivrikaya, F., Keleş, S. ve Günlü, A. 2007c. Sarıçam (*Pinus sylvestris* L.) meşcerelerinin hacim artımının meşcere yaşı, bonitet endeksi ve sıklık derecesine göre değişimi. Kastamonu Üniversitesi Orman Fakültesi Dergisi, 7(1), 24-37.
- Ercanlı, İ. 2010. Trabzon ve Giresun Orman Bölge Müdürlükleri sınırları içerisinde yer alan doğu ladini (*Picea orientalis* (L.) Link)-sarıçam (*Pinus sylvestris* L.) karışık meşcerelerine ilişkin büyüme modelleri. Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, 351 s., Trabzon.
- Ercanlı, İ. ve Yavuz, H. 2010. Doğu ladini (*Picea orientalis* (L.) Link)-sarıçam (*Pinus sylvestris* L.) karışık meşcerelerinde çap dağılımlarının olasılık yoğunluk fonksiyonları ile belirlenmesi. Kastamonu Üniversitesi Orman Fakültesi Dergisi, 10(1), 68-83.
- Ercanlı, İ., Bolat, F. ve 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, 119-126, Artvin, Turkey
- Ercanlı, İ., Kahriman, A. ve Bolat, F. 2015. Applications of artificial neural network for predicting the relationships between height and age for oriental beech. In The 10th international beech symposium (pp. 1-6), Kastamonu.
- Ercanlı, İ., Günlü, A., Şenyurt, M., Bolat, F. ve Kahriman, A. 2016. 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. Forest Engineering and Technologies FETEC.
- Ercanlı, İ., Günlü, A., Şenyurt, M. and Keleş, S. 2018. Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey. Forest Ecosystems, 5(1), 1-12.
- Ercanlı, İ. 2018. Tarsus yöresi Anadolu karaçamı ağaçlarında hacim tahminlerinin yapay sinir ağları ile elde edilmesi. Anadolu Orman Araştırmaları Dergisi, 4(1), 25-37.
- Ercanlı, İ. 2020. Innovative deep learning artificial intelligence applications for predicting relationships between individual tree height and diameter at breast height. Forest Ecosystems, 7, 1-18.
- Erkan, N. 1995. Kızılçamda meşcere gelişiminin simülasyonu. Doktora Tezi, İ.Ü. Fen Bilimleri Enstitüsü, 124 s.
- Evcimen, B.S. 1963. Türkiye sedir ormanlarının ekonomik önemi, hasılat ve amenajman esasları. T.C. Tarım Bakanlığı, Orman Genel Müdürlüğü Yayını, No: 355/16, İstanbul, 199 s.
- Fang, Z., Borders, B.E. and Bailey, R.L. 2000. Compatible volume-taper models for loblolly and slash pine based on a system with segmented-stem form factors. Forest Science, 46(1), 1-12.
- Farely, B.G. and Clark W.A. 1954. Simulation of self-organizing systems by digital computers. IEEE Transactions of Professional Group of Information Theory, PGIT-4, 76-84.
- Fathi, E. and Shoja, B. M. 2018. Deep neural networks for natural language processing. In Handbook of statistics (Vol. 38, pp. 229-316). Elsevier.

- Fırat, F. 1972. Orman hasılat bilgisi. İstanbul Üniversitesi Orman Fakültesi Yayınları, İ.Ü. Yayın No: 1642, O. F. Yayın No: 166, Kutulmuş Matbaası, İstanbul.
- Fonweban, J.N., Mayaka, T.B. and Seukep, J.B. 1995. Construction and validation of tree volume equations for *Eucalyptus saligna* in Cameroon. *The Commonwealth Forestry Review*, 355-360.
- Foody, G.M., Lucas, R.M., Curran, P.J. and Honzak, M. 1997. Mapping tropical forest fractional cover from coarse spatial resolution remote sensing imagery. *Plant Ecology*, 131(2), 143-154.
- Garber, S.M. and Maguire, D.A. 2003. Modeling stem taper of three central Oregon species using nonlinear mixed effects models and autoregressive error structures. *Forest Ecology and Management*, 179(1-3), 507-522.
- Garcia, O. 1988. Growth modeling-a (re)view. *New Zealand Forestry*, 14-17.
- Gevrey, M., Dimopoulos, I. and Lek, S. 2003. Review and comparison of methods to study the contribution of variables in artificial neural network models. *Ecological Modelling*, 160(3), 249-264.
- Gompertz, B. 1825. XXIV. On the nature of the function expressive of the law of human mortality, and on a new mode of determining the value of life contingencies. In a letter to Francis Baily, Esq. *FRS & Philosophical transactions of the Royal Society of London*, (115), 513-583.
- Gorgoso, J.J., Rojo, A., Obregón, A.C., Aranda and U.D. 2012. A comparison of estimation methods for fitting Weibull, Johnson's S and beta functions to *Pinus pinaster*, *Pinus radiata* and *Pinus sylvestris* stands in northwest Spain. *Forest Systems*, 21(3), 446-459.
- Gregoire, T.G., Schabenberger, O. and Barrett, J.P. 1995. Linear modeling of irregularly spaced, unbalanced, longitudinal data from permanent-plot measurements. *Canadian Journal of Forest Research*, 25, 137-156.
- Grote, R. and Pretzsch, H. 2002. A model for individual tree development based on physiological processes. *Plant Biology* 4, 167-180.
- Guan, B.T. and Gertner, G. 1991. Modeling red pine tree survival with an artificial neural network. *Forest Science*, 37(5), 1429-1440.
- Guan, B.T., Gertner, G.Z. and Parysow, P. 1997. A framework for uncertainty assessment of mechanistic forest growth models: a neural network example. *Ecological Modelling*, 98(1), 47-58.
- Gülen, İ. 1958. Karaçam (*P. nigra*, Arnold) hacim tablosu. *Teknik Rapor*.
- Günel, H.A. 1981. Orman hasılat bilgisi. ders notu, Bahçeköy-İstanbul.
- 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. In *International Symposium on New Horizons in Forestry-ISFOR*, Artvin.
- 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.
- Hamidi, S.K., Weiskittel, A., Bayat, M. and Fallah, A. 2021. Development of individual tree growth and yield model across multiple contrasting species using nonparametric and parametric methods in the Hyrcanian forests of northern Iran. *European Journal of Forest Research*, 1-14.

- Hann, D.W., Bluhm, A.A. and Hibbs, D.E., 2011. Development and evaluation of the tree-level equations and their combined stand-level behavior in the red alder plantation version of ORGANON.
- Hasenauer, H., Merkl, D. and Weingartner, M. 2001. Estimating tree mortality of Norway spruce stands with neural networks. *Advances in Environmental Research*, 5(4), 405-414.
- Hanewinkel, M. 2005. Neural networks for assessing the risk of windthrow on the forest division level: a case study in southwest Germany. *European Journal of Forest Research*, 124(3), 243-249.
- Hyypä, J., Hyypä, H., Inkinen, M., Engdahl, M., Linko, S. and Zhu, Y.H. 2000. Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. *Forest Ecology and Management*, 128(1-2), 109-120.
- Higgins, J. 2011. A neural network growth and yield model for Nova Scotia forests. Master Thesis, Dalhousie University, Institute of Applied Science, pp. 108.
- Hill, T., Marquez, L., O'Connor, M. and Remus, W. 1994. Artificial neural network models for forecasting and decision making. *International Journal of Forecasting*, 10(1), 5-15.
- Hopfield, J.J. 1982. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of The National Academy of Sciences*, 79(8), 2554-2558.
- Huang, X., Hu, X., Jiang, W., Yang, Z. and Li, H. 2014. Application of multilayer feedforward neural networks in predicting tree height and forest stock volume of Chinese fir. *IEEE Workshop on Electronics, Computer and Applications* (pp. 610-613).
- Hui G.Y. and von Gadow K.V. 1993. Zur entwicklung von einheitshöhenkurvenam beispiel der baumart *cunninghamia lanceolata*. *Allgemeine Forstund Jagdzeitung*, 164(12): 218-220.
- Ivănescu, V.C., Bertrand, J.W.M., Fransoo, J.C. and Kleijnen, J.P. 2006. Bootstrapping to solve the limited data problem in production control: an application in batch process industries. *Journal of the Operational Research Society*, 57(1), 2-9.
- Jensen, J.R., Qiu, F. and Ji, M. 1999. Predictive modelling of coniferous forest age using statistical and artificial neural network approaches applied to remote sensor data. *International Journal of Remote Sensing*, 20(14), 2805-2822.
- Jiang, L., Brooks, J.R. and Wang, J. 2005. Compatible taper and volume equations for yellow-poplar in West Virginia. *Forest Ecology and Management*, 213(1-3), 399-409.
- Johnson, N.L. 1949. Systems of frequency curves generated by methods of translation, *Biometrika*, 36, 149-176.
- Kahriman, A. 2011. Karadeniz Bölgesi sınırları içerisinde yer alan Sarıçam (*Pinus sylvestris* L.)-Doğu Kayını (*Fagus orientalis* Lipsky) karışık meşcerelerine ilişkin büyüme modellerinin geliştirilmesi. Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, 356 S., Trabzon.
- Kahriman, A. ve Yavuz, H. 2011. Sarıçam (*Pinus sylvestris* L.)-doğu kayını (*Fagus orientalis* Lipsky) karışık meşcerelerinde çap dağılımlarının olasılık yoğunluk fonksiyonları ile belirlenmesi. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, 12(2), 109-125.
- Kahriman, A. ve Yavuz, H. 2012. Doğu Karadeniz göknarı-doğu ladini karışık meşcerelerinde çeşitli yarışma endekslerinin tek ağaçların çap artımındaki

- etkilerinin incelenmesi. Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi, 13(2), 235-249.
- Kalıpsız, A. 1963. Karaçam (*Pinus nigra* Arnold) meşcerelerinin tabii bünyesi ve verim kudreti üzerine araştırmalar. Tarım Bakanlığı, Orman Genel Müdürlüğü, Sıra No: 349, Seri No: 8, Yenilik Basımevi, İstanbul.
- Kaloudis, S., Glezakos, T., Ferentinos, K.P., Tsiligridis, T.A. and Yialouris, C.P. 2006. Feedforward neural network modeling of fir taper in natural forests of greece. Management and Development of Mountainous and Island Areas, 166.
- Kanellopoulos, I., Wilkinson, G.G. and Megier, J. 1993. Integration of neural network and statistical image classification for land cover mapping. In Proceedings of IGARSS'93-IEEE International Geoscience and Remote Sensing Symposium (pp. 511-513).
- Kangas, A. and Maltamo, M. 2000. Percentile based basal area diameter distribution models for scots pine, Norway spruce and birch species. Silva Fennica, 34(4), 371-380.
- Kapucu, F., Yavuz, H. ve Gül, A.U. 1999. Doğal ve yapay dişbudak (*Fraxinus angustifolia*) meşcereleri için normal hasılat tablosu. Proje Raporu, KTÜ-BAP, 96.113.001.4, Trabzon
- Kapucu, F., Yavuz, H., Gül, A.U. ve Mısır, N. 2002. Kestane meşcerelerinin hasılat ve amenajman esasları. TOGTAG 2229 nolu TÜBİTAK Projesi, 118 s., Ankara.
- Karahalil, U. 2003. Toprak koruma ve odun üretimi fonksiyonlarının doğrusal programlama ile modellenmesi (Karanlıkdere planlama birimi örneği). Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 92 s., Trabzon.
- Keleş, S. 2003. Ormanların su ve odun üretimi fonksiyonlarının doğrusal programlama tekniği ile optimizasyonu (Karanlıkdere Planlama Birimi örneği). Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 105 s., Trabzon.
- Kimmins, J.P. 1990. Modelling the sustainability of forest production and yield for a changing and uncertain future. The Forestry Chronicle, 66(3), 271-280.
- Kirschbaum, M.U. 1999. CenW, a forest growth model with linked carbon, energy, nutrient and water cycles. Ecological Modelling, 118(1), 17-59.
- Klobučar, D., Pernar, R., Lončarić, S. and Subašić, M. 2008. Artificial neural networks in the assessment of stand parameters from an IKONOS satellite image. Croatian Journal of Forest Engineering: Journal for Theory and Application of Forestry Engineering, 29(2), 201-211.
- Knoebel, B.R. and Burkhardt, H.E. 1991. A bivariate distribution approach to modeling forest diameter distributions at two points in time. Biometrics, 241-253.
- Kohonen, T. 1982. Self-organized formation of topologically correct feature maps. Biological Cybernetics, 43(1), 59-69.
- Kozak, A., Munro, D.D. and Smith, J.H.G. 1969. Taper functions and their application in forest inventory. The Forestry Chronicle, 45(4), 278-283.
- Kozak, A. 1997. Effects of multicollinearity and autocorrelation on the variable-exponent taper functions. Canadian Journal of Forest Research, 27(5), 619-629.
- Köse, S., Yavuz, H., Mısır, M. ve Mısır, N. 2001. KTÜ Orman Fakültesi Araştırma Ormanı ladin meşcerelerinin hasılat esasları sonuç raporu. K.T.Ü. Araştırma Fonu Başkanlığı, Sonuç Raporu, 27 s.

- Král, K., Vrška, T., Hort, L., Adam, D. and Šamonil, P. 2010. Developmental phases in a temperate natural spruce-fir-beech forest: determination by a supervised classification method. *European Journal of Forest Research*, 129(3), 339-351.
- Kuehne, C., Weiskittel, A.R. and Waskiewicz, J. 2019. Comparing performance of contrasting distance-independent and distance-dependent competition metrics in predicting individual tree diameter increment and survival within structurally-heterogeneous, mixed-species forests of Northeastern United States. *Forest Ecology and Management*, 433, 205-216.
- Kuplich, T.M. 2006. Classifying regenerating forest stages in Amazonia using remotely sensed images and a neural network. *Forest Ecology and Management*, 234(1-3), 1-9.
- Leduc, D.J. 2001. Predicting diameter distributions of longleaf pine plantations: a comparison between artificial neural networks and other accepted methodologies (Vol. 25). US Department of Agriculture, Forest Service, Southern Research Station.
- Lee, W.K., Von Gadow, K., Chung, D.J., Lee, J.L. and Shin, M.Y. 2004. DBH growth model for *Pinus densiflora* and *Quercus variabilis* mixed forests in central Korea. *Ecological Modelling*, 176(1-2), 187-200.
- Leite, H.G., da Silva, M.L.M., Binoti, D.H.B., Fardin, L. and Takizawa, F.H. 2011. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. *European Journal of Forest Research*, 130(2), 263-269.
- Li, L. M., Song, W. G., Ma, J. and Satoh, K. 2009. Artificial neural network approach for modeling the impact of population density and weather parameters on forest fire risk. *International Journal of Wildland Fire*, 18(6), 640-647.
- Lima, M.D.O., Lustosa, J., Oliveira, E.M., Ferreira, J.C.B., Soares, K.L. and Miguel, E.P. 2017. Artificial neural networks in whole-stand level modeling of eucalyptus plants. *African Journal of Agricultural Research*, 12(7), 535-541.
- Liu, C., Zhang, S.Y., Lei, Y., Newton, P.F. and Zhang, L. 2004. Evaluation of three methods for predicting diameter distributions of black spruce (*Picea mariana*) plantations in central Canada. *Canadian Journal of Forest Research*, 34(12), 2424-2432.
- Liu, C. and Zhang, S. Y. 2005. Models for predicting product recovery using selected tree characteristics of black spruce. *Canadian Journal of Forest Research*, 35(4), 930-937.
- Looi, C.K. 1992. Neural network methods in combinatorial optimization. *Computers & Operations Research*, 19(3-4), 191-208.
- Lopez, G., Rubio, M.A., Martinez, M. and Batlles, F.J. 2001. Estimation of hourly global photosynthetically active radiation using artificial neural network models. *Agricultural and Forest Meteorology*, 107(4), 279-291.
- Magnussen, S. 1986. Diameter distributions in *Picea abies* described by the Weibull model. *Scandinavian Journal of Forest Research*, 1(1-4), 493-502.
- Maier, H.R., Dandy, G.C., Burch and M.D. 1998. Use of artificial neural networks for modelling cyanobacteria *Anabaena* spp. in the River Murray, South Australia. *Ecological Modelling*, 105(2-3), 257-272.
- Maier, H.R. and Dandy, G.C. 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software*, 15(1), 101-124.

- Maltamo, M., Kangas, A., Uuttera, J., Torniainen, T. and Saramäki, J. 2000. Comparison of percentile based prediction methods and the Weibull distribution in describing the diameter distribution of heterogeneous Scots pine stands. *Forest Ecology and Management*, 133(3), 263-274.
- Massey Jr, F.J. 1951. The Kolmogorov-Smirnov test for goodness of fit. *Journal of the American Statistical Association*, 46(253), 68-78.
- Max, T.A. and Burkhardt, H.E. 1976. Segmented polynomial regression applied to taper equations. *Forest Science*, 22(3), 283-289.
- McCulloch, W.S. and Pitts, W. 1943. A logical calculus of the ideas immanent in nervous activity. *The bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Mehtätalo, L. 2004. An algorithm for ensuring compatibility between estimated percentiles of diameter distribution and measured stand variables. *Forest Science*, 50(1), 20-32.
- Meng, S. X., Huang, S., Vanderschaaf, C.L., Yang, Y. and Trincado, G. 2012. Accounting for serial correlation and its impact on forecasting ability of a fixed- and mixed-effects basal area model: a case study. *European Journal of Forest Research*, 131(3), 541-552.
- Mensah, S., Pienaar, O.L., Kunneke, A., du Toit, B., Seydack, A., Uhl, E. and Seifert, T. 2018. Height–Diameter allometry in South Africa’s indigenous high forests: Assessing generic models performance and function forms. *Forest Ecology and Management*, 410, 1-11.
- Merkel, D. and Hasenauer, H. 1998. Using neural networks to predict individual tree mortality. In *Proceedings of the Int’l Conference on Engineering Applications of Neural Networks* (pp. 10-12).
- Mısıır, M. 2001. Çok amaçlı orman amenajman planlarının coğrafi bilgi sistemlerine dayalı olarak amaç programlama yöntemiyle düzenlenmesi (ormanüstü planlama birimi örneği ile). Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 144 s. Trabzon
- Mısıır, N. 2003. Karaçam ağaçlandırmalarına ilişkin büyüme modelleri. Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 209 s, Trabzon.
- Mısıır, N. 2010. Generalized height-diameter models for *Populus tremula* L. stands. *African Journal of Biotechnology*, 9(28), 4348-4355.
- Mitchell, K.J. 1969. Simulation of the growth of even-aged stands of white spruce. Bulletin 75. Yale University School of Forestry, New Haven, CT.
- Monserud, R.A. and Sterba, H. 1996. A basal area increment model for individual trees growing in even-and uneven-aged forest stands in Austria. *Forest Ecology and Management*, 80(1-3), 57-80.
- Mosaffaei, Z. and Jahani, A. 2020. Modeling of ash (*Fraxinus excelsior*) bark thickness in urban forests using Artificial Neural Network (ANN) and regression models. *Modeling Earth Systems and Environment*, 1-10.
- Munro, D.D. 1973. Modelling for managed stands. Forest Service, British Columbia, Research No, 65-6872.
- Nelson, T.C. 1964. Diameter distribution and growth of loblolly pine. *Forest Science*, 10(1), 105-114.
- Newnham, R.M. and Smith, J.H.G. 1964. Development and testing of stand models for Douglas fir and lodgepole pine. *The Forestry Chronicle*, 40(4), 494-504.

- Newton, P.F., Lei, Y. and Zhang, S.Y. 2005. Stand-level diameter distribution yield model for black spruce plantations. *Forest Ecology and Management*, 209(3), 181-192.
- Nord-Larsen, T. and Cao, Q.V. 2006. A diameter distribution model for even-aged beech in Denmark. *Forest Ecology and Management*, 231(1-3), 218-225.
- Ogana, F.N., Itam, E.S. and Osho, J.S. 2017. Modeling diameter distributions of *Gmelina arborea* plantation in Omo Forest Reserve, Nigeria with Johnson's SB. *Journal of Sustainable Forestry*, 36(2), 121-133.
- Özcan, B.G. 2002. Sahilçamı (*Pinus pinaster* Ait.) ağaçlandırmalarında artım ve büyüme. Doktora Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü. İstanbul.
- Özçelik, R., Diamantopoulou, M.J., Wiant Jr, H.V. and 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.
- 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. and 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. and Brooks, J.R. 2014. The use of tree crown variables in over-bark diameter and volume prediction models. *iForest-Biogeosciences and Forestry*, 7(3), 132.
- Özçelik, R. and Karaer, K. 2016. Development of merchantable volume equations for natural brutian pine and black pine stands in Eğirdir district. *Journal of the Faculty of Forestry, Istanbul University*, 66(1), 59-74.
- Özçelik, R., Fidalgo Fonseca, T.J., Parresol, B.R. and Eler, Ü. 2016. Modeling the diameter distributions of brutian pine stands using Johnson's SB distribution. *Forest Science*, 62(6), 587-593.
- Özçelik, R., Diamantopoulou, M.J., Eker, M. And Gürlevik, N. 2017. Artificial neural network models: an alternative approach for reliable aboveground pine tree biomass prediction. *Forest Science*, 63(3), 291-302.
- Özçelik, R., Diamantopoulou, M.J. and Trincado, G. 2019. Evaluation of potential modeling approaches for scots pine stem diameter prediction in north-eastern Turkey. *Computers and Electronics in Agriculture*, 162, 773-782.
- Özçelik, R. and Alkan, O. 2020. Fiting and calibrating a mixed-effects segmented taper model for brutian pine. *Cerne*, 26(4), 464-473.
- Özdemir, E. 2011. Karışık meşcerelerde artım ve büyümenin simulasyonu (Büyükdüz örneği). Doktora Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, 228 s., İstanbul.
- Özdemir, G.A. 2014. Karadeniz yöresi göknar meşcerelerinde aktüel kuruluşun optimal kuruluşa götürülmesi. *Journal of the Faculty of Forestry Istanbul University*, 64(1), 51-66.
- Özdemir, G.A. 2013. Trakya meşe ormanlarında artım ve büyüme ilişkileri. Doktora Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, 202 s., İstanbul.
- Özdemir, G.A. 2016. Douglas (*Pseudotsuga menziesii* (Mirb.) Franco) meşcerelerinin çap dağılımlarının modellenmesi. *İstanbul Üniversitesi Orman Fakültesi Dergisi*, 66(2), 548-558.

- Parresol, B.R., Hotvedt, J.E., Cao and Q.V. 1987. A volume and taper prediction system for bald cypress. *Canadian Journal of Forest Research*, 17(3), 250-259.
- Paruelo, J. and Tomasel, F. 1997. Prediction of functional characteristics of ecosystems: a comparison of artificial neural networks and regression models. *Ecological Modelling*, 98(2-3), 173-186.
- Peng, C. 2000. Growth and yield models for uneven-aged stands: past, present and future. *Forest Ecology and Management*, 132(2-3), 259-279.
- Porté, A. and Bartelink, H.H. 2002. Modelling mixed forest growth: a review of models for forest management. *Ecological Modelling*, 150(1-2), 141-188.
- Poudel, K.P. 2011. Evaluation of methods to predict Weibull parameters for characterizing diameter distributions. Master Thesis, Louisiana State University and Agricultural and Mechanical College, p. 53.
- 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.
- Poudel, K.P., Temesgen, H. and Gray, A.N. 2018. Estimating upper stem diameters and volume of Douglas-fir and Western hemlock trees in the Pacific northwest. *Forest Ecosystems*, 5(1), 1-12.
- Pretzsch, H., Biber, P. and Dursky, J. 2002. The single tree-based stand simulator SILVA: Construction, application and evaluation. *Forest Ecology and Management* 162, 3–21.
- Pretzsch, H. and Zenner, E.K. 2017. Toward managing mixed-species stands: from parametrization to prescription. *Forest Ecosystems*, 4(1), 1-17.
- Qin, J. and Cao, Q.V. 2006. Using disaggregation to link individual-tree and whole-stand growth models. *Canadian Journal of Forest Research*, 36(4), 953-960.
- Pierce, L.E., Dobson, M.C., Wilcox, E.P. and Ulaby, F.T. 1993. Artificial neural network inversion of tree canopy parameters in the presence of diversity. In *Proceedings of IGARSS'93-IEEE International Geoscience and Remote Sensing Symposium* (pp. 394-397).
- Reineke, L.H. 1933. Perfection a stand-density index for even-aged forest. *Journal of Agricultural Research*, 46, 627-638.
- Reis, L.P., de Souza, A.L., Mazzei, L., Mazzei, L., dos Reis, P.C.M., Leite, H.G., Soares, C.P.B., Moreira, C., Torres, M. E., da Silva, L.F. and Ruschel, A.R. 2016. Prognosis on the diameter of individual trees on the eastern region of the amazon using artificial neural networks. *Forest Ecology and Management*, 382, 161-167.
- Reynolds, M.R., Burk, T.E., Huang and W.C. 1988. Goodness-of-fit tests and model selection procedures for diameter distribution models. *Forest Science*, 34(2), 373-399.
- Rivas, J.C., González, J.Á., Aguirre, O. and Hernandez, F.J. 2005. The effect of competition on individual tree basal area growth in mature stands of *Pinus cooperi* Blanco in Durango (Mexico). *European Journal of Forest Research*, 124(2), 133-142.
- Robinson, A.P. and Ek, A.R. 2003. Description and validation of a hybrid model of forest growth and stand dynamics for the Great Lakes region. *Ecological Modelling*, 170(1), 73-104.
- Rojó, A., Perales, X., Sánchez-Rodríguez, F., Álvarez-González, J.G. and Von Gadow, K. 2005. Stem taper functions for maritime pine (*Pinus pinaster* Ait.) in Galicia (Northwestern Spain). *European Journal of Forest Research*, 124(3), 177-186.

- Rosenblatt, F. 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386.
- Running, S.W. and Coughlan, J.C. 1988. A general model of forest ecosystem processes for regional applications. I. Hydrologic balance, canopy gas exchange and primary production processes. *Ecological Modelling* 42, 125–154.
- Ryan, M.G. and Yoder, B.J. 1997. Hydraulic limits to tree height and tree growth. *Bioscience*, 47(4), 235-242.
- Sakıcı, O.E. and Gülsunar, M. 2012. Diameter distribution of bornmullerian fir in mixed stands. *Kastamonu Üniversitesi Orman Fakültesi Dergisi, Özel Sayı*, 263-270.
- Sakıcı, O.E., Seki, M., Sağlam, F. and Akyıldız, M. H. 2016. Modeling diameter distributions of black pine stands in Taşköprü region. *International Forestry Symposium*, 521-535, Kastamonu.
- 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 Özdemir, G. 2018. Stem taper estimations with artificial neural networks for mixed oriental beech and Kazdağı fir stands in Karabük region, Turkey. *Cerne*, 24(4), 439-451.
- Sánchez-González, M., del Río, M., Cañellas, I. and Montero, G. 2006. Distance independent tree diameter growth model for cork oak stands. *Forest Ecology and Management*, 225(1-3), 262-270.
- Sánchez, C.A.L., Varela, J.G., Dorado, F.C., Alboreca, A.R., Soalleiro, R.R., González, J.G.Á. and Rodríguez, F.S. 2003. A height-diameter model for *Pinus radiata* D. Don in Galicia (Northwest Spain). *Annals of Forest Science*, 60(3), 237-245.
- Saraçoğlu, Ö. 1986. Karadeniz yöresi göknar meşcerelerinde artım ve büyüme. Doktora Tezi, İ.Ü. Orman Fakültesi Orman Hasılatı ve Biyometri Bilim Dalı, 369 s., İstanbul.
- Schmoldt, D.L., Li, P., Abbott and A.L. 1997. Machine vision using artificial neural networks with local 3D neighborhoods. *Computers and Electronics in Agriculture*, 16(3), 255-271.
- Schröder, J. and González, J.G.Á. 2001. Comparing the performance of generalized diameter-height equations for maritime pine in Northwestern Spain. *Forstwissenschaftliches Centralblatt Vereinigt mit Tharandter Forstliches Jahrbuch*, 120(1), 18-23.
- Schultz, E.B., Matney, T.G. and Koger, J.L. 1999. A neural network model for wood chip thickness distributions. *Wood and Fiber Science*, 31(1), 2-14.
- Seki, M. 2020. Kastamonu Orman Bölge Müdürlüğü karaçam (*Pinus nigra* J.F. Arnold) meşcerelerine ilişkin ekolojik tabanlı büyüme modelleri. Doktora Tezi, Kastamonu Üniversitesi, Fen Bilimleri Enstitüsü, 201 s., Kastamonu.
- Shahzad, M.K., Hussain, A., Burkhart, H.E., Li, F. and Jiang, L. 2020. Stem taper functions for *Betula platyphylla* in the Daxing'an Mountains, northeast China. *Journal of Forestry Research*, 1-13.
- Sharda, R. 1994. Neural networks for the MS/OR analyst: An application bibliography. *Interfaces*, 24(2), 116-130.
- Sharma, M. and Yin Zhang, S. 2004. Height–diameter models using stand characteristics for *Pinus banksiana* and *Picea mariana*. *Scandinavian Journal of Forest Research*, 19(5), 442-451.

- Sharma, M. and Parton, J. 2007. Height–diameter equations for boreal tree species in Ontario using a mixed-effects modeling approach. *Forest Ecology and Management*, 249(3), 187-198.
- Shen, J., Hu, Z., Sharma, R. P., Wang, G., Meng, X., Wang, M., Wang, M. and Fu, L. 2020. Modeling height–diameter relationship for poplar plantations using combined-optimization multiple hidden layer back propagation neural network. *Forests*, 11(4), 442.
- Shiver, B.D. 1988. Sample sizes and estimation methods for the Weibull distribution for unthinned slash pine plantation diameter distributions. *Forest science (USA)*, 34, 819-814.
- Sıvacioğlu, A., Durkaya, A., Vurdu, H. ve Benli, R. 2006. Taşköprü (Kastamonu) yöresi doğal sarıçam (*Pinus silvestris* L.) meşcerelerinde sıklık bakımlarının artım ve büyümeye etkisi. *Kastamonu Üniversitesi Orman Fakültesi Dergisi*, 6(2), 153-166.
- Simon, H.A. and Newell, A. 1958. Heuristic problem solving: The next advance in operations research. *Operations Research*, 6(1), 1-10.
- Soares, P. and Tomé, M. 2002. Height–diameter equation for first rotation eucalypt plantations in Portugal. *Forest Ecology and Management*, 166(1-3), 99-109.
- Solomon, D.S., Herman, D.A. and Leak, W.B. 1995. FIBER 3.0: An ecological growth model for northeastern forest types. General Technical Report NE-204. USDA Forest Service, Northeastern Forest Experiment Station, Radnor, PA.
- Sothe, C., De Almeida, C.M., Schimalski, M.B., La Rosa, L.E.C., Castro, J.D.B., Feitosa, R.Q. And Tommaselli, A.M.G. 2020. Comparative performance of convolutional neural network, weighted and conventional support vector machine and random forest for classifying tree species using hyperspectral and photogrammetric data. *GIScience & Remote Sensing*, 57(3), 369-394.
- Sönmez, T., Ercanlı, İ. and Keleş, S. 2009. A distance-independent basal area growth model for oriental spruce (*Picea orientalis* (L.) Link) growing in mixture with oriental beech (*Fagus orientalis* Lipsky) in the Artvin region, North-East Turkey. *African Journal of Agricultural Research*, 4(8), 740-751.
- Sönmez, T., Günlü, A., Karahalil, U., Ercanlı, İ. ve Şahin, A. 2010. Saf doğu ladini meşcerelerinde çap dağılımının modellenmesi. III. Ulusal Karadeniz Ormancılık Kongresi, 388-398, Artvin.
- Stankova, T.V. and Zlatanov, T.M. 2010. Modeling diameter distribution of Austrian black pine (*Pinus nigra* Arn.) plantations: a comparison of the Weibull frequency distribution function and percentile-based projection methods. *European Journal of Forest Research*, 129(6), 1169-1179.
- Sun, O. 1977. Bir kızılçam (*P. brutia* Ten.) ağacının simülasyonu için büyüme modeli. *Ormancılık Araştırma Enstitüsü Yayınları, Teknik Bülten Serisi*, No: 119.
- Sun, O., Eren, E. ve Orpak, M. 1978. Temel ağaç türlerimizde tek ağaç ve birim alandaki odun çeşidi oranlarının saptanması. PROJE NO: TOAG-288.
- Şahin, A. 2015. Mersin yöresi saf kızılçam (*Pinus brutia* Ten.) meşcerelerinde hasılat araştırmaları. Doktora Tezi, Artvin Çoruh Üniversitesi, Fen Bilimleri Enstitüsü, 311 s., Artvin.
- Şenyurt, M. 2011. Batı Karadeniz yöresi sarıçam meşcerelerinde artım ve büyüme. Doktora Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, 215 s., İstanbul.

- Şenyurt, M., Ercanlı, İ., Yavuz, H. and Kahrıman, A. 2015. Predicting stand yield parameters based on artificial neural network for oriental beech in kestel forests, Bursa. In The 10th International Beech Symposium (pp. 1-6).
- 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. *Şumarski 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.
- Tamarit Urías, J.C., De los Santos Posadas, H.M., Aldrete, A., Valdez Lazalde, J.R., Ramírez Maldonado, H. and Guerra De la Cruz, V. 2014. Sistema de cubicación para árboles individuales de *Tectona grandis* L. f. mediante funciones compatibles de ahusamiento-volumen. *Revista Mexicana de Ciencias Forestales*, 5(21), 58-74.
- Tang, X., Pérez-Cruzado, C., Fehrmann, L., Álvarez-González, J.G., Lu, Y. and Kleinn, C. 2016. Development of a compatible taper function and stand-level merchantable volume model for Chinese fir plantations. *PloS One*, 11(1), e0147610.
- Tasissa, G. and Burkhart, H.E. 1998. An application of mixed effects analysis to modeling thinning effects on stem profile of loblolly pine. *Forest Ecology and Management*, 103(1), 87-101.
- Taylor, A.R., Chen, H.Y. and VanDamme, L. 2009. A review of forest succession models and their suitability for forest management planning. *Forest Science*, 55(1), 23-36.
- Tewari, V.P. 2007. Comparing the model forms estimating generalised diameter-height relationships in *Tecomella undulata* plantations in hot arid region of India. *Journal of Forestry Research*, 18(4), 255-260.
- Trincado, G., VanderSchaaf, C.L. and Burkhart, H.E. 2007. Regional mixed-effects height–diameter models for loblolly pine (*Pinus taeda* L.) plantations. *European Journal of Forest Research*, 126(2), 253-262.
- Turing, A.M. 1950. *Mind. Mind*, 59(236), 433-460.
- Ung, C.H., Jing Guo, X. and Fortin, M. 2013. Canadian national taper models. *The Forestry Chronicle*, 89(2), 211-224.
- URL-1. https://en.wikipedia.org/wiki/Deep_Blue_versus_Garry_Kasparov. Erişim Tarihi: 10 Şubat 2021.
- Usta, H.Z. 1991. Kızılçam (*Pinus brutia* Ten.) ağaçlandırmalarında hasılat araştırmaları. Ormancılık Araştırma Enstitüsü Teknik Yayın Serisi No: 219.
- Üçler, A.Ö., Demirci, A., Yavuz, H., Yücesan, Z., Oktan, E. ve Gül, A.U. 2001. Alpin zona yakın saf doğu ladini ormanlarının meşcere kuruluşlarıyla fonksiyonel yapılarının tespiti ve silvikültürel öneriler. Proje No: TOGTAG TARP-2215.
- Vahedi, A.A. 2016. Artificial neural network application in comparison with modeling allometric equations for predicting above-ground biomass in the Hyrcanian mixed-beech forests of Iran. *Biomass and Bioenergy*, 88, 66-76.
- Vanclay, J.K. 1994. Modelling forest growth and yield: applications to mixed tropical forests. CAB international, ISBN: 0-85198-913-6.
- Vega-Garcia, C., Lee, B.S., Woodard, P.M. and Titus, S.J. 1996. Applying Neural Network Technology to Human-Caused. *AI Applications*, (10),3.
- Vinícius Oliveira Castro, R., Boechat Soares, C.P., Leite, H.G., Lopes de Souza, A., Saraiva Nogueira, G. and Bolzan Martins, F. 2013. Individual growth model for

- Eucalyptus stands in Brazil using artificial neural network. International Scholarly Research Notices.
- Von Gadow, K. and Hui, G. 1999. Modelling forest development (Vol. 57). Springer Science & Business Media.
- Wang, J. and Chankong, V. 1992. Recurrent neural networks for linear programming: Analysis and design principles. Computers & Operations Research, 19(3-4), 297-311.
- Wang, Y., Raulier, F. and Ung, C.H. 2005. Evaluation of spatial predictions of site index obtained by parametric and nonparametric methods-A case study of lodgepole pine productivity. Forest Ecology and Management, 214(1-3), 201-211.
- Wang, M., Borders, B.E. and Zhao, D. 2008. An empirical comparison of two subject-specific approaches to dominant heights modeling: The dummy variable method and the mixed model method. Forest Ecology and Management, 255(7), 2659-2669.
- Weibull, W. 1951. A statistical distribution function of wide applicability. Journal of Applied Mechanics, 18(3), 293-297.
- Weiner, J. 1990. Asymmetric competition in plant populations. Trends in Ecology & Evolution, 5(11), 360-364.
- Weiskittel, A.R., Hann, D.W., Kershaw Jr, J.A. and Vanclay, J.K. 2011. Forest growth and yield modeling. John Wiley & Sons, ISBN: 978-0-470-66500-8.
- Widrow, B. and Hoff, M.E. 1960. Adaptive switching circuits. Stanford Univ Ca Stanford Electronics Labs.
- Xu, H., Sun, Y., Wang, X., Fu, Y., Dong, Y. and Li, Y. 2014. Nonlinear mixed-effects (NLME) diameter growth models for individual China-fir (*Cunninghamia lanceolata*) trees in southeast China. PloS One, 9(8), e104012.
- Yang, F. and Yue, Z. 2014. Kernel density estimation of three-parameter Weibull distribution with neural network and genetic algorithm. Applied Mathematics and Computation, 247, 803-814.
- Yavuz, H., Mısır, N., Tüfekçioğlu, A., Altun, L., Mısır, M., Ercanlı, İ., Sakıcı, O.E., Kahrıman, A., Karahalil, U., Yılmaz, M., Sarıyıldız, T., Küçük, M., Meydan, G., Bayburtlu, Ş., Bilgili, F., Aydın, A.C., Kara, Ö., Bolat, İ. ve Usta, A., 2010. Karadeniz Bölgesi saf ve karışık Sarıçam (*Pinus sylvestris* L.) meşcereleri için mekanistik büyüme modellerinin geliştirilmesi, biyokütle ve karbon depolama miktarlarının belirlenmesi. (TÜBİTAK-TOVAG Projesi, Proje No: 106O274), Karadeniz Teknik Üniversitesi Orman Fakültesi, Trabzon.
- Yazıcı, N. ve Çatal, Y. Barajların Anadolu karaçamı (*Pinus nigra* Arn.) ağaçlarında yıllık çap artımına etkileri: Isparta-Uluborlu örneği. Türkiye Ormancılık Dergisi, 20(1), 28-34.
- Yıldızbakan, A. 2005. Ağaçlarda büyümeye ait matematiksel modeller ve bu modellerin karşılaştırılması olarak incelenmesi. Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 41 s., Adana.
- Yee, D., Prior, M.G., Florence and L.Z. 1993. Development of predictive models of laboratory animal growth using artificial neural networks. Bioinformatics, 9(5), 517-522.
- Yeşil, A. 1992. Değişik sıklık ve bonitetlerdeki kızılçam meşcerelerinin yaşa göre gelişimi. İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, 179 s.

- Yücesan, Z. 2006. Çamlıhemşin-Fırtına Vadisi yüksek dağlık alanlardaki saf ve karışık ormanların meşcere dinamiklerinin analizi. Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, 329 s., Trabzon.
- Zhang, Q.B., Hebda, R.J., Zhang, Q.J. and Alfaro, R.I. 2000. Modeling tree-ring growth responses to climatic variables using artificial neural networks. *Forest Science*, 46(2), 229-239.
- Zhang, L., Packard, K.C. and Liu, C. 2003. A comparison of estimation methods for fitting Weibull and Johnson's SB distributions to mixed spruce fir stands in northeastern North America. *Canadian Journal of Forest Research*, 33(7), 1340-1347.
- Zhao, D., Lynch, T. B., Westfall, J., Coulston, J., Kane, M. and Adams, D.E. 2019. Compatibility, development, and estimation of taper and volume equation systems. *Forest Science*, 65(1), 1-13.
- Zurk, L.M., Davis, D., Njoku, E.G., Tsang, L. and Hwang, J.N. 1992. Inversion of parameters for semiarid regions by a neural network. *Proceedings of the 12th Annual International Geoscience and Remote Sensing Symposium*, Houston.
- Zuur, A.F., Ieno, E.N and Elphick, C.S. 2010. A protocol for data exploration to avoid common statistical problems. *Methods in Ecology and Evolution*, 1(1), 3-14.

EKLER

EK 1 Johnson SB Fonksiyonunun Örnek Alan Düzeyinde Hesaplanan Parametre Değerleri

Ö.A.N	Yüzdelik Yöntem				Moment Yöntemi			
	ξ	λ	δ	γ	ξ	λ	δ	γ
1	10,70	28,10	0,69	0,72	12,47	33,45	0,87	1,43
2	7,70	28,10	1,43	0,05	-15,85	52,31	2,03	-1,77
3	19,20	37,60	0,63	0,34	4,28	415,54	3,59	9,37
4	3,70	55,10	0,61	0,35	4,88	55,92	0,66	0,42
5	2,70	54,10	0,73	0,33	-4,79	63,95	0,95	0,35
6	7,10	42,70	0,77	-0,15	4,73	50,99	0,98	0,06
7	4,90	40,90	0,87	0,11	3,40	37,20	0,53	-0,03
8	3,70	35,10	1,22	-0,68	-0,43	33,44	0,50	-0,85
9	14,70	35,10	1,52	-1,61	4,58	41,54	0,52	-1,05
10	11,30	30,50	0,84	0,23	-1,09	39,58	8,33	-5,15
11	4,20	35,60	0,59	0,58	5,11	38,67	0,77	0,93
12	11,50	27,30	1,39	-0,01	34,10	11,48	3,22	2,22
13	2,70	35,10	1,06	-0,17	-0,47	32,46	0,55	-0,34
14	0,70	31,10	1,03	1,19	2,74	46,47	1,10	2,29
15	13,20	20,60	1,20	-0,14	-25,45	63,09	3,01	-3,99
16	9,20	28,60	1,23	-0,43	-14,40	52,44	1,63	-1,93
17	4,10	19,70	1,06	0,85	4,55	19,33	1,02	0,95
18	2,70	20,10	0,91	0,85	3,61	18,61	0,91	0,98
19	2,70	72,10	2,27	6,09	4,49	1,00	0,88	-0,57
20	5,30	52,50	0,63	0,09	-3,26	65,26	0,91	0,07
21	2,70	21,10	0,88	0,65	3,96	16,94	0,64	0,44
22	3,20	46,60	0,83	-0,06	5,64	36,40	0,29	-0,08
23	6,00	41,80	0,81	-0,28	5,31	38,75	0,44	-0,33
24	8,10	24,70	1,10	0,13	5,82	25,36	0,98	-0,03
25	4,20	21,60	1,41	0,41	0,97	22,13	1,23	-0,27
26	4,10	40,70	0,78	0,19	16,26	13,87	2,37	-0,98
27	2,70	58,10	0,64	1,32	2,54	91,25	0,87	2,09
28	2,80	54,00	0,75	-0,29	-10,52	63,10	0,65	-0,60

EK 1'in devamı

Ö.A.N	Yüzdelik Yöntem				Moment Yöntemi			
	ξ	λ	δ	γ	ξ	λ	δ	γ
29	4,70	31,10	0,98	0,94	-0,05	86,50	1,16	1,80
30	8,50	39,30	0,69	0,82	8,66	79,52	1,16	2,54
31	2,90	30,90	0,89	1,25	4,35	54,56	1,08	2,69
32	3,10	47,70	0,77	0,78	2,87	67,71	0,97	1,61
33	3,10	60,70	0,49	0,32	2,62	59,65	0,39	0,31
34	4,00	55,80	0,48	0,50	7,82	47,00	0,30	0,34
35	10,10	44,70	1,05	0,16	-1,80	66,24	1,64	0,20
36	2,80	67,00	0,78	0,50	-4,29	90,11	1,03	0,95
38	5,90	56,90	0,53	0,52	9,18	47,82	0,33	0,28
39	38,10	23,70	1,46	-0,77	35,37	21,86	0,60	-0,83
41	27,70	48,10	0,68	0,29	20,55	24,46	3,45	-2,94
42	14,70	34,10	1,21	-0,44	-9,08	56,23	1,44	-1,79
43	19,40	40,40	1,01	-0,64	-81,52	139,90	1,60	-3,69
44	2,70	16,10	1,43	0,20	1,59	14,74	1,09	-0,33
45	13,00	44,80	1,02	-0,73	9,63	42,76	0,45	-0,54
46	15,70	46,10	0,79	-0,16	43,43	13,27	1,80	0,47
47	12,70	38,10	0,70	0,17	6,59	62,92	1,66	0,91
48	2,80	43,00	2,22	0,66	19,33	22,39	3,19	0,00
49	6,70	29,10	0,91	0,23	5,17	29,24	0,80	0,10
50	3,80	27,00	1,11	0,73	0,54	36,44	1,50	1,01
51	33,20	39,60	0,61	0,35	32,63	50,14	0,91	0,72
52	2,80	24,00	1,10	0,17	1,82	22,10	0,86	-0,15
53	2,80	24,00	1,24	0,48	1,54	24,21	1,12	0,29
54	2,90	25,90	1,00	0,13	-1,83	29,61	1,16	-0,21
55	6,90	30,90	0,92	0,94	5,08	51,79	1,38	2,01
56	7,00	41,80	0,98	-0,54	-13,98	65,31	1,36	-1,29
57	16,50	41,30	1,00	-0,38	49,90	10,17	2,09	1,59
58	6,10	27,70	1,21	0,58	4,44	32,59	1,28	0,77
59	4,80	40,00	0,92	-0,12	-0,97	44,94	0,95	-0,29
60	7,30	30,50	0,82	-0,04	28,81	20,24	3,59	0,95
61	6,00	51,80	1,40	1,71	3,97	1,54	1,98	-5,60
62	4,00	43,80	0,96	0,34	-1,38	50,13	1,03	0,24
63	9,80	44,00	0,90	-0,23	10,02	37,62	0,54	-0,25
64	4,70	68,10	1,19	1,30	6,34	623,60	1,52	5,83
65	4,00	34,80	0,73	0,70	4,37	46,87	1,12	1,55
66	7,40	64,40	0,80	-0,49	4,18	59,17	0,23	-0,42
67	42,60	31,20	0,62	0,41	39,61	46,57	1,12	0,99
68	8,10	56,70	1,05	-1,04	2,08	55,60	0,49	-0,69
69	6,70	31,10	0,97	0,07	0,45	36,31	1,05	-0,39
70	4,00	45,80	0,70	0,66	5,28	48,17	0,79	0,85
71	5,00	33,80	1,05	-0,23	-17,27	55,77	1,38	-1,39

EK 1'in devamı

Ö.A.N	Yüzdelik Yöntem				Moment Yöntemi			
	ξ	λ	δ	γ	ξ	λ	δ	γ
72	5,70	33,10	1,75	-1,84	-24,97	59,02	0,78	-2,23
73	7,00	62,80	0,90	-0,59	3,15	57,37	0,37	-0,52
74	5,00	23,80	0,81	0,51	6,25	20,58	0,64	0,31
75	6,80	31,00	0,85	0,18	5,81	31,63	0,81	0,16
76	11,50	60,30	0,76	-0,41	-28,94	97,12	1,00	-1,43
77	6,70	65,10	0,76	-0,44	5,20	59,74	0,33	-0,38
78	14,50	48,30	0,79	-0,11	44,16	23,92	2,74	0,55
79	28,30	32,50	1,59	-1,66	21,38	34,87	0,41	-1,00
80	5,30	56,50	0,95	0,34	-6,59	90,75	1,61	0,87
81	6,00	48,80	0,58	0,28	7,03	45,35	0,50	0,33
82	5,90	18,90	1,14	0,38	0,89	28,14	1,97	0,37
83	14,10	16,70	1,07	0,79	13,50	17,53	1,32	0,74
84	12,20	18,60	0,90	0,45	12,39	18,31	0,99	0,48
85	12,60	20,20	1,19	-0,12	10,72	19,05	0,77	-0,47
86	18,30	15,50	1,20	0,33	17,73	15,41	1,23	0,11
87	9,40	37,40	0,91	-0,28	-142,49	193,69	2,60	-5,49
88	10,50	37,30	0,81	0,13	-2,65	55,63	1,43	-0,25
89	14,70	29,10	1,04	0,25	3,78	48,87	10,11	-4,58
90	6,00	31,80	0,80	0,24	-8,97	72,34	2,65	0,97
91	10,00	28,80	1,35	-0,30	-7,31	46,13	1,59	-1,56
92	7,10	30,70	1,25	-0,57	4,80	29,15	0,70	-0,61
93	9,60	31,20	0,90	-0,03	-6,44	52,07	1,81	-0,88
94	23,00	24,80	1,10	-0,07	4,80	45,29	1,67	-1,34
95	5,90	38,90	0,85	0,82	1,83	65,83	1,50	1,86
96	5,20	38,60	0,91	0,19	1,95	40,11	0,81	0,00
97	6,30	29,50	1,44	0,22	-7,11	48,95	2,06	-0,43
98	9,50	33,30	1,02	0,35	21,87	8,21	1,83	-0,30
99	9,90	34,90	0,88	0,81	14,15	9,99	2,18	-1,33
100	6,30	32,50	1,10	0,29	4,05	31,28	0,91	-0,14
101	6,60	37,20	0,87	0,08	5,44	34,18	0,66	-0,23
102	6,90	34,90	1,11	0,30	4,77	33,55	0,81	-0,01
103	12,30	27,50	0,73	0,28	11,51	28,24	0,80	0,33
104	5,70	26,10	1,11	0,13	-0,08	31,48	1,25	-0,36
105	11,70	26,10	1,28	-0,28	41,22	9,06	4,15	5,31
106	12,00	28,80	0,93	0,59	5,28	7,51	3,74	-5,67
107	8,90	24,90	1,68	-0,87	-38,39	70,92	1,78	-3,72
108	18,00	33,80	0,98	0,34	12,47	45,66	1,37	0,52
109	26,30	25,50	0,72	0,39	15,58	58,94	2,29	1,52
110	8,50	44,30	1,09	-0,02	34,49	17,87	2,52	0,41
111	-0,60	17,40	1,05	1,41	0,19	16,63	0,92	1,52
112	2,60	21,20	0,89	1,11	3,92	16,75	0,65	0,96

EK 1'in devamı

Ö.A.N	Yüzdelik Yöntem				Moment Yöntemi			
	ξ	λ	δ	γ	ξ	λ	δ	γ
113	-0,20	28,00	1,06	1,79	1,46	48,28	0,97	2,78
114	3,10	34,70	0,81	0,89	3,47	40,03	0,95	1,16
115	3,00	15,80	1,25	0,46	3,23	13,32	0,95	0,18
116	4,10	28,70	0,75	0,41	1,40	37,53	1,20	0,79
117	2,80	29,00	0,92	-0,22	2,46	26,55	0,50	-0,34
118	4,30	30,50	0,85	0,42	2,34	38,24	1,19	0,70
119	7,20	30,60	0,97	-0,24	-244,47	301,01	4,22	-9,15
120	3,30	31,50	0,80	0,13	3,01	32,65	0,85	0,21
121	6,50	39,30	0,71	0,11	-8,70	66,88	1,53	0,21
122	7,70	28,10	1,18	-0,62	-5,96	40,79	1,20	-1,34
123	5,40	31,40	0,81	0,43	6,21	31,73	0,86	0,61
124	21,90	17,90	0,96	0,30	18,93	20,07	1,12	-0,08
125	6,40	28,40	0,80	0,59	7,74	36,63	1,15	1,48
126	5,60	19,20	1,21	0,43	5,19	17,81	1,01	0,16
127	23,50	24,30	0,71	0,38	26,74	7,29	2,13	-1,29
128	2,90	13,90	1,59	0,77	2,31	13,25	1,61	0,28
129	4,70	22,10	1,22	0,50	0,01	29,93	1,74	0,36
130	8,50	21,30	1,33	0,16	3,32	25,93	1,53	-0,51
131	4,10	24,70	2,22	0,49	16,16	6,32	2,18	0,35
132	2,60	22,20	1,64	0,44	11,16	5,12	2,01	-0,27
133	-0,80	12,60	1,30	2,16	0,66	12,43	0,70	2,32
134	-0,70	11,50	0,84	1,16	0,76	10,48	0,70	1,82
135	5,60	41,20	0,96	-0,43	-17,94	57,85	0,91	-1,52
136	4,60	50,20	0,76	0,96	0,62	80,13	1,25	1,71
137	18,20	55,60	1,24	-1,53	9,26	59,04	0,43	-0,87
138	24,80	48,00	0,94	-0,61	-34,30	113,79	1,36	-1,88
139	16,80	33,00	0,75	0,21	21,22	25,90	4,02	-1,36
140	17,30	31,50	0,75	0,44	12,98	61,66	1,77	2,06
141	16,00	38,80	1,03	-0,49	-3,15	54,53	0,99	-1,32
142	6,30	29,50	1,18	0,28	1,86	32,20	1,09	-0,03
143	25,30	38,50	0,90	-0,42	-2,77	64,25	1,05	-1,51
144	26,50	25,30	0,78	0,19	16,49	44,64	1,63	0,13
145	8,80	33,00	1,17	0,12	-1,10	40,03	1,15	-0,66
146	8,70	28,10	0,91	0,11	5,66	30,78	1,06	-0,24
147	9,20	55,60	0,82	0,55	-12,37	147,31	2,40	2,38
148	9,40	42,40	0,79	-0,17	42,25	22,89	2,86	1,09
149	9,10	41,70	0,81	-0,17	37,26	16,06	2,36	0,87
150	21,80	23,00	0,91	0,29	21,15	21,52	0,85	0,17
151	17,50	26,30	0,94	0,30	16,31	29,10	1,07	0,42
152	11,30	32,50	1,64	0,69	8,63	22,39	4,97	-3,09
153	4,50	29,30	1,00	0,51	4,91	27,71	0,83	0,45

EK 1'in devamı

Ö.A.N	Yüzdelik Yöntem				Moment Yöntemi			
	ξ	λ	δ	γ	ξ	λ	δ	γ
154	18,60	24,20	0,61	0,61	19,56	22,05	0,60	0,60
155	13,60	22,20	1,26	-0,37	-5,35	38,95	1,36	-2,10
156	4,40	33,40	1,02	-0,23	2,05	32,21	0,67	-0,51
157	6,60	37,20	1,23	-0,05	62,44	14,21	5,86	9,91
158	6,00	37,80	0,92	-0,19	-20,89	70,42	1,81	-1,31
159	10,50	20,30	1,56	0,39	7,89	22,84	1,54	0,13
160	4,40	42,40	1,00	-0,21	-40,25	89,81	1,88	-2,05
161	6,90	37,90	0,79	0,31	16,06	16,23	2,62	-1,05
162	5,90	37,90	0,98	0,40	-2,53	70,69	1,95	1,44
163	6,50	38,30	0,97	-0,04	28,19	7,52	1,60	0,25
164	7,20	35,60	1,03	-0,05	27,54	9,04	1,84	0,41
165	6,70	28,10	1,35	-0,76	-3,20	32,98	0,71	-1,33
166	7,00	27,80	1,56	-0,18	-88,70	128,05	3,19	-5,76
167	12,90	24,90	0,94	0,20	6,65	36,59	1,64	0,23
168	4,80	34,00	1,04	-0,50	40,59	12,39	3,05	2,99
169	9,00	37,80	0,99	-0,03	-42,48	98,36	2,44	-2,27
170	5,90	33,90	1,18	-0,39	28,92	5,34	1,54	0,68
171	10,40	39,40	0,93	-0,17	40,57	15,43	2,63	1,47
172	9,30	34,50	0,81	0,14	6,61	35,42	0,77	-0,15
173	6,70	62,10	0,69	-0,21	52,25	22,12	2,08	0,83
174	7,70	41,10	0,92	-0,34	-8,71	56,11	0,99	-1,06
175	9,50	35,30	1,22	-0,64	-15,76	56,31	1,06	-1,91
176	15,60	56,20	0,77	-0,34	-9,16	79,54	0,85	-1,05
177	10,30	56,50	0,93	-0,51	-122,80	187,96	1,61	-3,63
178	21,70	42,10	0,96	-0,57	0,19	66,76	1,22	-1,21
179	22,10	24,70	0,81	0,39	23,19	23,88	0,90	0,50
180	28,00	43,80	0,61	0,27	40,18	16,44	2,16	-0,66

EK 2 Weibull Fonksiyonunun Örnek Alan Düzeyinde Hesaplanan Parametre Değerleri
(A Değeri, Weibull-1, 2, 3 ve 4 Yöntemlerinde Örnek Alandaki Minimum Çapın Yarıısı Olarak Hesaplanmıştır.)

Ö, A, N	Weibull-1			Weibull-2		Weibull-3		Weibull-4		Weibull-5		
	α	γ	β	γ	β	γ	β	γ	β	α	γ	β
1	6,00	3,76	13,02	2,24	14,13	3,76	13,23	1,80	14,70	9,10	2,24	20,14
2	4,50	4,56	18,02	3,84	18,70	4,56	18,42	4,06	18,61	3,42	3,84	22,36
3	10,25	5,99	23,62	2,63	26,15	5,99	24,19	2,36	26,58	13,21	2,63	35,35
4	2,50	1,03	30,57	1,58	26,47	1,03	30,00	1,67	26,16	-3,93	1,58	28,90
5	2,00	1,00	27,16	1,24	29,23	1,00	31,33	1,89	26,40	-4,58	1,24	24,53
6	4,20	2,01	29,69	2,51	30,49	2,01	31,63	3,16	29,59	-2,89	2,51	32,55
7	3,10	1,19	23,73	1,48	26,82	1,19	28,54	2,60	24,12	-2,27	1,48	24,79
8	2,50	3,70	27,20	5,07	25,26	3,70	25,95	4,86	25,34	-5,50	5,07	28,49
9	8,00	3,98	34,26	5,31	35,09	3,98	35,91	9,67	34,01	-1,55	5,31	40,64
10	6,30	3,64	20,54	3,04	20,48	3,64	20,07	2,79	20,70	6,56	3,04	26,91
11	2,75	1,44	14,77	1,48	14,29	1,44	14,38	1,38	14,53	1,94	1,48	17,24
12	6,40	7,17	19,89	5,49	20,10	7,17	19,79	4,49	20,40	7,10	5,49	26,94
13	2,00	1,81	21,50	1,84	23,99	1,81	24,07	3,35	21,92	-2,70	1,84	23,50
14	1,00	1,87	8,62	1,62	8,90	1,87	8,64	1,52	9,04	0,20	1,62	9,87
15	7,25	4,77	18,77	5,28	18,06	4,77	18,20	4,88	18,17	10,21	5,28	25,46
16	5,25	3,88	21,99	4,09	22,70	3,88	22,81	4,82	22,39	3,48	4,09	27,07
17	2,70	2,09	8,53	2,20	8,86	2,09	8,94	2,16	8,89	3,95	2,20	11,10
18	2,00	2,26	7,58	1,98	7,70	2,26	7,53	1,74	7,90	2,75	1,98	11,96
19	2,00	2,43	6,62	2,68	6,08	2,43	6,16	2,46	6,15	3,21	2,68	13,72
20	3,30	1,52	30,97	1,48	33,84	1,52	33,58	2,27	31,03	-5,93	1,48	30,05
21	2,00	1,66	9,83	1,87	9,13	1,66	9,35	1,83	9,16	2,31	1,87	11,05
22	2,25	0,85	32,83	1,25	33,71	0,85	38,72	2,81	28,65	-6,75	1,25	24,53
23	3,65	1,81	33,08	1,85	32,73	1,81	32,88	3,54	29,78	-5,89	1,85	31,30
24	4,70	2,31	15,97	2,33	17,56	2,31	17,58	3,39	16,71	4,43	2,33	19,72
25	2,75	3,69	11,84	2,80	12,20	3,69	11,82	3,29	11,96	2,95	2,80	15,12
26	2,70	4,49	20,90	2,78	22,02	4,49	20,94	2,28	22,67	-1,23	2,78	25,13
27	2,00	1,36	11,17	1,11	10,01	1,36	9,43	0,89	10,85	2,10	1,11	16,45
28	2,05	3,91	35,31	1,53	41,72	3,91	36,08	3,33	36,67	-16,17	1,53	33,33
29	3,00	1,73	11,58	1,76	12,75	1,73	12,79	1,87	12,59	2,62	1,76	15,24
30	4,90	2,14	14,77	1,75	15,72	2,14	15,13	1,50	16,27	5,94	1,75	19,09
31	2,10	2,17	8,12	1,62	8,65	2,17	8,17	1,40	8,97	2,64	1,62	12,31
32	2,20	1,56	14,25	1,29	18,07	1,56	17,21	1,46	17,47	-0,62	1,29	18,21
33	2,20	0,49	30,34	0,88	32,80	0,49	45,68	1,49	27,64	-8,83	0,88	24,45
34	2,65	0,82	32,00	1,24	21,43	0,82	24,96	1,23	21,50	-0,82	1,24	26,97
35	5,70	2,18	27,31	2,77	28,54	2,18	29,58	3,06	28,18	3,23	2,77	32,23

EK 2'nin devamı

Ö, A, N	Weibull-1			Weibull-2		Weibull-3		Weibull-4		Weibull-5		
	α	γ	β	γ	β	γ	β	γ	β	α	γ	β
36	2,05	0,91	27,86	1,13	33,11	0,91	35,80	1,75	29,51	-5,54	1,13	25,17
37	2,10	0,39	51,33	0,80	75,81	0,39	122,22	4,59	51,88	-24,95	0,80	28,15
38	3,60	1,09	31,18	1,30	23,89	1,09	25,18	1,35	23,60	0,86	1,30	29,19
39	19,70	6,85	34,53	6,92	35,11	6,85	35,13	10,46	34,49	30,74	6,92	53,59
40	2,05	0,45	50,04	0,97	62,91	0,45	97,22	7,52	45,20	-17,66	0,97	31,61
41	14,50	3,14	32,97	2,65	37,10	3,14	36,30	2,70	36,99	19,34	2,65	47,24
42	8,00	5,30	28,03	4,49	29,08	5,30	28,72	5,14	28,78	6,42	4,49	36,02
43	10,35	9,13	35,84	5,81	37,76	9,13	36,90	5,79	37,77	4,72	5,81	47,11
44	2,00	3,30	8,92	3,27	9,17	3,30	9,16	3,47	9,11	1,97	3,27	11,79
45	7,15	2,02	39,34	2,73	41,12	2,02	43,11	5,62	38,37	-2,96	2,73	42,03
46	8,50	4,56	33,27	3,70	36,00	4,56	35,33	3,59	36,10	0,56	3,70	42,76
47	7,00	4,03	23,64	2,93	25,39	4,03	24,53	2,57	25,84	7,12	2,93	32,68
48	2,05	2,47	19,97	2,89	21,68	2,47	22,16	4,25	20,82	-1,67	2,89	22,77
49	4,00	1,88	17,96	2,11	18,33	1,88	18,72	2,65	17,68	3,86	2,11	20,40
50	2,55	2,11	12,03	2,22	12,33	2,11	12,43	2,25	12,30	2,10	2,22	15,47
51	17,25	5,02	32,90	3,50	33,59	5,02	32,54	2,78	34,52	26,23	3,50	53,04
52	2,05	2,82	13,51	2,33	13,87	2,82	13,49	2,85	13,47	0,38	2,33	16,44
53	2,05	1,93	12,23	2,32	12,24	1,93	12,63	2,69	11,98	1,32	2,32	14,69
54	2,10	2,10	14,64	2,19	15,25	2,10	15,36	2,74	14,75	-0,43	2,19	16,82
55	4,10	1,92	13,04	1,98	13,24	1,92	13,31	1,89	13,36	5,81	1,98	16,69
56	4,15	2,33	32,67	3,28	32,82	2,33	34,35	4,52	31,83	-4,80	3,28	34,99
57	8,90	7,19	33,58	5,41	34,35	7,19	33,78	4,63	34,75	5,49	5,41	43,38
58	3,70	2,37	14,29	2,56	15,00	2,37	15,18	2,78	14,83	4,18	2,56	17,93
59	3,05	2,30	25,12	2,59	26,55	2,30	27,03	3,16	25,89	-2,83	2,59	27,58
60	4,30	4,66	20,78	3,51	20,64	4,66	20,12	3,06	20,97	2,54	3,51	25,33
61	3,65	2,84	16,40	2,39	16,55	2,84	16,16	2,19	16,78	3,62	2,39	21,01
62	2,65	1,87	22,02	1,71	23,97	1,87	23,53	2,34	22,63	-0,39	1,71	23,68
63	5,55	1,53	33,07	2,04	34,81	1,53	36,98	3,66	32,17	-0,90	2,04	33,67
64	3,00	2,29	21,17	2,08	22,36	2,29	22,00	1,89	22,75	-1,03	2,08	25,88
65	2,65	1,74	14,80	1,64	13,81	1,74	13,65	1,54	14,02	2,17	1,64	16,15
66	4,35	1,49	52,29	1,15	61,62	1,49	57,35	4,26	48,88	-17,08	1,15	37,20
67	21,95	7,76	33,14	3,82	34,40	7,76	32,76	3,40	34,80	36,69	3,82	56,99
68	4,70	1,74	46,57	2,34	52,29	1,74	55,15	6,49	47,30	-20,20	2,34	44,39
69	4,00	2,36	20,78	2,64	20,34	2,36	20,68	3,03	19,97	1,79	2,64	23,43
70	2,65	1,31	20,90	1,61	17,90	1,31	18,85	1,49	18,23	0,33	1,61	21,90
71	3,15	4,58	21,38	3,65	22,78	4,58	22,32	3,63	22,79	-2,59	3,65	26,06
72	3,50	8,97	27,40	8,46	27,88	8,97	27,81	9,21	27,78	-7,32	8,46	31,64
73	4,15	4,62	46,96	1,69	54,82	4,62	47,80	4,58	47,83	-11,34	1,69	43,39

EK 2'nin devamı

Ö, A, N	Weibull-1			Weibull-2		Weibull-3		Weibull-4		Weibull-5		
	α	γ	β	γ	β	γ	β	γ	β	α	γ	β
74	3,15	2,91	12,21	2,24	11,96	2,91	11,51	2,02	12,17	3,37	2,24	16,74
75	4,05	2,37	17,99	2,40	19,40	2,37	19,44	2,63	19,14	3,68	2,40	22,30
76	6,40	4,41	45,55	3,48	48,06	4,41	47,00	4,14	47,25	-13,34	3,48	50,88
77	4,00	1,28	50,32	1,61	55,88	1,28	59,29	4,05	48,72	-19,63	1,61	43,73
78	7,90	3,69	34,10	3,39	36,10	3,69	35,78	3,35	36,14	2,20	3,39	42,41
79	14,80	5,65	39,47	6,54	39,72	5,65	40,07	12,05	38,71	11,95	6,54	52,41
80	3,30	1,70	29,54	1,95	30,52	1,70	31,39	2,36	29,56	-2,60	1,95	30,46
81	3,65	1,00	27,64	1,44	27,01	1,00	30,25	1,82	25,64	0,15	1,44	26,21
82	3,60	2,73	11,45	2,95	11,55	2,73	11,67	3,03	11,51	4,64	2,95	14,81
83	7,70	4,31	13,21	4,32	12,85	4,31	12,85	3,51	13,10	13,49	4,32	20,96
84	6,75	3,20	14,57	3,52	13,82	3,20	13,96	3,04	14,05	10,65	3,52	20,76
85	6,95	4,18	17,05	4,38	17,67	4,18	17,74	4,75	17,55	8,86	4,38	23,99
86	9,80	4,52	16,59	5,37	16,27	4,52	16,48	5,23	16,30	16,79	5,37	26,21
87	5,35	10,95	26,26	3,65	28,36	10,95	26,52	3,87	28,20	-1,83	3,65	31,96
88	5,90	3,63	24,71	2,48	25,16	3,63	24,00	2,75	24,79	3,59	2,48	29,62
89	8,00	4,53	20,44	3,17	21,89	4,53	21,14	3,47	21,67	10,63	3,17	28,39
90	3,65	3,15	18,68	2,84	18,03	3,15	17,80	2,37	18,50	2,07	2,84	23,39
91	5,65	4,59	22,02	4,46	22,09	4,59	22,04	4,77	21,97	4,43	4,46	27,62
92	4,20	2,57	22,72	3,21	24,32	2,57	25,03	4,96	23,36	-0,05	3,21	26,26
93	5,45	3,19	22,35	3,19	22,49	3,19	22,49	3,32	22,39	3,85	3,19	27,53
94	12,15	5,73	25,15	5,45	25,29	5,73	25,21	5,19	25,38	16,98	5,45	37,64
95	3,60	1,78	16,31	1,85	15,85	1,78	15,98	1,72	16,09	3,85	1,85	19,29
96	3,25	1,45	22,62	1,97	23,19	1,45	24,78	2,57	22,20	-0,75	1,97	25,35
97	3,80	3,15	18,25	3,73	17,76	3,15	18,08	3,67	17,79	2,69	3,73	21,94
98	5,40	5,50	19,42	3,35	20,02	5,50	19,19	2,83	20,43	4,40	3,35	25,28
99	5,60	2,87	18,36	2,63	16,44	2,87	16,25	2,02	17,14	6,93	2,63	22,77
100	3,80	1,91	21,08	2,62	19,09	1,91	20,12	2,87	18,86	1,62	2,62	22,91
101	3,95	1,64	27,12	2,28	23,91	1,64	25,46	2,77	23,23	0,36	2,28	27,20
102	4,10	1,93	21,15	2,13	21,25	1,93	21,64	2,90	20,31	2,28	2,13	23,28
103	6,80	2,16	19,66	2,41	19,33	2,16	19,68	2,57	19,14	8,51	2,41	24,67
104	3,50	2,19	16,79	2,85	16,49	2,19	17,14	3,18	16,27	1,86	2,85	19,82
105	6,50	7,03	20,95	4,72	21,24	7,03	20,70	4,88	21,18	7,29	4,72	27,53
106	6,65	3,03	16,97	2,66	17,62	3,03	17,33	2,57	17,71	9,10	2,66	23,19
107	5,10	6,07	20,62	5,87	20,65	6,07	20,61	6,70	20,49	3,52	5,87	25,59
108	9,65	2,94	23,85	2,88	25,32	2,94	25,26	3,23	24,98	13,48	2,88	33,31
109	13,80	5,15	23,68	3,50	24,32	5,15	23,51	3,27	24,50	22,99	3,50	37,57
110	4,90	3,31	29,90	3,83	28,61	3,31	29,04	3,40	28,96	-0,06	3,83	34,24
111	0,35	0,95	3,54	1,11	3,69	0,95	3,90	1,23	3,57	-0,03	1,11	3,44
112	1,95	1,49	6,72	1,55	6,78	1,49	6,84	1,48	6,85	2,87	1,55	11,16
113	0,55	1,62	4,77	1,41	4,73	1,62	4,58	1,20	4,95	0,27	1,41	5,76

EK 2'nin devamı

Ö, A, N	Weibull-1			Weibull-2		Weibull-3		Weibull-4		Weibull-5		
	α	γ	β	γ	β	γ	β	γ	β	α	γ	β
114	2,20	1,42	13,70	1,67	11,95	1,42	12,43	1,48	12,29	1,38	1,67	16,37
115	2,15	2,13	8,31	2,49	8,46	2,13	8,67	2,84	8,31	2,41	2,49	11,40
116	2,70	2,51	13,52	1,82	14,55	2,51	13,77	1,92	14,40	1,64	1,82	17,12
117	2,05	1,73	21,82	2,59	19,52	1,73	20,95	3,32	18,93	-5,09	2,59	22,74
118	2,80	1,79	15,79	2,08	15,62	1,79	16,08	2,11	15,58	1,06	2,08	19,00
119	4,25	4,17	23,30	3,91	22,13	4,17	22,00	3,76	22,21	-1,03	3,91	27,49
120	2,30	2,20	17,14	2,20	18,32	2,20	18,31	2,42	18,03	-1,77	2,20	20,60
121	3,90	2,11	22,43	1,55	26,22	2,11	24,62	2,43	24,07	-2,00	1,55	23,47
122	4,50	3,46	22,23	3,19	23,39	3,46	23,18	5,15	22,39	-1,09	3,19	25,79
123	3,35	1,94	16,25	1,89	16,63	1,94	16,56	2,08	16,34	2,08	1,89	18,92
124	11,60	3,64	19,90	4,27	19,45	3,64	19,74	4,53	19,35	19,55	4,27	30,59
125	3,85	3,98	12,57	2,36	13,78	3,98	12,94	1,95	14,23	4,25	2,36	18,10
126	3,45	2,98	11,17	2,85	11,43	2,98	11,37	3,08	11,32	4,34	2,85	14,80
127	12,40	5,75	20,69	3,77	22,15	5,75	21,42	3,17	22,56	19,73	3,77	33,45
128	2,10	3,44	6,99	3,38	6,80	3,44	6,79	3,22	6,84	2,68	3,38	8,91
129	3,00	2,40	12,36	2,84	11,95	2,40	12,23	2,84	11,94	3,21	2,84	15,22
130	4,90	3,14	15,51	3,95	14,92	3,14	15,28	3,98	14,91	5,86	3,95	19,56
131	2,70	5,32	13,52	4,69	13,41	5,32	13,28	4,74	13,40	2,10	4,69	16,50
132	1,95	4,18	11,02	3,63	11,34	4,18	11,19	3,46	11,40	1,15	3,63	13,50
133	0,25	1,40	1,32	1,18	1,30	1,40	1,23	1,02	1,36	0,26	1,18	1,55
134	0,30	1,85	1,65	1,20	1,77	1,85	1,59	0,92	1,93	0,20	1,20	2,04
135	3,45	5,97	28,29	4,20	29,74	5,97	28,98	4,06	29,82	-6,63	4,20	32,11
136	2,95	1,26	18,12	1,45	16,40	1,26	17,05	1,36	16,68	1,46	1,45	20,46
137	9,75	2,67	54,04	3,49	57,20	2,67	59,08	9,53	53,52	-12,88	3,49	59,57
138	13,05	2,86	48,68	4,46	46,96	2,86	49,17	5,77	46,09	-1,86	4,46	59,06
139	9,05	4,64	22,78	3,31	24,52	4,64	23,75	2,89	24,92	10,76	3,31	32,65
140	9,30	3,31	20,41	2,46	22,29	3,31	21,45	2,53	22,20	13,98	2,46	29,43
141	8,65	4,29	33,26	4,79	33,79	4,29	34,09	5,04	33,66	2,39	4,79	41,23
142	3,80	2,11	17,09	1,97	18,67	2,11	18,43	3,08	17,46	3,11	1,97	19,18
143	13,30	5,99	38,22	4,96	38,44	5,99	37,95	5,32	38,24	8,30	4,96	50,61
144	13,90	6,49	25,52	4,20	25,86	6,49	25,08	3,90	26,04	20,55	4,20	40,21
145	5,05	5,01	21,40	3,30	21,68	5,01	20,87	3,45	21,58	3,29	3,30	26,08
146	5,00	3,29	20,44	3,06	19,05	3,29	18,89	3,02	19,08	4,53	3,06	24,40
147	5,25	1,65	28,15	1,75	28,04	1,65	28,41	1,96	27,43	2,05	1,75	29,93
148	5,35	5,19	29,04	3,54	30,56	5,19	29,57	3,37	30,72	-2,61	3,54	36,05
149	5,20	6,65	27,54	3,79	29,63	6,65	28,42	3,36	30,00	-1,94	3,79	33,58
150	11,55	3,32	21,78	3,43	22,20	3,32	22,28	3,91	21,91	18,44	3,43	32,50
151	9,40	3,79	20,63	3,43	21,37	3,79	21,15	3,46	21,35	14,36	3,43	30,10

EK 2'nin devamı

Ö, A, N	Weibull-1			Weibull-2		Weibull-3		Weibull-4		Weibull-5		
	α	γ	β	γ	β	γ	β	γ	β	α	γ	β
152	6,30	2,74	19,72	3,31	19,99	2,74	20,47	3,98	19,63	8,11	3,31	25,48
153	2,90	1,53	14,89	1,96	15,19	1,53	16,01	2,30	14,78	1,92	1,96	17,28
154	9,95	2,39	18,61	2,63	17,47	2,39	17,72	2,26	17,88	17,22	2,63	27,65
155	7,45	6,13	20,10	6,10	20,02	6,13	20,01	5,50	20,15	8,97	6,10	27,52
156	2,85	3,01	23,74	2,81	22,95	3,01	22,76	3,57	22,33	-2,14	2,81	25,71
157	3,95	5,74	22,63	3,70	23,85	5,74	23,02	3,63	23,90	0,43	3,70	27,46
158	3,65	4,27	24,87	3,06	26,10	4,27	25,22	3,40	25,78	-1,53	3,06	28,93
159	5,90	3,70	14,07	3,91	14,83	3,70	14,91	4,55	14,63	8,97	3,91	19,95
160	2,85	4,33	26,60	3,32	27,86	4,33	27,15	3,44	27,75	-4,46	3,32	29,86
161	4,10	8,36	18,83	3,18	20,26	8,36	18,86	2,23	21,27	1,78	3,18	25,61
162	3,60	4,09	18,79	2,23	20,56	4,09	19,09	2,42	20,30	1,18	2,23	23,05
163	3,90	8,44	23,62	4,35	24,04	8,44	23,08	3,15	24,83	-0,84	4,35	29,58
164	4,25	5,21	22,65	3,93	23,22	5,21	22,69	3,34	23,60	-0,47	3,93	27,44
165	4,00	4,07	22,67	5,27	22,08	4,07	22,54	5,60	21,99	-0,63	5,27	25,46
166	4,15	4,54	18,76	4,48	19,05	4,54	19,03	4,65	18,99	2,95	4,48	22,56
167	7,10	3,69	18,59	3,29	18,89	3,69	18,67	3,31	18,88	9,30	3,29	25,34
168	3,05	4,22	24,97	4,64	24,62	4,22	24,81	4,33	24,76	-3,57	4,64	28,67
169	5,15	4,84	24,42	3,78	25,40	4,84	24,86	3,32	25,74	1,00	3,78	30,18
170	3,60	6,69	23,30	5,11	23,69	6,69	23,29	4,27	24,03	-0,82	5,11	28,34
171	5,85	5,12	27,99	3,90	28,61	5,12	27,98	3,61	28,84	0,74	3,90	33,61
172	5,30	2,16	24,57	2,72	22,66	2,16	23,47	2,73	22,64	4,81	2,72	28,13
173	4,00	5,40	40,18	3,42	42,85	5,40	41,21	3,19	43,18	-13,96	3,42	46,51
174	4,50	4,63	30,52	4,21	29,95	4,63	29,71	3,88	30,17	-0,72	4,21	34,69
175	5,40	4,70	28,81	5,46	28,13	4,70	28,43	5,28	28,19	1,33	5,46	33,30
176	8,45	5,58	46,64	4,38	44,90	5,58	44,10	4,04	45,23	-6,40	4,38	54,20
177	5,80	8,41	41,40	5,15	43,38	8,41	42,20	4,48	43,84	-6,76	5,15	49,08
178	11,50	3,49	41,09	4,50	40,47	3,49	41,42	5,57	39,83	7,53	4,50	51,23
179	11,70	3,70	22,43	3,95	21,73	3,70	21,86	3,32	22,11	20,16	3,95	34,17
180	14,65	4,84	34,27	3,33	34,05	4,84	32,90	2,64	35,03	18,87	3,33	48,75

EK 3 Johnson SB Parametre Tahmin Yöntemlerinin Nispi Sıra Değerleri

Ö. A. N	TH		OH		OMH		HKOK	
	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem
1	2	1	2	1	2	1	2	1
2	2	1	2	1	2	1	2	1
3	2	1	2	1	2	1	2	1
4	1	2	1	2	2	1	2	1
5	2	1	2	1	1	1	1	2
6	1	2	1	2	1	1	1	2
7	1	2	1	2	2	1	2	1
8	2	1	2	1	2	1	2	1
9	2	1	2	1	2	1	2	1
10	1	2	1	2	1	1	1	2
11	1	2	1	2	1	1	2	1
13	2	1	1	2	2	1	1	2
14	1	2	1	2	2	1	2	1
15	2	1	2	1	2	1	2	1
16	2	1	2	1	2	1	2	1
17	2	1	1	2	1	1	1	2
18	1	2	1	2	1	1	2	1
20	1	2	1	2	2	1	2	1
21	1	2	1	2	1	1	1	2
22	2	1	1	2	2	1	1	2
23	2	1	2	1	2	1	2	1
24	2	1	1	2	1	1	1	2
25	1	2	1	2	2	1	2	1
26	2	1	1	2	1	1	1	2
27	1	2	1	2	2	1	2	1
28	2	1	2	1	1	1	1	2
33	2	1	2	1	2	1	2	1
34	2	1	2	1	2	1	2	1
35	1	2	1	2	2	1	2	1
36	1	2	1	2	1	1	1	2
38	2	1	2	1	2	1	1	2
39	2	1	1	2	1	1	2	1
41	2	1	1	2	1	1	1	2
42	1	2	1	2	1	1	2	1
43	2	1	2	1	1	1	2	1
44	1	2	1	2	1	1	2	1
45	2	1	2	1	1	1	2	1

EK 3'ün devamı

Ö. A. N	TH		OH		OMH		HKOK	
	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem
46	1	2	1	2	1	1	1	2
47	1	2	1	2	2	1	2	1
48	1	2	1	2	1	1	1	2
49	2	1	2	1	2	1	2	1
50	1	2	1	2	1	1	2	1
51	1	2	1	2	1	1	2	1
52	2	1	1	2	2	1	1	2
53	2	1	2	1	2	1	2	1
54	1	2	1	2	2	1	2	1
55	1	2	1	2	1	1	1	2
56	1	2	1	2	2	1	2	1
57	1	2	1	2	1	1	1	2
58	1	2	1	2	2	1	2	1
59	1	2	1	2	2	1	2	1
60	1	2	1	2	2	1	2	1
62	2	1	2	1	2	1	2	1
63	1	2	1	2	2	1	2	1
64	1	2	1	2	1	1	2	1
65	1	2	1	2	2	1	2	1
66	2	1	2	1	2	1	2	1
67	1	2	1	2	1	1	2	1
68	1	2	1	2	2	1	2	1
69	2	1	2	1	2	1	2	1
70	1	2	1	2	1	1	2	1
71	2	1	2	1	2	1	2	1
72	2	1	1	2	2	1	2	1
73	1	2	1	2	1	1	1	2
74	1	2	1	2	1	1	1	2
75	2	1	2	1	1	1	2	1
76	2	1	2	1	2	1	2	1
77	2	1	2	1	2	1	2	1
78	1	2	1	2	1	1	1	2
79	2	1	2	1	2	1	2	1
80	1	2	1	2	2	1	2	1
81	2	1	2	1	2	1	2	1
82	1	2	1	2	2	1	2	1
83	2	1	2	1	2	1	2	1
84	2	1	2	1	2	1	2	1
85	1	2	1	2	1	1	2	1
86	2	1	2	1	1	1	1	2
87	2	1	2	1	2	1	2	1
88	1	2	1	2	2	1	2	1
89	2	1	2	1	1	1	1	2
90	1	2	1	2	2	1	2	1

EK 3'ün devamı

Ö. A. N	TH		OH		OMH		HKOK	
	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem
91	2	1	2	1	2	1	2	1
92	2	1	2	1	1	1	2	1
93	1	2	1	2	2	1	2	1
94	2	1	2	1	1	1	2	1
95	1	2	1	2	2	1	2	1
96	2	1	2	1	2	1	2	1
97	2	1	2	1	2	1	2	1
98	1	2	1	2	1	1	1	2
99	1	2	1	2	1	1	1	2
100	2	1	2	1	2	1	2	1
101	2	1	2	1	2	1	2	1
102	1	2	1	2	2	1	2	1
103	2	1	1	2	1	1	1	2
104	2	1	2	1	2	1	2	1
107	2	1	2	1	2	1	2	1
108	2	1	2	1	1	1	1	2
109	1	2	1	2	2	1	2	1
110	1	2	1	2	1	1	1	2
111	2	1	2	1	2	1	1	2
112	2	1	2	1	2	1	2	1
113	2	1	2	1	2	1	1	2
114	1	2	1	2	1	1	2	1
115	2	1	2	1	1	1	1	2
116	1	2	1	2	2	1	2	1
117	1	2	1	2	2	1	2	1
118	1	2	1	2	1	1	2	1
119	1	2	1	2	1	1	1	2
120	1	2	1	2	2	1	2	1
121	1	2	1	2	2	1	2	1
122	1	2	1	2	2	1	2	1
123	1	2	1	2	2	1	2	1
124	2	1	1	2	2	1	2	1
125	1	2	1	2	2	1	2	1
126	1	2	1	2	2	1	2	1
127	2	1	2	1	1	1	1	2
129	2	1	2	1	2	1	2	1
130	2	1	2	1	2	1	1	2
132	2	1	1	2	1	1	1	2
133	1	2	1	2	1	1	1	2
134	2	1	2	1	2	1	2	1
135	2	1	2	1	2	1	2	1
136	1	2	2	1	2	1	2	1
137	2	1	2	1	2	1	2	1
138	2	1	2	1	2	1	2	1

EK 3'ün devamı

Ö. A. N	TH		OH		OMH		HKOK	
	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem	Yüzdelik Yöntem	Moment Yöntem
139	1	2	1	2	1	1	1	2
140	1	2	1	2	1	1	1	2
141	1	2	1	2	2	1	2	1
142	2	1	2	1	1	1	1	2
143	1	2	1	2	2	1	2	1
144	1	2	1	2	1	1	1	2
145	1	2	1	2	1	1	1	2
146	2	1	2	1	2	1	2	1
147	1	2	1	2	1	1	2	1
148	2	1	1	2	1	1	1	2
149	1	2	1	2	1	1	1	2
150	1	2	1	2	2	1	2	1
151	1	2	1	2	1	1	1	2
152	2	1	2	1	1	1	1	2
153	2	1	2	1	2	1	2	1
154	2	1	1	2	1	1	2	1
155	2	1	2	1	1	1	1	2
156	1	2	1	2	2	1	2	1
158	2	1	2	1	2	1	2	1
159	1	2	1	2	1	1	1	2
160	2	1	2	1	2	1	2	1
161	2	1	2	1	1	1	1	2
162	1	2	1	2	1	1	1	2
164	2	1	1	2	1	1	2	1
165	2	1	2	1	2	1	2	1
166	2	1	2	1	2	1	2	1
167	2	1	2	1	2	1	2	1
169	1	2	1	2	1	1	1	2
171	1	2	1	2	1	1	1	2
172	1	2	1	2	1	1	1	2
173	2	1	1	2	1	1	1	2
174	1	2	1	2	1	1	1	2
176	2	1	2	1	2	1	2	1
177	1	2	1	2	2	1	2	1
178	1	2	1	2	1	1	1	2
179	2	1	2	1	1	1	1	2
180	2	1	1	2	1	1	1	2

EK 4 Weibull Parametre Tahmin Yöntemlerinin Nispi Sıra Değerleri

No	TH					OH					OMH					HKOK				
	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5
1	1,0	1,1	1,0	1,7	5,0	1,0	1,0	1,0	5,0	1,6	1,0	1,2	1,0	1,6	5,0	1,0	1,2	1,0	2,3	5,0
2	1,0	1,6	1,1	1,4	5,0	1,0	1,0	1,0	5,0	1,3	3,3	1,2	1,0	1,1	5,0	3,4	1,2	1,0	1,0	5,0
3	3,9	1,0	3,3	3,5	5,0	2,5	1,0	2,5	5,0	3,6	2,1	4,4	1,0	1,9	5,0	1,5	5,0	1,0	3,0	4,6
4	5,9	1,5	5,0	1,0	1,2	5,0	3,4	5,0	1,0	3,3	5,0	1,2	4,0	1,0	4,0	5,0	1,1	3,8	1,0	3,7
5	4,3	5,0	4,8	1,0	1,6	4,2	5,0	4,9	1,0	3,1	3,7	2,8	2,8	1,0	5,0	2,7	2,6	2,1	1,0	5,0
6	3,6	2,5	5,0	1,0	1,5	1,5	1,3	2,1	5,0	1,0	3,9	1,0	2,1	2,2	5,0	4,2	1,0	3,3	1,2	5,0
7	2,7	5,0	3,3	1,0	1,7	1,2	2,3	1,6	5,0	1,0	2,3	4,0	1,0	5,0	3,3	1,5	2,6	1,0	5,0	2,1
8	5,5	4,0	5,0	2,0	1,0	1,3	1,2	1,3	5,0	1,0	1,4	2,3	1,0	1,5	5,0	1,5	1,7	1,1	1,0	5,0
9	2,8	5,0	3,9	1,0	1,7	1,2	2,0	1,7	5,0	1,0	2,8	5,0	1,0	1,9	3,4	2,8	5,0	1,0	2,2	3,2
10	1,0	5,0	1,0	1,2	2,3	1,0	2,9	1,0	5,0	1,6	2,5	4,4	1,0	2,4	5,0	2,6	5,0	1,0	2,5	4,8
11	5,5	1,0	4,7	4,8	5,0	4,6	1,0	4,7	2,9	5,0	5,0	1,0	3,1	3,3	3,4	5,0	1,0	3,9	4,1	4,6
12	3,3	1,0	2,8	2,9	5,0	2,8	1,0	2,8	2,0	5,0	2,0	1,0	1,9	1,9	5,0	3,3	1,0	1,9	2,4	5,0
13	1,6	5,0	2,1	1,0	1,5	1,0	5,0	1,6	4,0	1,0	2,6	5,0	2,2	1,0	2,7	1,8	5,0	1,8	1,0	2,0
14	1,0	5,0	1,0	1,0	1,0	1,0	5,0	1,0	5,0	1,0	4,9	5,0	1,0	2,0	2,5	3,2	5,0	1,0	2,2	2,6
15	1,0	4,0	1,0	1,0	5,0	1,0	4,0	1,0	3,6	5,0	1,4	3,4	1,1	1,0	5,0	1,5	2,9	1,1	1,0	5,0
16	5,5	1,0	4,7	4,6	5,0	4,6	1,0	4,7	4,2	5,0	1,0	5,0	1,6	1,0	4,7	3,7	5,0	2,8	1,0	4,9
17	1,0	5,0	1,0	1,0	1,2	1,6	5,0	1,6	1,0	1,7	1,0	5,0	1,0	1,0	2,9	1,1	5,0	1,1	1,0	4,0
18	1,0	5,0	1,0	1,1	1,8	1,5	5,0	1,5	1,0	2,2	3,1	5,0	1,0	1,6	1,9	1,6	5,0	1,0	1,5	3,6
19	6,0	1,0	5,0	5,0	5,0	1,9	1,0	1,9	5,0	1,9	2,0	1,0	2,0	2,0	5,0	2,4	1,0	1,8	1,9	5,0
20	1,0	5,0	1,1	1,0	1,0	1,1	5,0	1,2	1,0	1,1	1,0	5,0	1,0	1,0	1,0	1,0	5,0	1,0	1,0	1,0
21	5,4	2,2	3,7	5,0	1,0	1,4	1,1	1,3	5,0	1,0	4,6	2,2	3,7	5,0	1,0	5,0	1,9	1,1	4,3	1,0
22	1,8	5,0	1,8	1,0	1,1	1,5	5,0	1,7	2,0	1,0	1,1	5,0	1,0	1,3	1,4	1,1	5,0	1,0	1,1	1,3
23	5,3	1,0	5,0	1,7	2,6	2,6	1,0	2,8	5,0	1,7	1,3	1,0	1,6	2,7	5,0	1,7	1,0	1,6	2,0	5,0
24	1,5	4,4	3,3	1,0	5,0	3,0	4,7	4,0	1,0	5,0	3,1	3,4	2,9	1,0	5,0	3,4	3,9	3,4	1,0	5,0
25	1,0	5,0	1,0	1,0	1,5	1,0	5,0	1,0	3,5	1,5	2,5	5,0	1,0	1,2	3,1	2,2	5,0	1,0	1,2	2,8
26	5,8	1,0	4,9	5,0	4,9	3,1	1,0	3,1	5,0	3,1	2,3	1,5	1,0	4,7	5,0	1,7	1,1	1,0	5,0	4,8
27	1,0	5,0	1,0	1,1	1,2	1,0	2,7	1,0	5,0	1,1	4,8	5,0	1,0	4,5	4,7	4,1	5,0	1,0	3,6	3,3
28	1,0	5,0	1,0	1,0	1,1	1,0	5,0	1,0	2,0	1,1	1,0	5,0	1,0	1,2	2,2	1,1	5,0	1,0	1,1	1,7
29	1,0	5,0	1,1	1,0	1,2	1,8	5,0	1,8	1,0	2,0	1,0	5,0	1,7	1,3	3,2	1,7	5,0	1,4	1,0	2,7
30	1,1	5,0	1,0	1,7	2,0	1,0	2,4	1,0	5,0	1,4	1,0	3,3	1,8	2,2	5,0	1,0	3,7	1,0	3,3	5,0
31	1,0	5,0	1,0	1,0	1,1	1,0	5,0	1,0	4,0	1,1	1,0	5,0	1,2	1,9	3,6	1,0	5,0	1,4	1,9	3,7
32	5,4	1,0	4,7	4,8	5,0	2,4	1,0	2,5	5,0	2,6	1,0	5,0	4,3	4,1	2,4	3,0	1,0	3,4	3,6	5,0
33	4,7	3,0	5,0	1,0	1,6	1,8	1,5	2,2	5,0	1,0	1,9	2,4	1,0	5,0	3,3	1,4	3,3	1,0	5,0	3,1
34	2,8	5,0	1,9	1,0	1,3	1,6	3,0	1,4	5,0	1,0	4,6	1,0	3,2	3,0	5,0	5,0	2,5	3,3	1,0	3,1
35	5,1	1,0	5,0	3,8	4,4	2,1	1,0	2,4	5,0	2,2	5,0	1,0	4,2	3,3	4,4	5,0	1,0	4,9	2,1	4,0
36	3,7	2,3	5,0	1,0	1,4	1,7	1,3	2,4	5,0	1,0	1,0	2,8	3,2	5,0	2,7	1,0	2,5	2,7	5,0	2,2
37	5,0	1,0	5,0	2,5	2,7	4,2	1,0	5,0	4,6	2,7	2,0	5,0	3,0	5,0	1,0	1,7	3,5	2,5	5,0	1,0

EK 4'ün devamı

No	TH					OH					OMH					HKOK				
	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5
38	2,3	5,0	1,6	1,0	1,5	1,6	5,0	1,1	4,9	1,0	2,8	5,0	1,7	1,0	1,8	2,9	5,0	1,6	1,0	2,2
39	2,7	1,0	2,5	2,3	5,0	2,3	1,0	2,5	2,0	5,0	1,7	1,6	1,4	1,0	5,0	2,5	1,0	2,3	1,4	5,0
40	4,1	5,0	4,4	1,0	1,6	3,2	5,0	4,3	3,8	1,0	1,3	2,4	2,0	5,0	1,0	1,2	2,8	1,9	5,0	1,0
41	1,0	2,0	1,2	1,5	5,0	1,0	1,5	1,1	5,0	2,9	1,0	2,0	1,3	1,6	5,0	1,0	2,3	1,9	2,2	5,0
42	1,0	5,0	1,0	1,0	2,5	1,0	2,7	1,0	5,0	1,6	3,5	3,5	1,1	1,0	5,0	2,9	4,5	1,0	1,0	5,0
43	1,0	4,7	1,0	2,0	5,0	1,0	2,8	1,0	5,0	3,0	4,3	5,0	2,1	1,0	1,8	3,7	5,0	1,0	3,1	4,9
44	6,0	3,1	4,6	4,7	1,0	2,1	1,6	2,0	5,0	1,0	5,0	2,1	3,0	3,1	1,0	5,0	1,0	2,6	3,1	1,3
45	1,3	5,0	1,4	1,0	1,1	1,4	5,0	1,5	1,0	1,3	1,1	5,0	1,2	1,1	1,0	1,1	5,0	1,1	1,0	1,1
46	1,0	5,0	1,1	1,3	1,4	1,0	2,5	1,0	5,0	1,1	1,4	2,9	1,0	5,0	2,7	1,0	4,8	2,3	4,0	5,0
47	1,0	5,0	1,0	1,3	2,3	1,0	2,9	1,0	5,0	1,6	5,0	3,4	2,5	1,0	3,7	2,6	5,0	1,0	1,7	3,3
48	1,0	5,0	1,1	1,0	1,0	1,0	2,7	1,0	5,0	1,0	2,0	5,0	2,4	2,0	1,0	2,2	5,0	2,2	1,8	1,0
49	2,8	2,3	4,2	1,0	5,0	1,0	1,0	1,2	5,0	1,3	3,2	1,0	1,0	5,0	2,6	4,6	1,9	1,0	5,0	1,7
50	5,5	1,0	4,7	4,6	5,0	2,8	1,0	2,9	5,0	3,0	5,0	1,0	3,7	3,7	4,8	5,0	1,0	3,9	3,6	4,9
51	1,0	5,0	1,0	1,1	2,5	1,0	5,0	1,0	2,1	2,5	1,0	5,0	1,1	1,0	2,3	1,0	5,0	1,1	1,2	2,3
52	1,0	5,0	1,1	1,1	1,9	1,0	5,0	1,1	5,0	1,9	2,1	5,0	1,1	1,1	1,0	1,4	5,0	1,0	1,0	1,2
53	1,1	5,0	1,3	1,0	1,3	1,0	5,0	1,2	3,3	1,2	1,7	5,0	1,4	1,0	1,8	2,1	5,0	1,7	1,0	1,9
54	1,4	5,0	2,1	1,0	1,8	1,0	1,6	1,1	5,0	1,1	5,0	3,8	3,2	3,3	1,0	5,0	3,9	1,2	2,9	1,0
55	1,0	5,0	1,0	1,1	1,6	1,0	2,1	1,0	5,0	1,2	2,6	2,6	1,0	1,0	5,0	3,1	2,8	1,0	1,0	5,0
56	1,8	5,0	2,0	1,0	1,0	1,4	3,7	1,7	5,0	1,0	1,5	5,0	1,0	1,9	2,9	2,4	5,0	1,5	1,0	3,7
57	1,0	5,0	1,0	1,1	1,4	1,0	5,0	1,0	2,7	1,4	1,6	5,0	1,0	1,8	2,5	1,7	5,0	1,0	1,8	2,2
58	1,0	5,0	1,1	1,0	1,3	1,0	3,4	1,0	5,0	1,2	2,5	5,0	1,6	1,0	4,1	2,6	5,0	1,3	1,0	3,3
59	1,4	5,0	2,1	1,0	1,1	1,1	2,0	1,2	5,0	1,0	1,0	5,0	1,0	1,0	1,7	1,6	5,0	1,0	1,8	2,2
60	1,0	5,0	1,0	1,3	1,7	1,0	2,8	1,0	5,0	1,3	1,0	5,0	1,4	1,5	2,4	1,0	5,0	1,1	1,3	2,9
61	1,0	5,0	1,0	1,0	1,0	1,0	2,7	1,0	5,0	1,0	1,3	4,1	1,0	1,2	5,0	1,5	5,0	1,0	1,0	4,9
62	1,2	5,0	1,4	1,0	1,4	1,0	2,5	1,1	5,0	1,1	1,7	5,0	1,0	2,9	1,5	1,1	5,0	1,2	3,3	1,0
63	1,8	5,0	2,0	1,0	1,3	1,4	4,8	1,8	5,0	1,0	2,0	5,0	1,3	1,0	2,2	1,5	5,0	1,0	1,1	1,6
64	1,0	5,0	1,0	1,0	1,0	1,0	4,7	1,0	5,0	1,0	1,0	5,0	1,5	2,2	2,1	1,4	5,0	1,0	2,1	2,4
65	1,0	5,0	1,0	1,1	1,2	1,0	3,1	1,0	5,0	1,1	3,0	5,0	1,0	1,4	1,6	3,5	5,0	1,0	2,0	2,0
66	5,5	1,0	5,0	3,3	3,5	4,1	1,0	4,5	5,0	3,2	5,0	4,5	4,8	1,0	3,0	2,5	5,0	2,4	2,1	1,0
67	1,0	5,0	1,0	1,0	2,0	1,0	5,0	1,0	1,5	2,0	1,0	5,0	1,1	1,1	1,9	1,0	5,0	1,1	1,2	1,9
68	5,1	1,0	5,0	3,2	3,2	3,8	1,0	4,5	5,0	2,9	1,0	4,2	1,7	2,5	5,0	2,1	3,0	2,4	1,0	5,0
69	1,2	5,0	1,2	1,0	1,3	1,0	4,2	1,1	5,0	1,1	1,9	5,0	1,2	1,0	1,0	1,7	5,0	1,1	1,1	1,0
70	1,3	5,0	1,2	1,0	1,1	1,2	5,0	1,1	3,6	1,0	2,1	5,0	1,4	1,0	1,4	2,3	5,0	1,5	1,0	1,5
71	1,0	5,0	1,0	1,6	1,3	1,0	1,7	1,0	5,0	1,1	5,0	2,7	1,8	1,0	2,1	5,0	2,6	1,6	1,0	2,6
72	1,0	1,0	5,0	4,3	1,0	1,0	1,0	1,2	5,0	1,0	2,3	1,5	1,0	1,0	5,0	1,9	1,0	1,1	1,0	5,0
73	1,0	5,0	1,2	1,2	1,7	1,0	2,4	1,1	5,0	1,2	2,6	1,8	1,1	1,0	5,0	5,0	1,0	2,6	2,6	3,2
74	1,0	5,0	1,0	1,1	1,7	1,0	3,3	1,0	5,0	1,4	2,8	5,0	2,6	1,0	2,0	2,9	5,0	2,2	1,0	1,9
75	1,0	5,0	1,2	1,1	1,5	1,0	3,6	1,1	5,0	1,3	1,6	5,0	1,0	1,6	1,2	1,5	5,0	1,0	1,6	1,3
76	1,0	5,0	1,1	1,1	1,0	1,0	5,0	1,1	2,0	1,0	1,1	5,0	1,0	1,0	1,7	1,1	5,0	1,0	1,0	1,9
77	1,7	5,0	1,8	1,0	1,0	1,5	5,0	1,8	2,0	1,0	1,0	5,0	1,1	1,2	1,6	1,0	5,0	1,0	1,1	1,5

EK 4'ün devamı

No	TH					OH					OMH					HKOK				
	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5
78	1,0	5,0	1,1	1,2	1,4	1,0	3,5	1,1	5,0	1,2	3,2	5,0	1,0	2,1	3,4	2,2	5,0	1,0	1,6	2,7
79	1,6	2,8	2,0	1,0	5,0	1,0	1,8	1,3	5,0	3,2	5,0	1,0	1,8	1,2	2,1	3,7	1,0	1,1	1,6	5,0
80	1,3	5,0	1,5	1,0	1,1	1,1	3,0	1,2	5,0	1,0	1,4	5,0	1,1	1,0	2,6	1,9	5,0	1,3	1,0	3,3
81	2,8	5,0	2,9	1,0	1,4	1,4	2,5	1,6	5,0	1,0	3,2	5,0	1,0	1,0	1,4	3,9	5,0	1,0	2,3	1,9
82	1,0	5,0	1,2	1,0	3,9	1,0	1,6	1,0	5,0	1,5	2,6	1,5	1,5	1,0	5,0	2,8	1,8	1,5	1,0	5,0
83	1,0	2,4	1,0	1,1	5,0	1,0	2,2	1,0	5,0	4,4	2,8	1,9	1,0	1,6	5,0	2,6	1,7	1,0	1,5	5,0
84	1,0	4,2	1,1	1,1	5,0	1,0	3,0	1,0	5,0	3,5	2,7	3,0	1,0	1,2	5,0	2,6	3,0	1,0	1,2	5,0
85	1,0	5,0	1,1	1,0	3,3	1,0	4,0	1,1	5,0	2,8	1,8	5,0	1,2	1,0	4,2	2,1	5,0	1,0	1,1	4,5
86	1,0	4,5	1,1	1,0	5,0	1,0	4,5	1,1	5,0	5,0	2,2	4,4	1,0	1,1	5,0	2,2	4,5	1,0	1,0	5,0
87	1,0	5,0	1,0	1,2	1,2	1,0	3,6	1,0	5,0	1,1	2,6	5,0	1,0	1,2	1,3	3,8	5,0	1,0	2,5	3,6
88	1,0	5,0	1,0	1,8	4,9	1,0	1,3	1,0	5,0	1,3	5,0	1,9	2,0	1,2	1,0	3,5	3,7	2,4	1,0	5,0
89	1,0	5,0	1,0	1,2	4,5	1,0	2,6	1,0	5,0	2,4	1,9	3,2	1,0	1,7	5,0	1,9	3,7	1,0	1,7	5,0
90	1,0	5,0	1,0	1,2	1,5	1,0	2,8	1,0	5,0	1,2	5,0	2,6	2,6	3,2	1,0	3,8	5,0	1,0	3,3	2,1
91	1,0	5,0	1,2	1,2	4,5	1,0	1,8	1,0	5,0	1,7	5,0	1,5	1,0	1,0	3,6	5,0	1,7	1,0	1,2	4,1
92	2,8	1,6	5,0	1,0	2,4	1,1	1,0	1,6	5,0	1,1	5,0	1,7	1,9	1,0	2,5	5,0	1,0	2,1	2,9	2,6
93	1,0	5,0	1,1	1,1	2,4	1,0	2,0	1,0	5,0	1,3	3,9	1,2	1,3	1,0	5,0	4,7	4,2	1,3	1,0	5,0
94	1,0	4,6	1,1	1,2	5,0	1,0	4,3	1,1	5,0	4,7	1,3	4,3	1,2	1,0	5,0	1,7	5,0	1,3	1,0	4,8
95	1,0	5,0	1,0	1,0	1,1	1,0	3,0	1,0	5,0	1,1	2,8	5,0	1,0	1,3	2,2	3,1	5,0	1,0	1,3	2,4
96	5,5	1,0	5,0	4,1	4,4	4,6	1,0	5,0	3,2	4,4	4,6	1,0	5,0	2,7	3,9	4,8	1,0	5,0	3,5	4,1
97	1,0	5,0	1,0	1,0	1,1	1,0	2,0	1,0	5,0	1,0	1,4	5,0	1,3	1,0	4,8	2,4	4,9	1,1	1,0	5,0
98	1,0	5,0	1,0	1,0	1,2	1,0	5,0	1,0	4,8	1,2	1,8	5,0	1,0	2,2	2,7	2,0	5,0	1,0	2,2	2,8
99	1,0	5,0	1,0	1,1	1,3	1,0	2,7	1,0	5,0	1,1	1,4	1,2	1,0	2,8	5,0	1,3	2,9	1,0	2,2	5,0
100	2,4	5,0	2,2	1,0	1,7	1,1	2,0	1,1	5,0	1,0	2,1	5,0	1,4	2,5	1,0	2,1	5,0	1,4	2,3	1,0
101	5,2	5,0	4,2	1,0	2,4	1,4	1,5	1,4	5,0	1,0	4,6	1,0	2,3	5,0	1,7	5,0	1,9	2,7	4,3	1,0
102	1,7	5,0	2,0	1,0	1,8	1,0	2,0	1,1	5,0	1,1	2,2	3,6	1,4	5,0	1,0	2,7	3,9	1,3	5,0	1,0
103	4,1	1,0	3,6	3,3	5,0	2,4	1,0	2,5	5,0	3,3	2,5	1,0	2,8	3,0	5,0	2,6	1,0	2,5	2,2	5,0
104	3,6	1,0	5,0	1,5	4,8	1,2	1,0	1,4	5,0	1,4	5,0	1,4	2,1	1,7	1,0	5,0	1,1	2,6	1,5	1,0
105	4,1	1,0	3,5	3,5	5,0	3,1	1,0	3,1	5,0	4,4	2,6	1,0	2,0	2,1	5,0	2,8	1,0	1,7	2,6	5,0
106	1,0	5,0	1,0	1,2	4,3	1,0	1,6	1,0	5,0	1,5	1,7	1,4	1,0	1,9	5,0	2,0	1,6	1,0	1,7	5,0
107	1,0	5,0	1,1	1,0	4,1	1,0	2,8	1,1	5,0	2,4	5,0	4,7	1,1	1,0	4,6	4,9	4,1	1,3	1,0	5,0
108	4,3	1,0	3,7	3,6	5,0	2,9	1,0	3,0	5,0	4,0	1,9	1,0	2,0	1,7	5,0	2,3	1,0	2,2	2,0	5,0
109	1,0	1,9	1,0	1,1	5,0	1,0	1,6	1,0	5,0	3,8	1,0	1,3	1,0	1,5	5,0	1,0	1,5	1,2	1,6	5,0
110	5,9	1,0	5,0	5,0	5,0	2,8	1,0	2,8	5,0	2,8	5,0	1,0	4,2	4,0	4,3	5,0	1,0	4,4	4,2	4,6
111	5,7	1,0	4,4	5,0	4,9	1,9	1,0	1,8	5,0	1,9	5,0	1,0	4,3	4,9	4,9	5,0	1,0	2,0	2,8	3,4
112	1,0	5,0	1,1	1,1	1,8	1,0	4,1	1,0	5,0	1,6	4,5	5,0	1,0	1,0	2,6	4,1	5,0	1,0	1,0	3,0
113	6,0	1,0	5,0	5,0	5,0	1,7	1,0	1,7	5,0	1,7	5,0	1,0	4,2	3,8	3,8	5,0	1,0	2,5	1,8	1,5
114	1,2	5,0	1,1	1,0	1,3	1,0	3,2	1,0	5,0	1,1	5,0	4,8	1,7	1,0	1,9	5,0	4,8	1,6	1,0	3,1
115	1,0	5,0	1,3	1,0	2,3	1,0	3,6	1,2	5,0	1,8	4,2	5,0	1,5	1,0	4,1	4,2	5,0	1,8	1,0	3,8
116	1,0	5,0	1,0	1,0	1,1	1,0	5,0	1,0	3,1	1,1	1,2	5,0	1,3	1,1	1,0	1,2	5,0	1,2	1,0	1,0
117	1,1	5,0	1,1	1,0	1,0	1,0	5,0	1,0	1,1	1,0	1,0	5,0	1,0	1,1	1,0	1,0	5,0	1,0	1,0	1,0

EK 4'ün devamı

No	TH					OH					OMH					HKOK				
	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5
118	1,0	5,0	1,1	1,0	1,1	1,3	5,0	1,4	1,0	1,4	1,0	5,0	1,1	1,0	1,1	1,1	5,0	1,1	1,0	1,1
119	1,0	5,0	1,0	1,0	1,1	1,0	5,0	1,0	2,5	1,1	1,0	5,0	1,1	1,1	1,1	1,0	5,0	1,0	1,0	1,0
120	1,0	5,0	1,4	1,2	1,4	1,0	2,4	1,2	5,0	1,1	5,0	4,7	1,0	1,8	3,0	2,9	5,0	1,0	1,6	2,6
121	1,0	5,0	2,1	1,2	1,9	1,0	2,4	1,4	5,0	1,3	1,7	1,4	1,0	1,2	5,0	2,1	2,9	1,2	1,0	5,0
122	1,8	5,0	3,2	1,0	2,7	1,0	1,4	1,2	5,0	1,1	3,7	2,5	2,2	1,0	5,0	4,0	1,7	1,0	1,6	5,0
123	1,0	5,0	1,1	1,0	1,2	1,0	3,6	1,0	5,0	1,2	2,4	5,0	1,2	1,0	1,8	2,1	5,0	1,0	1,0	1,5
131	1,0	5,0	1,0	1,0	1,0	1,0	2,7	1,0	5,0	1,0	5,0	4,2	1,0	1,0	4,9	5,0	4,4	1,0	1,0	4,8
132	6,0	1,0	4,9	4,9	5,0	1,5	1,0	1,5	5,0	1,5	3,1	1,3	1,0	2,2	5,0	5,0	1,2	1,0	2,3	4,0
133	6,0	1,0	5,0	5,0	5,0	3,8	1,0	3,8	5,0	3,8	5,0	1,0	4,9	4,8	4,8	5,0	1,0	4,9	4,6	4,6
134	6,0	1,0	5,0	4,8	5,0	3,9	1,0	3,9	5,0	3,9	5,0	1,0	4,9	4,5	4,6	5,0	1,0	4,9	4,0	4,2
135	1,0	5,0	1,0	1,1	1,0	1,2	5,0	1,2	1,0	1,2	1,3	5,0	1,0	1,3	2,0	1,1	5,0	1,0	1,3	1,7
136	5,9	1,0	4,9	4,8	5,0	2,6	1,0	2,6	5,0	2,6	4,9	5,0	2,1	1,0	2,3	5,0	1,0	2,5	1,8	3,5
137	1,3	5,0	1,4	1,0	1,0	1,4	5,0	1,5	1,0	1,2	1,2	5,0	1,4	1,0	1,1	1,5	5,0	1,6	1,0	1,6
138	1,0	5,0	1,0	1,0	1,0	1,0	5,0	1,0	1,2	1,0	1,0	5,0	1,0	1,0	1,0	1,0	5,0	1,0	1,0	1,0
139	1,0	1,3	1,0	1,5	5,0	1,0	1,1	1,0	5,0	1,9	1,8	5,0	1,7	1,0	3,8	1,1	5,0	1,0	1,0	2,6
140	1,0	5,0	1,0	1,2	4,2	1,0	2,3	1,0	5,0	2,0	1,2	2,5	1,0	1,5	5,0	2,0	2,7	1,0	2,0	5,0
141	1,0	5,0	1,5	1,1	1,9	1,0	4,5	1,5	5,0	1,8	3,1	5,0	1,7	1,0	2,0	2,7	5,0	1,9	1,0	2,3
142	1,1	5,0	1,2	1,0	1,3	1,0	4,4	1,1	5,0	1,2	2,2	5,0	1,7	1,0	2,2	1,3	5,0	1,0	1,2	1,1
143	1,0	5,0	1,0	1,1	2,1	1,5	5,0	1,5	1,0	2,4	1,4	5,0	1,0	1,1	2,4	1,3	5,0	1,0	1,2	2,1
144	1,0	5,0	1,0	1,0	2,6	1,2	5,0	1,2	1,0	2,7	1,5	5,0	1,2	1,0	2,5	1,1	5,0	1,0	1,4	2,6
145	1,0	5,0	1,0	1,0	1,4	1,0	5,0	1,0	4,9	1,4	1,5	5,0	1,0	1,5	3,2	1,9	5,0	1,0	1,3	2,5
146	1,0	5,0	1,0	1,1	2,1	1,0	2,7	1,0	5,0	1,5	2,4	5,0	1,0	1,9	4,1	1,6	5,0	1,0	1,0	2,4
147	1,2	5,0	1,3	1,0	1,2	1,0	4,2	1,1	5,0	1,0	2,0	5,0	1,6	1,0	2,1	1,8	5,0	1,5	1,0	1,8
148	5,6	1,0	4,7	5,0	4,9	4,8	1,0	4,8	4,0	5,0	2,6	1,0	2,6	4,0	5,0	3,6	1,0	3,3	4,3	5,0
149	1,0	5,0	1,0	1,3	1,1	1,0	2,7	1,0	5,0	1,0	5,0	4,0	1,0	2,7	3,6	5,0	4,4	1,0	3,1	4,3
150	1,0	1,4	1,1	1,0	5,0	1,0	1,3	1,1	5,0	3,7	2,1	1,7	1,1	1,0	5,0	2,0	1,9	1,1	1,0	5,0
151	1,0	2,3	1,1	1,2	5,0	1,0	2,3	1,1	3,9	5,0	2,0	2,4	1,0	1,3	5,0	1,3	2,1	1,0	1,2	5,0
152	1,0	5,0	1,1	1,0	1,7	1,0	5,0	1,1	3,5	1,7	2,9	5,0	2,5	1,0	4,7	2,3	5,0	2,0	1,0	4,0
153	1,7	5,0	2,1	1,0	1,6	1,0	3,5	1,4	5,0	1,1	5,0	3,9	3,3	1,0	2,1	5,0	4,9	3,1	1,0	2,4
154	3,7	1,0	3,2	3,2	5,0	3,2	1,0	3,2	2,7	5,0	4,4	1,0	3,3	3,5	5,0	3,2	1,0	2,7	2,8	5,0
155	3,2	1,0	2,8	2,8	5,0	2,7	1,0	2,7	5,0	4,8	3,3	1,0	1,7	1,8	5,0	3,0	1,0	1,8	2,1	5,0
156	5,9	1,0	5,0	4,8	5,0	5,0	1,0	5,0	4,0	5,0	4,9	1,0	4,6	4,5	5,0	4,6	1,0	4,3	4,1	5,0
157	5,3	1,0	4,4	4,7	5,0	2,0	1,0	2,0	5,0	2,1	5,0	1,0	2,0	1,8	1,6	5,0	2,8	1,0	4,1	5,0
158	1,0	5,0	1,1	1,4	1,5	1,0	5,0	1,1	4,7	1,5	2,6	5,0	1,0	1,3	2,4	1,9	5,0	1,0	1,7	3,0
159	1,0	5,0	1,1	1,0	4,5	1,0	5,0	1,1	4,5	4,5	2,0	3,6	1,1	1,0	5,0	1,9	3,8	1,4	1,0	5,0
160	5,1	1,0	4,4	5,0	4,5	4,8	1,5	4,9	1,0	5,0	3,9	4,6	1,0	3,4	5,0	2,4	2,9	1,0	2,7	5,0
161	5,5	1,0	4,6	5,0	4,8	2,2	1,0	2,2	5,0	2,3	5,0	2,3	1,0	2,5	2,4	3,8	3,6	1,0	5,0	4,8
162	5,1	1,0	4,3	4,6	5,0	4,3	1,0	4,3	2,6	5,0	2,9	1,0	5,0	3,4	3,4	1,2	2,1	1,0	3,8	5,0
163	5,9	1,0	4,9	5,0	4,9	5,0	1,0	5,0	4,5	5,0	3,7	5,0	1,0	2,9	1,9	2,0	2,7	1,0	5,0	4,6
164	1,0	1,6	1,0	5,0	2,7	1,0	1,0	1,0	5,0	1,1	3,2	3,6	1,0	5,0	4,8	3,4	3,2	1,0	4,9	5,0

EK 4'ün devamı

No	TH					OH					OMH					HKOK				
	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5	W1	W2	W3	W4	W5
165	1,5	5,0	2,1	1,0	1,1	1,1	2,1	1,3	5,0	1,0	5,0	1,3	3,4	1,0	4,1	5,0	1,9	3,3	1,0	3,8
166	1,0	5,0	1,0	1,0	1,3	1,0	3,1	1,0	5,0	1,2	2,7	4,4	1,1	1,0	5,0	2,3	5,0	1,1	1,0	4,0
167	1,0	5,0	1,1	1,2	4,5	1,0	2,5	1,0	5,0	2,3	2,0	2,5	1,1	1,0	5,0	1,9	2,9	1,0	1,1	5,0
168	1,2	5,0	2,0	1,9	1,0	1,0	2,0	1,2	5,0	1,0	2,8	2,6	1,0	1,0	5,0	3,1	2,2	1,1	1,0	5,0
169	1,0	5,0	1,0	1,2	1,2	1,0	2,6	1,0	5,0	1,1	5,0	4,3	3,2	1,0	1,0	5,0	3,1	2,2	1,3	1,0
170	1,0	5,0	1,0	1,1	1,0	1,0	3,0	1,0	5,0	1,0	3,9	5,0	1,0	1,7	1,6	3,7	5,0	1,0	2,8	2,7
171	1,0	5,0	1,2	1,6	1,5	1,0	2,8	1,1	5,0	1,2	1,3	5,0	1,0	1,5	1,1	1,4	5,0	1,0	2,7	2,9
172	4,4	1,0	3,9	2,8	5,0	2,3	1,0	2,3	5,0	2,9	2,5	2,8	2,8	1,0	5,0	4,8	5,0	2,3	1,0	3,1
173	5,8	1,0	4,9	5,0	4,9	5,0	1,0	5,0	4,4	5,0	1,3	1,4	2,1	1,0	5,0	1,0	1,1	1,3	1,9	5,0
174	1,0	5,0	1,3	2,4	2,4	1,0	1,4	1,0	5,0	1,1	5,0	2,8	1,0	2,7	4,4	3,8	2,8	1,0	3,1	5,0
175	1,0	5,0	1,1	1,0	1,1	1,0	3,2	1,0	5,0	1,1	3,2	5,0	2,2	1,0	2,4	3,2	5,0	1,8	1,0	1,8
176	1,0	5,0	1,0	1,2	1,1	1,0	5,0	1,0	2,6	1,1	1,2	5,0	1,4	1,0	1,4	1,0	5,0	1,2	1,0	1,5
177	1,0	5,0	1,0	1,4	1,0	1,0	3,9	1,0	5,0	1,0	1,3	4,3	1,0	1,4	5,0	1,2	4,9	1,0	2,6	5,0
178	4,7	1,0	4,2	3,6	5,0	3,8	1,0	4,0	5,0	4,7	2,7	1,2	2,6	1,0	5,0	4,5	1,0	4,0	2,4	5,0
179	1,0	2,7	1,0	1,1	5,0	1,0	2,4	1,0	5,0	4,4	2,1	1,5	1,0	1,1	5,0	1,8	2,1	1,0	1,3	5,0
180	2,3	1,0	2,0	2,4	5,0	2,0	1,0	1,9	5,0	4,7	1,0	3,5	1,1	2,1	5,0	1,1	3,2	1,0	2,8	5,0

EK 5 Çap dağılım modellerinin nispi sıra numarası (JSB: Johnson SB-Moment, W3: Weibull-3)

No	TH			OH			OMH			HKOK		
	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM
1	1,1	1,0	3,0	1,1	1,0	3,0	1,0	2,1	3,0	1,0	2,1	3,0
2	3,0	1,0	3,0	3,0	1,0	3,0	1,8	1,0	3,0	1,8	1,0	3,0
3	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,5	3,0	1,5	1,0	3,0
4	2,4	3,0	1,0	2,4	3,0	1,0	2,2	3,0	1,0	2,4	3,0	1,0
5	2,3	3,0	1,0	2,3	3,0	1,0	1,9	3,0	1,0	2,5	3,0	1,0
6	2,2	3,0	1,0	2,2	3,0	1,0	2,6	3,0	1,0	2,4	3,0	1,0
7	1,0	3,0	1,7	1,0	3,0	1,7	1,9	1,0	3,0	1,0	1,7	3,0
8	1,1	1,0	3,0	1,1	1,0	3,0	1,6	1,0	3,0	2,1	1,0	3,0
9	1,6	3,0	1,0	1,6	3,0	1,0	1,0	3,0	1,2	1,0	1,8	3,0
10	1,0	1,0	3,0	1,0	1,0	3,0	1,2	1,0	3,0	1,3	1,0	3,0
11	2,7	3,0	1,0	2,7	3,0	1,0	2,3	3,0	1,0	2,7	3,0	1,0
13	2,5	3,0	1,0	2,5	3,0	1,0	2,4	3,0	1,0	2,4	3,0	1,0
14	3,0	3,0	1,0	3,0	3,0	1,0	1,4	1,0	3,0	3,0	2,3	1,0
15	3,0	3,0	1,0	3,0	3,0	1,0	1,0	1,1	3,0	2,2	3,0	1,0
16	2,9	3,0	1,0	2,9	3,0	1,0	2,9	3,0	1,0	3,0	3,0	1,0
17	3,0	3,0	1,0	3,0	3,0	1,0	3,0	3,0	1,0	2,9	3,0	1,0
18	3,0	3,0	1,0	3,0	3,0	1,0	2,9	3,0	1,0	2,9	3,0	1,0
20	1,0	2,1	3,0	1,0	2,1	3,0	1,0	1,0	3,0	2,4	3,0	1,0
21	2,4	1,0	3,0	2,4	1,0	3,0	1,3	1,0	3,0	1,3	1,0	3,0
22	2,2	3,0	1,0	2,2	3,0	1,0	2,4	3,0	1,0	2,5	3,0	1,0
23	2,1	3,0	1,0	2,1	3,0	1,0	2,6	3,0	1,0	2,1	3,0	1,0
24	1,0	1,3	3,0	1,0	1,3	3,0	1,0	1,4	3,0	1,0	1,7	3,0
25	1,0	1,2	3,0	1,0	1,2	3,0	3,0	1,0	3,0	3,0	1,0	1,7
26	3,0	3,0	1,0	3,0	3,0	1,0	3,0	1,0	2,8	3,0	1,0	1,9
27	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,2	3,0
28	3,0	3,0	1,0	3,0	3,0	1,0	3,0	2,9	1,0	3,0	2,5	1,0
29	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,2	3,0	1,0	1,2	3,0
30	3,0	3,0	1,0	3,0	3,0	1,0	2,7	3,0	1,0	3,0	2,7	1,0
31	3,0	3,0	1,0	3,0	3,0	1,0	1,7	1,0	3,0	1,4	1,0	3,0
32	2,9	3,0	1,0	2,9	3,0	1,0	1,0	2,6	3,0	3,0	2,9	1,0
33	1,0	3,0	1,5	1,0	3,0	1,5	1,0	2,0	3,0	1,0	1,5	3,0
34	1,0	2,1	3,0	1,0	2,1	3,0	1,8	3,0	1,0	1,6	3,0	1,0
35	2,7	3,0	1,0	2,7	3,0	1,0	2,6	3,0	1,0	2,4	3,0	1,0
36	1,1	3,0	1,0	1,1	3,0	1,0	1,0	3,0	2,6	2,1	3,0	1,0
38	2,7	3,0	1,0	2,7	3,0	1,0	2,2	3,0	1,0	2,5	3,0	1,0

EK 5'in devamı

No	TH			OH			OMH			HKOK		
	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM
39	2,9	3,0	1,0	2,9	3,0	1,0	3,0	2,7	1,0	3,0	2,8	1,0
41	2,9	3,0	1,0	2,9	3,0	1,0	1,9	1,0	3,0	2,5	3,0	1,0
42	1,0	1,0	3,0	1,0	1,0	3,0	1,1	1,0	3,0	1,6	1,0	3,0
43	3,0	2,7	1,0	3,0	2,7	1,0	1,0	3,0	2,3	3,0	1,2	1,0
44	3,0	2,9	1,0	3,0	2,9	1,0	1,3	1,0	3,0	1,0	1,4	3,0
45	2,2	3,0	1,0	2,2	3,0	1,0	1,8	3,0	1,0	2,6	3,0	1,0
46	1,0	1,1	3,0	1,0	1,1	3,0	3,0	1,9	1,0	3,0	2,0	1,0
47	1,1	1,0	3,0	1,1	1,0	3,0	1,1	3,0	1,0	1,7	1,0	3,0
48	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,1	3,0	1,0	1,0	3,0
49	1,0	1,5	3,0	1,0	1,5	3,0	1,0	1,8	3,0	1,0	1,3	3,0
50	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,0	3,0
51	3,0	3,0	1,0	3,0	3,0	1,0	2,9	3,0	1,0	3,0	2,6	1,0
52	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,0	3,0
53	1,0	3,0	1,7	1,0	3,0	1,7	1,0	3,0	1,5	1,8	3,0	1,0
54	1,0	1,2	3,0	1,0	1,2	3,0	1,0	1,2	3,0	1,0	1,0	3,0
55	1,0	1,0	3,0	1,0	1,0	3,0	1,1	1,0	3,0	1,2	1,0	3,0
56	1,0	2,6	3,0	1,0	2,6	3,0	3,0	1,4	1,0	1,0	3,0	2,7
57	3,0	3,0	1,0	3,0	3,0	1,0	3,0	1,0	1,9	3,0	1,0	1,3
58	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,5	3,0	1,0	1,2	3,0
59	1,0	1,7	3,0	1,0	1,7	3,0	1,0	1,5	3,0	1,0	1,0	3,0
60	1,0	1,0	3,0	1,0	1,0	3,0	1,6	1,0	3,0	1,6	1,0	3,0
62	1,0	1,2	3,0	1,0	1,2	3,0	1,3	1,0	3,0	1,1	1,0	3,0
63	1,0	3,0	2,1	1,0	3,0	2,1	1,5	3,0	1,0	1,0	3,0	1,8
64	2,4	3,0	1,0	2,4	3,0	1,0	1,6	1,0	3,0	1,7	1,0	3,0
65	1,0	1,1	3,0	1,0	1,1	3,0	1,0	2,4	3,0	1,0	1,8	3,0
66	2,7	3,0	1,0	2,7	3,0	1,0	2,3	3,0	1,0	2,1	3,0	1,0
67	3,0	3,0	1,0	3,0	3,0	1,0	1,5	3,0	1,0	2,6	3,0	1,0
68	2,0	3,0	1,0	2,0	3,0	1,0	3,0	2,8	1,0	2,8	3,0	1,0
71	1,3	1,0	3,0	1,3	1,0	3,0	1,3	1,0	3,0	1,4	1,0	3,0
72	3,0	1,4	1,0	3,0	1,4	1,0	1,6	1,0	3,0	1,6	1,0	3,0
73	1,1	1,0	3,0	1,1	1,0	3,0	2,3	3,0	1,0	1,1	3,0	1,0
74	1,0	1,0	3,0	1,0	1,0	3,0	1,0	2,7	3,0	1,0	2,7	3,0
75	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,5	3,0	1,0	1,3	3,0
76	3,0	2,8	1,0	3,0	2,8	1,0	3,0	2,8	1,0	3,0	2,5	1,0
77	2,5	3,0	1,0	2,5	3,0	1,0	2,2	3,0	1,0	2,2	3,0	1,0
78	1,0	1,6	3,0	1,0	1,6	3,0	3,0	1,0	1,9	3,0	1,0	3,0
79	1,0	1,9	3,0	1,0	1,9	3,0	1,0	1,5	3,0	1,5	1,0	3,0
80	1,0	1,9	3,0	1,0	1,9	3,0	1,0	1,9	3,0	1,0	1,9	3,0
81	1,0	2,2	3,0	1,0	2,2	3,0	1,0	3,0	2,7	1,0	2,9	3,0

EK 5'in devamı

No	TH			OH			OMH			HKOK		
	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM
82	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,2	3,0	1,0	1,3	3,0
83	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,3	3,0	1,0	1,4	3,0
84	1,0	1,5	3,0	1,0	1,5	3,0	1,0	1,9	3,0	1,0	2,0	3,0
85	1,0	1,2	3,0	1,0	1,2	3,0	2,0	1,0	3,0	2,3	1,0	3,0
86	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,2	3,0	1,0	1,2	3,0
87	1,1	1,0	3,0	1,1	1,0	3,0	1,2	1,0	3,0	2,2	1,0	3,0
88	1,0	1,0	3,0	1,0	1,0	3,0	3,0	1,0	1,0	3,0	1,0	2,7
89	1,0	1,0	3,0	1,0	1,0	3,0	1,5	1,0	3,0	1,4	1,0	3,0
90	1,0	1,0	3,0	1,0	1,0	3,0	3,0	1,6	1,0	3,0	1,0	2,8
91	1,0	1,0	3,0	1,0	1,0	3,0	1,1	1,0	3,0	1,4	1,0	3,0
92	1,0	3,0	2,7	1,0	3,0	2,7	1,0	2,0	3,0	1,0	1,7	3,0
93	1,0	1,3	3,0	1,0	1,3	3,0	1,6	1,0	3,0	1,4	1,0	3,0
94	1,4	1,0	3,0	1,4	1,0	3,0	1,0	2,4	3,0	1,0	1,6	3,0
95	1,0	1,0	3,0	1,0	1,0	3,0	1,2	1,0	3,0	1,1	1,0	3,0
96	2,3	3,0	1,0	2,3	3,0	1,0	2,7	3,0	1,0	2,6	3,0	1,0
97	1,0	1,0	3,0	1,0	1,0	3,0	1,2	1,0	3,0	1,4	1,0	3,0
98	1,0	1,0	3,0	1,0	1,0	3,0	2,0	1,0	3,0	2,2	1,0	3,0
99	1,0	1,1	3,0	1,0	1,1	3,0	2,7	1,0	3,0	2,0	1,0	3,0
100	1,0	3,0	2,1	1,0	3,0	2,1	1,0	2,0	3,0	1,0	2,2	3,0
101	1,0	2,2	3,0	1,0	2,2	3,0	1,0	2,4	3,0	1,0	2,7	3,0
102	1,0	1,7	3,0	1,0	1,7	3,0	2,9	1,0	3,0	1,1	1,0	3,0
103	1,0	2,3	3,0	1,0	2,3	3,0	2,9	3,0	1,0	2,3	3,0	1,0
104	1,0	1,5	3,0	1,0	1,5	3,0	1,1	1,0	3,0	1,0	1,1	3,0
107	3,0	3,0	1,0	3,0	3,0	1,0	3,0	2,2	1,0	3,0	1,9	1,0
108	3,0	3,0	1,0	3,0	3,0	1,0	2,3	3,0	1,0	2,6	3,0	1,0
109	1,1	1,0	3,0	1,1	1,0	3,0	2,8	1,0	3,0	2,5	1,0	3,0
110	3,0	3,0	1,0	3,0	3,0	1,0	2,5	3,0	1,0	2,7	3,0	1,0
111	3,0	2,7	1,0	3,0	2,7	1,0	1,3	1,0	3,0	1,6	1,0	3,0
112	1,0	1,6	3,0	1,0	1,6	3,0	1,0	1,6	3,0	1,0	1,7	3,0
113	3,0	3,0	1,0	3,0	3,0	1,0	1,0	3,0	1,3	2,2	3,0	1,0
114	2,7	3,0	1,0	2,7	3,0	1,0	1,0	2,5	3,0	2,1	3,0	1,0
115	1,0	1,3	3,0	1,0	1,3	3,0	1,0	1,5	3,0	1,0	1,6	3,0
116	1,0	1,0	3,0	1,0	1,0	3,0	1,0	3,0	1,6	1,0	3,0	1,4
117	1,0	1,2	3,0	1,0	1,2	3,0	1,0	1,0	3,0	1,0	1,1	3,0
118	1,0	1,3	3,0	1,0	1,3	3,0	1,0	1,3	3,0	1,0	1,4	3,0
119	1,2	1,0	3,0	1,2	1,0	3,0	3,0	1,9	1,0	2,6	3,0	1,0
120	1,0	1,2	3,0	1,0	1,2	3,0	1,0	1,0	3,0	1,1	1,0	3,0
121	1,0	1,4	3,0	1,0	1,4	3,0	3,0	1,9	1,0	2,7	3,0	1,0
122	1,0	1,4	3,0	1,0	1,4	3,0	1,0	1,3	3,0	1,0	1,1	3,0
123	1,0	1,4	3,0	1,0	1,4	3,0	1,0	3,0	2,7	1,0	3,0	3,0

EK 5'in devamı

No	TH			OH			OMH			HKOK		
	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM
124	2,8	3,0	1,0	2,8	3,0	1,0	3,0	1,8	1,0	2,8	3,0	1,0
125	1,0	1,3	3,0	1,0	1,3	3,0	2,0	1,0	3,0	2,3	1,0	3,0
126	1,0	1,0	3,0	1,0	1,0	3,0	1,2	1,0	3,0	1,1	1,0	3,0
127	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,2	3,0	2,3	1,0	3,0
128	3,0	3,0	1,0	3,0	3,0	1,0	1,0	1,0	3,0	1,0	1,3	3,0
129	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,5	3,0
130	1,0	1,1	3,0	1,0	1,1	3,0	1,0	1,5	3,0	1,0	2,2	3,0
132	1,0	1,0	3,0	1,0	1,0	3,0	1,3	1,0	3,0	2,1	1,0	3,0
133	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,4	3,0	1,0	2,3	3,0
134	3,0	3,0	1,0	3,0	3,0	1,0	2,5	3,0	1,0	2,4	3,0	1,0
135	3,0	2,9	1,0	3,0	2,9	1,0	3,0	1,2	1,0	3,0	1,4	1,0
137	2,6	3,0	1,0	2,6	3,0	1,0	2,2	3,0	1,0	2,8	3,0	1,0
138	1,0	2,2	3,0	1,0	2,2	3,0	1,4	1,0	3,0	1,4	1,0	3,0
139	1,0	1,0	3,0	1,0	1,0	3,0	1,3	1,0	3,0	1,7	1,0	3,0
140	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,6	3,0	1,3	1,0	3,0
141	1,4	3,0	1,0	1,4	3,0	1,0	3,0	2,2	1,0	3,0	1,6	1,0
142	1,0	1,7	3,0	1,0	1,7	3,0	1,0	1,9	3,0	1,0	1,2	3,0
143	2,3	3,0	1,0	2,3	3,0	1,0	3,0	1,0	1,4	3,0	1,2	1,0
144	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,4	3,0	3,0	1,0	1,2
145	2,9	3,0	1,0	2,9	3,0	1,0	3,0	2,0	1,0	3,0	1,8	1,0
146	1,0	1,1	3,0	1,0	1,1	3,0	1,1	1,0	3,0	1,0	1,1	3,0
147	1,0	1,4	3,0	1,0	1,4	3,0	1,4	3,0	1,0	1,5	3,0	1,0
148	3,0	2,2	1,0	3,0	2,2	1,0	1,9	1,0	3,0	3,0	1,1	1,0
149	1,0	1,0	3,0	1,0	1,0	3,0	1,9	1,0	3,0	2,3	1,0	3,0
150	1,0	1,4	3,0	1,0	1,4	3,0	1,0	2,0	3,0	1,0	2,2	3,0
151	3,0	3,0	1,0	3,0	3,0	1,0	2,5	3,0	1,0	2,7	3,0	1,0
152	2,9	3,0	1,0	2,9	3,0	1,0	1,4	3,0	1,0	2,1	3,0	1,0
153	1,0	3,0	2,6	1,0	3,0	2,6	1,0	3,0	1,5	1,3	3,0	1,0
154	2,9	3,0	1,0	2,9	3,0	1,0	1,8	3,0	1,0	2,2	3,0	1,0
155	3,0	3,0	1,0	3,0	3,0	1,0	3,0	1,2	1,0	3,0	1,4	1,0
156	2,9	3,0	1,0	2,9	3,0	1,0	2,4	3,0	1,0	2,9	3,0	1,0
158	3,0	2,9	1,0	3,0	2,9	1,0	3,0	2,0	1,0	3,0	1,1	1,0
159	2,9	3,0	1,0	2,9	3,0	1,0	2,3	3,0	1,0	1,7	3,0	1,0
160	3,0	3,0	1,0	3,0	3,0	1,0	3,0	1,6	1,0	3,0	2,0	1,0
161	1,0	1,0	3,0	1,0	1,0	3,0	2,5	1,0	3,0	3,0	1,0	2,0
162	3,0	3,0	1,0	3,0	3,0	1,0	1,6	3,0	1,0	3,0	2,4	1,0
164	3,0	3,0	1,0	3,0	3,0	1,0	3,0	1,0	1,0	3,0	1,5	1,0
165	1,0	1,5	3,0	1,0	1,5	3,0	2,9	1,0	3,0	2,7	1,0	3,0
166	1,0	1,0	3,0	1,0	1,0	3,0	2,1	1,0	3,0	1,7	1,0	3,0
167	1,0	1,1	3,0	1,0	1,1	3,0	1,4	1,0	3,0	1,5	1,0	3,0

EK 5'in devamı

No	TH			OH			OMH			HKOK		
	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM	JSBM	W3	BYSAM
169	1,5	1,0	3,0	1,5	1,0	3,0	1,6	1,0	3,0	1,7	1,0	3,0
171	3,0	3,0	1,0	3,0	3,0	1,0	1,9	1,0	3,0	3,0	1,0	1,7
172	2,8	3,0	1,0	2,8	3,0	1,0	2,7	3,0	1,0	2,7	3,0	1,0
173	1,2	1,0	3,0	1,2	1,0	3,0	1,0	1,5	3,0	2,6	1,0	3,0
174	3,0	3,0	1,0	3,0	3,0	1,0	3,0	2,8	1,0	3,0	2,1	1,0
175	1,0	1,1	3,0	1,0	1,1	3,0	2,0	1,0	3,0	1,9	1,0	3,0
176	3,0	2,6	1,0	3,0	2,6	1,0	1,4	3,0	1,0	2,1	3,0	1,0
177	3,0	3,0	1,0	3,0	3,0	1,0	3,0	2,4	1,0	3,0	1,5	1,0
178	2,8	3,0	1,0	2,8	3,0	1,0	2,3	3,0	1,0	2,3	3,0	1,0
179	1,0	1,0	3,0	1,0	1,0	3,0	1,0	1,5	3,0	1,0	1,4	3,0
180	1,0	1,0	3,0	1,0	1,0	3,0	1,7	1,0	3,0	2,6	1,0	3,0

EK 6 Çap dağılım modellerinin Kolmogorov-Smirnov Testi sonuçları (1: Teorik dağılım örnek dağılımına uygun; 0: Uygun değil)

No	n	KS	JSBM		W3		BYSAM	
			Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç
1	29	0,246	0,082	1	0,131	1	0,199	1
2	34	0,230	0,068	1	0,096	1	0,136	1
3	20	0,294	0,074	1	0,169	1	1,021	0
4	29	0,246	0,069	1	0,163	1	0,679	0
5	36	0,227	0,103	1	0,214	1	0,710	0
6	26	0,264	0,099	1	0,147	1	0,376	0
7	30	0,238	0,091	1	0,224	1	0,102	1
8	27	0,258	0,111	1	0,161	1	0,285	0
9	14	0,349	0,149	1	0,215	1	0,188	1
10	26	0,264	0,059	1	0,046	1	0,157	1
11	38	0,221	0,088	1	0,104	1	0,892	0
12	32	0,234	0,071	1	0,159	1	0,512	0
13	48	0,196	0,135	1	0,184	1	0,373	0
14	85	0,148	0,110	1	0,106	1	0,174	0
15	34	0,230	0,057	1	0,066	1	0,219	1
16	33	0,232	0,066	1	0,096	1	0,262	0
17	80	0,152	0,039	1	0,062	1	0,736	0
18	92	0,142	0,034	1	0,059	1	0,796	0
19	139	0,115	0,136	0	0,048	1	0,298	0
20	23	0,280	0,099	1	0,137	1	1,244	0
21	77	0,155	0,050	1	0,061	1	0,489	0
22	28	0,252	0,116	1	0,316	0	0,174	1
23	21	0,289	0,100	1	0,187	1	0,287	1
24	29	0,246	0,019	1	0,117	1	1,520	0
25	70	0,163	0,090	1	0,108	1	0,508	0
26	43	0,207	0,102	1	0,082	1	0,312	0
27	52	0,189	0,070	1	0,179	1	0,836	0
28	16	0,328	0,177	1	0,244	1	0,182	1
29	32	0,234	0,090	1	0,101	1	1,372	0
30	28	0,252	0,101	1	0,085	1	0,435	0
31	68	0,165	0,042	1	0,055	1	0,292	0
32	35	0,230	0,102	1	0,120	1	0,489	0
33	15	0,338	0,085	1	0,326	1	0,211	1

No	n	KS	JSBM		W3		BYSAM	
			Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç
34	32	0,234	0,124	1	0,155	1	0,251	0
35	38	0,221	0,052	1	0,146	1	0,107	1
36	35	0,230	0,129	1	0,214	1	0,492	0
37	17	0,318	1,866	0	0,456	0	0,561	0
38	35	0,230	0,074	1	0,099	1	0,154	1
39	17	0,318	0,119	1	0,168	1	0,266	1
40	24	0,275	0,996	0	0,464	0	0,684	0
41	23	0,280	0,086	1	0,199	1	0,338	0
42	26	0,264	0,108	1	0,110	1	0,332	0
43	17	0,318	0,130	1	0,110	1	0,403	0
44	67	0,166	0,061	1	0,018	1	0,320	0
45	19	0,301	0,114	1	0,276	1	0,753	0
46	15	0,338	0,201	1	0,226	1	0,254	1
47	34	0,230	0,096	1	0,110	1	0,220	1
48	62	0,173	0,086	1	0,135	1	0,442	0
49	53	0,187	0,048	1	0,119	1	0,350	0
50	48	0,196	0,063	1	0,033	1	0,756	0
51	17	0,318	0,106	1	0,157	1	0,117	1
52	48	0,196	0,079	1	0,135	1	0,927	0
53	65	0,169	0,042	1	0,113	1	0,522	0
54	37	0,224	0,048	1	0,117	1	0,654	0
55	59	0,177	0,044	1	0,025	1	0,453	0
56	25	0,270	0,076	1	0,171	1	0,220	1
57	24	0,275	0,085	1	0,066	1	0,212	1
58	59	0,177	0,041	1	0,086	1	0,291	0
59	34	0,230	0,052	1	0,099	1	0,246	0
60	38	0,221	0,067	1	0,093	1	0,274	0
61	58	0,179	0,065	1	0,047	1	0,640	0
62	61	0,174	0,070	1	0,083	1	0,485	0
63	26	0,264	0,087	1	0,252	1	0,165	1
64	34	0,230	0,148	1	0,056	1	0,531	0
65	50	0,192	0,069	1	0,099	1	0,262	0
66	17	0,318	0,220	1	0,311	1	0,288	1
67	12	0,393	0,059	1	0,209	1	0,267	1
68	13	0,361	0,169	1	0,337	1	0,309	1
69	33	0,232	0,088	1	0,069	1	0,124	1
70	37	0,224	0,053	1	0,094	1	0,397	0

EK 6'nın devamı

No	n	KS	JSBM		W3		BYSAM	
			Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç
71	26	0,264	0,122	1	0,140	1	0,289	0
72	18	0,309	0,160	1	0,066	1	1,009	0
73	28	0,252	0,132	1	0,246	1	0,566	0
74	39	0,218	0,068	1	0,183	1	0,301	0
75	57	0,180	0,059	1	0,080	1	0,472	0
76	14	0,349	0,186	1	0,139	1	0,464	0
77	15	0,338	0,160	1	0,332	1	0,192	1
78	22	0,284	0,079	1	0,083	1	0,123	1
79	12	0,375	0,170	1	0,144	1	0,214	1
80	39	0,218	0,068	1	0,137	1	0,246	0
81	40	0,215	0,042	1	0,203	1	0,336	0
82	46	0,201	0,059	1	0,111	1	0,352	0
83	31	0,236	0,019	1	0,077	1	0,253	0
84	27	0,258	0,034	1	0,087	1	0,097	1
85	23	0,280	0,086	1	0,116	1	0,217	1
86	25	0,270	0,033	1	0,068	1	0,284	0
87	18	0,309	0,157	1	0,201	1	0,234	1
88	25	0,270	0,121	1	0,078	1	0,139	1
89	31	0,236	0,056	1	0,044	1	0,302	0
90	37	0,224	0,099	1	0,109	1	0,318	0
91	31	0,236	0,071	1	0,066	1	0,273	0
92	29	0,246	0,101	1	0,167	1	0,155	1
93	29	0,246	0,082	1	0,073	1	0,189	1
94	17	0,318	0,066	1	0,071	1	0,224	1
95	55	0,183	0,045	1	0,047	1	0,373	0
96	33	0,232	0,078	1	0,170	1	0,740	0
97	43	0,207	0,060	1	0,058	1	0,273	0
98	26	0,264	0,098	1	0,069	1	0,314	0
99	28	0,252	0,085	1	0,100	1	0,161	1
100	31	0,236	0,092	1	0,117	1	0,157	1
101	32	0,234	0,046	1	0,171	1	0,257	0
102	37	0,224	0,058	1	0,114	1	0,238	0
103	25	0,270	0,058	1	0,102	1	0,567	0
104	31	0,236	0,062	1	0,113	1	0,386	0
105	36	0,227	0,077	1	0,042	1	0,186	1
106	29	0,246	0,089	1	0,125	1	0,247	0

EK 6'nın devamı

No	n	KS	JSBM		W3		BYSAM	
			Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç
107	31	0,236	0,067	1	0,044	1	0,145	1
108	32	0,234	0,054	1	0,103	1	0,107	1
109	21	0,289	0,102	1	0,071	1	0,260	1
110	31	0,236	0,034	1	0,060	1	0,149	1
111	71	0,161	0,009	1	0,079	1	0,499	0
112	79	0,153	0,071	1	0,128	1	0,187	0
113	106	0,132	0,041	1	0,040	1	0,167	0
114	41	0,212	0,066	1	0,117	1	0,520	0
115	52	0,565	0,024	1	0,096	1	0,354	1
116	41	0,212	0,084	1	0,096	1	0,176	1
117	18	0,309	0,106	1	0,179	1	2135	0
118	35	0,230	0,051	1	0,067	1	1340	0
119	19	0,301	0,082	1	0,191	1	0,638	0
120	29	0,246	0,081	1	0,085	1	0,356	0
121	20	0,294	0,136	1	0,159	1	0,773	0
122	18	0,309	0,101	1	0,109	1	0,284	1
123	34	0,230	0,034	1	0,053	1	0,113	1
124	20	0,294	0,077	1	0,074	1	0,265	1
125	36	0,227	0,113	1	0,136	1	0,163	1
126	46	0,201	0,027	1	0,025	1	0,384	0
127	16	0,328	0,124	1	0,050	1	0,880	0
129	50	0,192	0,046	1	0,526	0	0,836	0
130	33	0,232	0,061	1	1073	0	1371	0
131	61	0,174	0,057	1	0,028	1	0,249	0
132	65	0,169	0,052	1	0,500	0	0,579	0
133	63	0,684	0,001	1	0,753	0	0,766	0
134	43	0,684	0,018	1	0,765	0	0,260	1
135	21	0,289	0,155	1	1001	0	0,425	0
136	33	0,232	0,065	1	0,554	0	0,505	0
137	12	0,375	0,221	1	1317	0	0,506	0
138	9	0,432	0,121	1	0,186	1	0,284	1
139	21	0,289	0,086	1	0,093	1	0,226	1
140	31	0,236	0,076	1	0,062	1	0,310	0
141	16	0,328	0,100	1	0,563	0	0,521	0
142	47	0,198	0,087	1	0,127	1	0,170	1
143	11	0,391	0,140	1	1003	0	0,982	0

No	n	KS	JSBM		W3		BYSAM	
			Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç	Mak, Oransal Mutlak Hata	Sonuç
144	13	0,361	0,147	1	1000	0	1351	0
145	30	0,238	0,115	1	0,500	0	0,382	0
146	32	0,234	0,091	1	0,093	1	0,170	1
147	29	0,246	0,101	1	0,589	0	0,678	0
148	19	0,301	0,092	1	1001	0	0,970	0
149	21	0,289	0,153	1	0,129	1	0,183	1
150	22	0,284	0,055	1	0,089	1	0,232	1
151	33	0,232	0,035	1	0,518	0	0,109	1
152	46	0,201	0,055	1	0,590	0	0,244	0
153	43	0,207	0,036	1	0,602	0	0,566	0
154	26	0,264	0,057	1	1029	0	0,704	0
155	25	0,270	0,142	1	0,500	0	0,235	1
156	33	0,232	0,089	1	1045	0	0,685	0
157	38	0,221	0,130	1	0,500	0	0,176	1
158	33	0,232	0,084	1	0,509	0	0,130	1
159	50	0,192	0,017	1	0,514	0	0,158	1
160	32	0,234	0,116	1	1002	0	0,532	0
161	32	0,234	0,152	1	0,500	0	0,508	0
162	36	0,227	0,116	1	1000	0	0,740	0
163	30	0,238	0,135	1	1000	0	0,848	0
164	24	0,275	0,098	1	0,500	0	0,276	0
165	25	0,270	0,155	1	0,155	1	0,188	1
166	43	0,207	0,094	1	0,112	1	0,252	0
167	27	0,258	0,044	1	0,034	1	0,154	1
168	28	0,252	0,060	1	0,537	0	0,314	0
169	25	0,270	0,131	1	0,121	1	0,172	1
170	36	0,227	0,029	1	0,500	0	0,927	0
171	23	0,280	0,098	1	0,500	0	0,211	1
172	43	0,207	0,051	1	0,598	0	0,183	1
173	17	0,318	0,129	1	1000	0	1046	0
174	38	0,221	0,111	1	0,503	0	0,286	0
176	14	0,349	0,120	1	0,505	0	0,299	1
177	24	0,275	0,156	1	0,500	0	0,183	1
178	19	0,301	0,106	1	0,676	0	0,239	1
179	43	0,207	0,069	1	0,124	1	0,562	0
180	16	0,328	0,133	1	0,500	0	0,859	0

EK 7 Kodlar

TEZ KAPSAMINDA TASARLANAN AĞ YAPISI

Bu ağ tasarımı aşırı uyum (overfitting) problemini giderecek ya da çok az düzeye indirecek parametre uyarlamaları dikkate alınmıştır.

% veriyi yükle
load veri

% verileri [-1 1] aralığına taşı
[input,ps]=mapminmax(data(:));
[output_train,ts]=mapminmax(data(:));

% verileri eğitim ve test için ayır
Q=size(input,2);
Q1=floor(Q*0.90);
Q2=Q-Q1;
ind=randperm(Q);
ind1=ind(1:Q1);
ind2=ind(Q1+(1:Q2));
x1=input(:,ind1);
t1=output_train(:,ind1);
x2=input(:,ind2);
t2=output_train(:,ind2);
...

%Ağın tasarımını gerçekleştir

net = feedforwardnet(1);
numNN=1;
NN=cell(1,numNN);
perfs=zeros(1,numNN);

% Ağı tekrar tekrar eğit

for i=1:numNN
fprintf('Training %d/%d\n',i,numNN);
nets{i}=train(net,x1,t1);
net.trainFcn='trainbr';
net.trainParam.mu=0.1;
net.trainParam.lr=0.1;
net.trainParam.epochs=1000;
net.layers{1}.transferFcn = 'tansig';
end
...

%Ağın genel performansını, ağ ortalaması ile karşılaştır.

perfs=zeros(1,numNN);
y2Total=0;
for i=1:numNN
neti=nets{i};
y2=neti(x2);
perfs(i)=mse(neti,t2,y2);
y2Total=y2Total+y2;
end
perfs
y2AverageOutput=y2Total/numNN;
perfAveragedOutputs=mse(nets{i},t2,y2AverageOutput)

EK 7'nin devamı,

Doğrusal olmayan modellerin çözümü için geliştirilen kod

```
f=function(par){
  b0=par[1]
  b1=par[2]
  sigma=par[3]
  eps=y-(b0+b1*X)
  f=1/(sqrt(2*pi)*sigma)*exp(-1/2*(eps^2/sigma^2))
  return(f)
}
logl=function(par){
  f1=-sum(log(f(par)))
  return(f1)
}
init=c(0,0,0)
install.packages("GenSA")
library(GenSA)
f2=GenSA(par=init, fn=logl,lower=c(-Inf, -Inf,0),upper=c(Inf,Inf,100))
initial1=f2$par
f1=optim(par=initial1,fn=logl, method = "Nelder-Mead", hessian=T)
f1$par
hess=f1$hessian
sd = sqrt(diag(solve(hess)))
sd
f1$par/sd
2*(1-pnorm(par1 için hesaplanan t değeri,0,1))
2*(1-pnorm(par2 için hesaplanan t değeri,0,1))
```

#Modeli tanımla

Parametre değerlerinin elde edilmesi

parametrenin standart hata değeri
parametrenin t değeri
p değerinin hesaplanması

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı ve Soyadı : Ferhat BOLAT

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Yüksek lisans	ÇAKÜ Fen Bilimleri Enstitüsü	2015
Lisans	KTÜ Orman Fakültesi	2011
Lise	Mamak Lisesi	2005

İş Deneyimi

Yıl	Kurum	Görev
2012-Halen	ÇAKÜ	Araştırma Görevlisi

Projeler

ÇNÜ Araştırma Ormanı Karaçam Meşcereleri İçin Artım ve Büyüme Tahminlerinin Yapay Sinir Ağları Tekniği ile Elde Edilmesi, Yükseköğretim Kurumları tarafından destekli bilimsel araştırma projesi, Araştırmacı: Ferhat BOLAT, Yürütücü: Muammer ŞENYURT, Araştırmacı: Alkan GÜNLÜ, Araştırmacı: Sinan BULUT, Araştırmacı: İlker ERCANLI, 09/03/2016-15/11/2017 (ULUSAL)

Ankara Orman Bölge Müdürlüğü Anadolu Karaçamı Meşcerelerinde Artım ve Büyümenin Yapay Sinir Ağları ile Modellenmesi, ARAŞTIRMA PROJESİ, Yürütücü: İlker ERCANLI, Araştırmacı: Ferhat BOLAT, 18/12/2018 (Devam Ediyor) (ULUSAL)

Tarsus Orman İşletme Müdürlüğü Sınırları İçerisinde Yayılış Gösteren Anadolu Karaçamı *Pinus nigra* Arnold subsp *pallasiana* Lamb Holmboe Meşcereleri İçin Uyumlu Gövde Çapı ve Gövde Hacim Denklemlerinin Karışık Etkili Modelleme Yaklaşımı ile Geliştirilmesi, TÜBİTAK PROJESİ, Bursiyer, 01/08/2013-01/09/2014 (ULUSAL)

Ankara Orman Bölge Müdürlüğü Anadolu Karaçamı Meşcereleri için Tek Ağaç Gövde Çapı ve Gövde Hacminin Uyumlu Gövde Çapı Denklemleri ve Yapay Sinir Ağları ile Tahmin Edilmesi, TÜBİTAK PROJESİ, Yürütücü: İlker ERCANLI, Bursiyer: Ferhat BOLAT, 01/09/2020-01/09/2020 (ULUSAL)

Yayınlar

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.

Bolat, F., Bulut S., Günlü, A., Ercanlı, İ. and Şenyurt, M. 2020. Regression kriging to improve basal area and growing stock volume estimation based on remotely sensed data, terrain indices and forest inventory of black pine forests. *New Zealand Journal of Forestry Science*, 50.

Ünal, H.E., Birben, Ü. and Bolat, F. 2019. Rural population mobility, deforestation, and urbanization: case of Turkey. *Environmental Monitoring and Assessment*, 191(1), 1-12.

Şenyurt, M., Ercanlı İ. and Bolat, F. 2017. Taper equations based on nonlinear mixed effect modeling approach for *Pinus nigra* in Çankırı forests. *Bosque*, 38(3), 545-554.

Göl, C., Bulut, S. and Bolat F. 2017. Comparison of different interpolation methods for spatial distribution of soil organic carbon and some soil properties in the Black Sea backward region of Turkey. *Journal of African Earth Sciences*, 134, 85-91.

Bolat, F. ve Ercanlı, İ. 2017. Bursa-Kestel Ormanlarında Çap Dağılımlarının Weibull Fonksiyonu ile Modellenmesi. Kastamonu Üniversitesi Orman Fakültesi Dergisi, 17(1), 107-107.

Bildiriler

Ercanlı, İ. and Bolat, F. 2017. Diameter distribution modeling based on Artificial Neural Networks for Kunduz Forests. International Symposium on New Horizons in Forestry, 238-241, Isparta.

Şenyurt M., Ercanlı, İ., Günlü, A., Bolat, F. and Bulut S. 2017. Predicting breast height diameter from stump diameters of crimean pine stands in CAKU Research Forest. International Symposium on New Horizonsin Forestry, Özet Bildiri/Sözlü Sunum, 249.s.

Bolat, F., Ercanlı, İ. and Şenyurt, M. 2017. Comparison of some autoregressive models for removing temporal autocorrelation effect in stem analysis data. International Symposium on New Horizons in Forestry, Tam Metin Bildiri/Sözlü Sunum, 232-237.