

**ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**ANADOLU KARAÇAMI [*Pinus nigra* J.F. Arnold subsp. *pallasiana*
(Lamb.) Holmboe] MEŞCERELERİ (BURSA-KESTEL) İÇİN ÇAP-BOY
İLİŞKİLERİNİN YAPAY SINIR AĞLARI İLE MODELLENMESİ**

Doğa EYÜBOĞLU

ORMAN MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI

2019

Her hakkı saklıdır

TEZ ONAYI

Doęa EYÜBOęLU tarafından hazırlanan “Anadolu Karaçamı [*Pinus nigra* J.F. Arnold subsp. *pallasiana* (Lamb.) Holmboe] Meşcereleri (Bursa-Kestel) için Çap-Boy İlişkilerinin Yapay Sınır Ağları ile Modellenmesi” adlı tez çalışması 02/05/2019 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

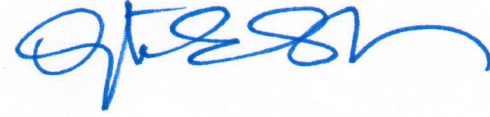
Danışman : Doç. Dr. İlker ERCANLI

Jüri Üyeleri :

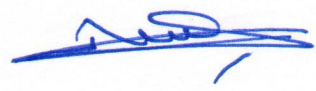
Başkan: Doç. Dr. İlker ERCANLI



Üye: Doç. Dr. Oytun Emre SAKICI



Üye: Dr. Öğr. Üyesi Muammer ŞENYURT



Yukarıdaki sonucu onaylarım

Prof. Dr. Tamer KEÇELİ

Enstitü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğine göre hazırlamış olduğum “**Anadolu Karaçamı [*Pinus nigra* J.F. Arnold subsp. *pallasiana* (Lamb.) Holmboe] Meşcereleri (Bursa-Kestel) için Çap-Boy İlişkilerinin Yapay Sınır 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. (30/04/2019.).

Doğa EYÜBOĞLU

ÖZET

Yüksek Lisans Tezi

Anadolu Karaçamı [*Pinus nigra* J.F. Arnold subsp. *pallasiana* (Lamb.) Holmboe]
Meşcereleri (Bursa-Kestel) için Çap-Boy İlişkilerinin Yapay Sinir Ağları ile
Modellenmesi

Doğa EYÜBOĞLU

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Orman Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. İlker ERCANLI

Bu çalışmada, ülkemizin Marmara bölgesinde yer alan Kestel ormanları Anadolu Karaçam'ının çap-boy ilişkilerinin modellenmesinde Yapay Sinir Ağ modellerinin kullanım olanaklarının değerlendirilmesi amaçlanmıştır. Bu amaçla, 110 örnek alanda ölçülmüş ağaçları boylarını tahmin üzere 5 farklı aktivasyon fonksiyonu ve 100 farklı nöron sayısı alternatifi olmak üzere toplam 500 farklı Yapay Sinir Ağ modeli için veri eğitimi gerçekleştirilmiş ve tahminler elde edilmiştir. Bu Yapay Sinir Ağ modellerinin karşılaştırılmasında; r , Ortalama Mutlak Hata (OMH), max. Ortalama Mutlak Hata (max. OMH), Hata Kareler Ortalamasının Karekökü (HKOK), Yüzde Hata Kareler Ortalamasının Karekökü (HKOK%), Bias, Bias%, R^2 , AIC ve BIC gibi çeşitli başarı ölçütleri kullanılmış, lojistik sigmoid (log-sig)'in giriş katmanı ile ara katmanı bağlantı noktasında ve hiperbolik tanjant sigmoid (tan-sig)'in de ara katman ile çıkış katmanı bağlantı noktasında olduğu Aktivasyon fonksiyonu seçeneğine (A2) ve 75 nörona sahip Yapay Sinir Ağ modelinin ağaçların boy değerlerini tahmin etmede en başarılı model olduğu belirlenmiştir. Bu en başarılı Yapay Sinir Ağ modeli için r ; 0.9317, OMH; 0.9183, max. OMH; 5.1449, HKOK; 1.2660, HKOK%; 10.4356, Bias; -0.0229, Bias%; -0.1886, R^2 ; 0.8732, AIC; 197.3114 ve BIC; 211.4062 olarak hesaplanmıştır.

Bu en başarılı YSA modeli ile elde edilen tahminlerde, Schnutte (1981)'un Doğrusal Olmayan Regresyon modeline göre r , OMH, max. OMH, HKOK, HKOK%, Bias, Bias%, R^2 , AIC ve BIC değerlerinde sırasıyla, -%4.518, %12.296, %35.689, %22.929, %22.929, %51.703, %49.978, -%11.016 oranlarında iyileşmeler elde edilmiştir. Tüm bu ölçütler değerlendirildiğinde, YSA modellerinin ağaçların boy tahminlerinde başarıyla kullanılabileceği sonucuna varılabilir.

2018, 44 sayfa

Anahtar Kelimeler: Çap-Boy İlişkisi, Yapay Sinir Ağları, Tahmin, Schnutte (1981)'un Doğrusal Olmayan Regresyon Modeli

ABSTRACT

M.S. Thesis

Modeling Relationships between Diameter and Height by Artificial Neural networks for Anatolian Black Pine Stands [*Pinus nigra* J.F. Arnold subsp. *pallasiana* (Lamb.) Holmboe] located in Bursa-Kestel Forests

Doğa EYÜBOĞLU

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

Supervisor: Assoc. Prof. Dr. İlker ERCANLI

In this study, it is aiming to evaluate the usability of Artificial Neural Network Model to predict dbh and height relations for Kestel Forests located in Marmara region of our country. For this purpose, 500 Artificial Neural Network Model models with 5 activation functions and 100 neuron number alternatives were trained by using the height of trees measured in 110 sample areas and the height predictions were obtained. In comparisons based on some criteria such as r , Absolute Average Error (AAE), max. Absolute Average Error (max. AAE), Root Mean Squared Error (RMSE), Percent Root Mean Squared Error, Bias, Bias%, R^2 , Akaike Information Criteria (AIC) and Bayesian Information Criteria (BIC) , the Artificial Neural Network Model including activation function alternative (A2) with logistic sigmoid (log-sig) at connection point between the input layer and the hidden layer with the hyperbolic tangent sigmoid (tan-sig) at connection point between the hidden layer and the output layer and 75 neurons gave the best predictive results.

For this the best predictive ANN model, r , AAE, max. AAE, RMSE, RMSE%, Bias, Bias%, R^2 , AIC and BIC were calculated as 0.9317, 0.9183, 5.1449, 1.2660, 10.4356, -0.0229, -0.1886, 0.8732, 197.3114 and 211.4062, respectively. According to Schnutte (1981) 's regression model, the best predictive ANN model gave improvements in the rates of AAE, RMSE, RMSE%, Bias, Bias%, R^2 , AIC and BIC of 4.518%, 12.296%, 35.689%, 22.929%, 22.929%, 51.703%, 49.978% -11.016%, respectively. When all these criterion values are evaluated, it can be concluded that ANN models can be used successfully in the height predictions.

2018, 44 pages

Key Words: The relationships between Diameter at breast height and total height, Artificial Neural Networks, Prediction, Schnutte (1981)' nonlinear regression model

ÖNSÖZ VE TEŞEKKÜR

“Anadolu Karaçamı [*Pinus nigra* J.F. Arnold subsp. *pallasiana* (Lamb.) Holmboe] Meşcereleri (Bursa-Kestel) için Çap-Boy İlişkilerinin Yapay Sinir Ağları ile Modellenmesi” adlı bu çalışma Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalında ders dönemi bitimi sonunda yüksek lisans tez çalışması olarak hazırlanmıştır. Başlangıç aşamasından, çalışmanın sonlandırılmasına kadar geçen sürede yardım ve desteklerini esirgemeyen herkese sonsuz teşekkür ederim.

İlk olarak çalışma konusunun seçiminden, çalışmanın sonlandırılmasına kadar her aşamada desteğini esirgemeyen, bilgi ve tecrübesinden sıkça yararlandığım danışman hocam Sayın a, Doç. Dr. İlker ERCANLI'ya, jüri üyelerim Dr. Öğr. Üyesi Muammer ŞENYURT'a ve Dr. Öğr. Üyesi Oytun Emre SAKICI'ya teşekkürlerimi bir borç bilirim. Son olarak bütün hayatım boyunca beni hem maddi hem de manevi olarak destekleyen ve her durumda yanımda olduklarını bildiğim aileme sonsuz şükranlarımı sunarım.

Doğa EYÜBOĞLU

Çankırı, 2019

İÇİNDEKİLER

| | |
|--|-----|
| ÖZET..... | i |
| ÖNSÖZ ve TEŞEKKÜRLER | iii |
| ŞEKİLLER DİZİNİ | vi |
| ÇİZELGELER DİZİNİ | vii |
| 1. GİRİŞ | 1 |
| 2. MATERYAL VE YÖNTEM | 9 |
| 2.1. Materyal | 9 |
| 2.2. Yöntem | 13 |
| 2.2.1. Doğrusal Olmayan Regresyon Analizi | 13 |
| 2.2.2. Yapay Sinir Ağları ile Boy Tahmini | 15 |
| 2.2.3. YSA modellerinin Tahminlerinin Karşılaştırılması ve Denetlemesi ... | 21 |
| 3. BULGULAR ve TARTIŞMA | 24 |
| 4. SONUÇ ve ÖNERİLER | 32 |
| KAYNAKLAR | 37 |
| ÖZGEÇMİŞ | 44 |

SİMGELER DİZİNİ

| | |
|----------------|---|
| m | : Metre |
| mm | : Milimetre |
| m ² | : Metrekare |
| d | : Göğüs Çapı |
| h | : Ağaç Boyu |
| D_0 | : En kalın çaplı ağaçların ortalama çapı |
| H_0 | : En kalın çaplı ağaçların ortalama boyu |
| OMH | : Ortalama Mutlak Hata |
| HKOK | : Hata Kareler Ortalamasının Karekökü |
| HKOK% | : Yüzde Hata Kareler Ortalamasının Karekökü |
| OH | : Ortalama Hata |
| OH% | : Yüzde Ortalama Hata |
| R ² | : Belirtme Katsayısı |
| THY | : Toplam Hata Yüzdesi |
| OMHY | : Ortalama mutlak hata yüzdesi |
| AIC | : Akaike Bilgi Ölçütü |
| BIC | : Bayesian Bilgi Ölçütü |

ŞEKİLLER DİZİNİ

| | |
|---|----|
| Şekil 2.1 Çalışma alanı Kestel Orman İşletme Şefliği Alanı | 9 |
| Şekil 2.2. Doğrusal Olmayan Regresyon modelinin geliştirilmesinde ve Yapay Sinir Ağlarının eğitiminde (a) ve denetlemesinde (b) kullanılan verilerin çap-boy ilişkisi | 12 |
| Şekil 2.3. İnsan sinir sisteminde nöron yapısı ve uyarı iletimi | 15 |
| Şekil 2.4. Biyolojik sinir hücreleri ile yapay sinir ağlarının yapısının karşılaştırılması | 16 |
| Şekil 2.5. Farklı aktivasyon fonksiyonları | 18 |
| Şekil 2.6. Bu çalışmada esas alınan Yapay Sinir Ağ modeli | 19 |
| Şekil 3.1. En başarılı Yapay Sinir Ağ modeli ile tahmin edilen boyların ölçülen boylara göre değişimi | 26 |
| Şekil 3.2 . Schnutte (1981)'in denklemi ile tahmin edilen boyların ölçülen boylara göre değişimi | 26 |
| Şekil 3.3. En başarılı YSA modeline ilişkin hataların ile tahmin edilen boylara göre değişimi | 27 |
| Şekil 3.4. Schnutte (1981)'in denklemine ilişkin hataların ile tahmin edilen boylara göre değişimi | 27 |
| Şekil 3.5. Nöron sayılarına göre HKOK değişimi | 29 |
| Şekil 3.6. Nöron Sayılarına göre belirtme katsayısının (R^2) değişimi | 30 |
| Şekil 3.7. En başarılı YSA modeli ile 142 adet ağacın tahmin edilen boyların ölçülen boylara göre değişimi | 31 |

ÇİZELGELER DİZİNİ

| | |
|--|----|
| Çizelge 2.1 Çalışma materyaline ilişkin bazı istatistiksel bilgiler | 11 |
| Çizelge 2.2. Aktivasyon Fonksiyon seçenekleri | 21 |
| Çizelge 3.1. Farklı Aktivasyon fonksiyonlarında en başarılı olarak belirlenen nöron sayısı seçeneğini için Yapay Sinir Ağ modelleri ve Doğrusal Olmayan Regresyon modeline ilişkin r , OMH, max. OMH, HKOK, HKOK%, Bias, Bias%, R^2 , AIC and BIC başarı ölçüt değerleri | 25 |
| Çizelge 3.2. Farklı Aktivasyon fonksiyonlarında en başarılı olarak belirlenen nöron sayısı seçeneğini için Yapay Sinir Ağ modelleri ve Doğrusal Olmayan Regresyon modeline ilişkin r , OMH, max. OMH, HKOK, HKOK%, Bias, Bias%, R^2 , AIC and BIC başarı ölçüt değerlerine göre hesaplanan rölatif sıra değerleri..... | 25 |
| Çizelge 3.3. Aktivasyon fonksiyonu alternatiflerine göre r , OMH, max. OMH, HKOK, HKOK%, R^2 , AIC ve BIC başarı ölçütlerinin ortalamaları | 28 |
| Çizelge 3.4. Aktivasyon fonksiyon alternatiflerine göre r , OMH, max. OMH, HKOK, HKOK%, R^2 , AIC ve BIC başarı ölçütlerinin rölatif sıra değerleri | 28 |

1.GİRİŞ

Varoluşun ilk zamanlarından bu yana insanođlu orman ile sürekli bir yararlanma faaliyet içerisindeydi. Barınma, beslenme, ateşin bulunmasıyla hammadde gibi temel düzeyde insanın hayatta kalma mücadelesini kazanmaya yardımcı olmuştur. Bu hassas dengede ormanlar; insanlığın yerleşik hayata geçmesi, tarım alanlarının oluşturulması, hayvanların ehlileştirilmesi, sivil hayatın gelişmesi, sosyalleşme, endüstrileşme ve özellikle son yüz yılda teknolojinin önlenemez gelişimiyle süregelen ihtiyaçların düzensiz ve plansız sağlanması ile yıpratılarak, erozyon ile toprakların kaybolması, biyolojik çeşitliliğin azalması gibi tehditlerle baş başa kalmıştır. (Başkent 1999).

Sonsuz olarak değerlendirilen ormanların gün geçtikçe tehlike de olduğu anlaşılınca düzenli yararlanma ve belirli şartlarla tedarik etme gereği hissedilmiştir (Kapucu 1996). Bu bağlamda ormanların insanođluna sunduđu kullanılabilir su, iklim özellikleri, sosyal yaşama katkısı, erozyon önleme vb. gibi fonksiyonları belirli disiplinlerle sürekli bir biçimde karşılama düşüncesiyle orman amenajmanı ortaya konulmuştur (Eraslan, 1982). Böyle bir disiplinde hiçbir sektörde görülmeyen planların ve geniş çaplı araştırmaların sebepleri ise son derece geniş alanlarda yapılması, geri dönüş sürecinin yine son derece uzun yıllar gerektirmesi ve doğanın bizzat kendinin bu işleyiş, pozitif ve negatif bütün etmenleriyle, içinde olmasını sayabiliriz (Eraslan, 1982).

Ormanlardan ve ormancılıktan faydalanma arttıkça orman amenajmanı da aynı doğrultuda ilerlemek zorunda kalmıştır. Başlangıçta ana ürün olarak odun ve yan ürünlerden yararlanmayı amaç ederken, günü takip ettiğimiz bu vakitlerde bazı durumlarda ise temel amaç olarak ormanın sosyal hizmetleri, çevre koruma, eğlen dinlen, doğa koruma, ekolojik fonksiyonları tabiat kurallarını göz önünde bulundurarak planlamaktadır (Kapucu, 1996). Bu gereklilikler doğrultusunda ormancılık sektöründe yeni ufuklar açılmış ve çok amaçlı planlama yaklaşımı gündeme gelmiştir. Çok amaçlı planlamanın kesintisiz tüm bir havzada ele alınmasının gündeme gelmesiyle ekosistem planlama kavramı doğmuştur. Bağlantılı olarak orman ekosistem dinamiğini kavramaya yönelik bilimsel birikimlerin artması, bilişim teknolojilerinin gelişimi ve karar verme

tekniklerinin kullanımıyla planlama kavramı, günümüzde ekosistem tabanlı çok amaçlı planlama (ETÇAP) yaklaşımı sürecini gündeme getirmiştir. Geline nokta; bir taraftan, orman ekosistemlerinin sunduğu odun ürünüyle birlikte odun dışı orman ürünleri ve hizmet fonksiyonlarının sayısallaştırılmasına çalışılırken öte yandan dinamik büyüme ve artım modelleri ile meşcere dinamiği kavranmaya çalışılmaktadır. Bu çalışmalara biyoçeşitliliğin korunması, çölleşme ile mücadele ve küresel iklim değişiklikleri de yansıtılarak planlama yeni bir boyuta taşınmaktadır. Ekonomik değerlendirmelerin de yansıtıldığı bu planlama tam anlamıyla ekosistem tabanlı çok amaçlı yaklaşımı olarak kendisini göstermektedir.

Ormanların planlamasının en önemli aşaması, orman envanteri olup, orman envanterinin önemli bileşenleri de, ağaç göğüs çapı ve boyu ölçümleridir. Özellikle, ağaçların boy ölçümlerine, daha doğru hacim tahminleri sunan çift girişli ağaç hacim denklemleri ve tablolarının uygulanmasında, toplam ve ticari biyokütle tahminlerinin elde edilmesinde, değişik yaşlı meşcerelerin verim gücü tahminlerinin elde edilmesinde ihtiyaç duyulabilmektedir (Clutter *et al.* 1983, van Laar and Akça 2007). Bununla birlikte, ağaçların boylarının ölçümleri, göğüs çapı ve diğer tek ağaç özelliklerine göre daha zor ve zaman alıcı olup (Martin and Flewelling 1998, Huang *et al.*, 1992), böylece orman envanterinde, örnek alanlardaki tüm ağaçların boyları ölçülememektedir (Clutter *et al.* 1983, van Laar and Akça 2007). Diğer taraftan, orman envanteri çalışmalarında, ağaçların boy değerleri, meşceredeki ağaçların göğüs çapları ile boyları arasındaki istatistiksel ilişkileri gösteren meşcere boy eğrileri ile tahmin edilebilmektedir (Avery and Burkhart 1983, van Laar and Akça, 2007).

Meşcere boy eğrileri ile ağaçların göğüs çapları ile boyları arasındaki ampirik ilişkileri, istatistiksel denklemler temel alarak gösterilmektedir. Ağaçların çap-boy ilişkilerinin gelişimi, genellikle sigmoid ya da “S” biçimli bir trend göstermesinden dolayı, meşcere boy eğrileri, doğrusal olmayan (Nonlinear relationship) denklemler ile modellenmektedir (Wykoff *et al.* 1982, Huang *et al.* 1992, Robinson and Wykoff 2004).

Ormancılık literatüründe, ağaçların çap-boy ilişkileri üzerine yapılan ilk çalışmalar, ağaç göğüs çapını kullanarak ağaç boyunu tahmin etmeye çalışmışlar ve sadece ağaç göğüs çapının yer aldığı denklemler geliştirmişlerdir (Huang *et al.* 1992, Curtis 1967, Wykoff *et al.* 1982, Larsen and Hann 1987, Wang and Hann 1988, Moore *et al.* 1996, Zhang 1997, Fang and Bailey 1998, Peng 1999, Fekedulegn *et al.* 1999). Ağaçların çap-boy ilişkileri üzerinde, çeşitli meşcere koşullarının önemli etkilere sahip olmakta ve böylece farklı meşcereler arasında aynı çapa karşılık gelen boy değerleri arasında önemli farklar oluşabilmektedir. Bu bakımdan, sadece göğüs çapını içeren boy denklemleri, farklı sıklık, verim gücü ve yaştaki meşcerelerin çap-boy ilişkilerini modellemede yetersiz olabilmektedir (Temesgen and Gadow 2004, Castedo-Dorado *et al.* 2005, Trincado *et al.* 2007). Böylece, meşcereler arasındaki ağaçların çap-boy ilişkileri arasındaki farklılığı daha iyi temsil etmek ve modellemek üzere farklı yaklaşımlar ve teknikler önerilmiş ve kullanılmıştır. Ferguson and Leech (1978), Krumland and Wensel (1978), Larsen and Hann (1987) ve Parresol (1992) ilk aşamada farklı meşcere yapıları için ayrı ayrı olmak üzere geliştirdikleri çap-boy denklemleri ile parametre değerlerini tahmin edip, ikinci aşamada ise bu denklem parametreleri ile meşcere özellikleri arasında ilişkileri modellemişlerdir. Bu konuda daha çok tercih edilen bir yaklaşım olarak da, de göğüs çapı ile birlikte diğer meşcere özelliklerini de içeren doğrusal olmayan regresyon denklemleri önerilmiştir (Fulton 1999, Huang *et al.* 2000, Schöeder and Álvarez González 2001, López Sánchez *et al.* 2003, Sharma and Zhang 2004, Temesgen and Gadow 2004, Castedo Dorado *et al.* 2005, Trincado *et al.* 2007, Adame *et al.* 2008, Paulo *et al.* 2011). Ağaçların göğüs çapı ile birlikte çeşitli meşcere özelliklerinin içerildiği doğrusal olmayan regresyon denklemleri, özellikle “genelleştirilmiş boy denklemleri (*generalized height-diameter models*)” olarak da adlandırılmaktadır.

Ağaçların çap-boy ilişkilerinin modellemesinde yaygın bir biçimde kullanılan diğer bir istatistik yöntem de; Doğrusal Olmayan Karışık Etkili Modellemedir (Linear and Nonlinear Mixed Effect Models). Özellikle, farklı yapıdaki meşcere yaşı, verim gücü ve meşcere sıklığı gibi farklı özelliklere sahip meşcerelerden elde edilen verilerin bir veri havuzunda bir araya getirilmesi ile hiyerarşik veri yapıları söz konusu olmakta,

regresyon modellemesinde önemli varsayımlardan birisi olan verilerin birbirinden bağımsızlığı varsayımı da ihlal edilmektedir (Castedo-Dorado *et al.* 2006, Trincado *et al.* 2007, Crecente-Campo *et al.* 2010). Bu problem, “otokorelasyon” veya “seri korelasyon” olarak adlandırılmaktadır (Mehtätalo 2004, Castedo-Dorado *et al.* 2006, Crecente-Campo *et al.* 2010). Bu problemin belirgin olduğu çap-boy ilişkilerinde, Doğrusal Olmayan Regresyon Modellerinde parametrelere ilişkin güven aralıklarının sistematik bir hata ile tahmin edilmesi söz konusu olabilmektedir (İyit vd. 2006). Böylece, regresyon modellerinin sonuçlarının güvenilirliğini olumsuz yönde etkilemekte ve hatalı tahminlerin elde edilebilmektedir (Ye, 2005). Özellikle son yıllardaki çap-boy denklemlerinin geliştirilmesinde, Doğrusal Olmayan Karışık Etkili Modelleme (Nonlinear Mixed Effect Models) yöntemleri sıklıkla kullanılmaktadır (Mehtätalo, 2004 Lynch *et al.* 2005, Calama and Montero 2004; Castedo-Dorado *et al.* 2006, Sharma and Parton 2007, Trincado *et al.* 2007, Saunders and Wagner 2008, Budhathoki *et al.* 2008, Adame *et al.* 2008, Crecente-Campo *et al.* 2010). Doğrusal Olmayan Karışık Etkili Modelleme yaklaşımında, “otokorelasyon” veya “seri korelasyon” probleminin modellerin tahmin başarısındaki olumsuz etkinin giderilmesi esastır.

Tüm bu istatistik bilimin konusu regresyon analizi tekniklerinin yanında, günümüz artım ve büyüme modellemesinde yer bulan diğer bir modelleme metodolojisi de; Yapay Zeka Uygulamaları olan Yapay Sinir Ağlarıdır (YSA). 1960’lı yıllarla birlikte, özellikle bilgisayar teknolojisinin gelişimine bağlı olarak kapsamlı bilgisayarların üretilmesi ile artım ve büyüme modellemesinde; çeşitli tek ağaç ve meşcere özelliklerine ilişkin ilişkiler için elle çizilen grafiklerden, karmaşık hesaplamalara dayanan istatistik analiz yöntemlerine doğru bir geçiş yaşanmıştır. Bilgisayar yazılımlarının desteği ile tek ağaç ve meşcerelerinin artım ve büyümesinin tahmin edilmesinde, istatistik yöntemler ve özellikle istatistik biliminin önemli bir konusu olan Regresyon Analizi ve Regresyon Modelleri uzun yıllardır kullanılmaktadır. Çeşitli tek ağaç ve meşcere özellikleri arasındaki ilişkileri, istatistik denklemler vasıtasıyla tahmin eden regresyon modelleri; model hatalarının normal dağılım göstermesi, hataların azalan ya da artan bir trende sahip olmaması, tahmin değerinin değişimine bağlı olarak hata varyanslarının homojenliği, hatalar arasında bir korelasyonun olmaması

(otokorelasyon) ve bağımsız değişkenler arasında bir korelasyonun olmaması gibi çeşitli istatistiksel varsayımların sağlanması durumunda doğru ve güvenilir tahminler sunabilmektedirler (İyit 2008, Doğanay 2007). Regresyon modellerine ilişkin bu varsayımlar ile birlikte, modellere ilişkin denetim süreçleri daha da önem kazanmakta, ormancılıkta çeşitli düzeylerde tahminlerin elde edilmesinde; zaman serisi analizinin bir uygulaması olan Otoregresif modeller ile stokastik süreçlerin bir çeşidi olan karışık etkili doğrusal olmayan regresyon modelleri gibi çeşitli yöntemlerin kullanımı önerilmektedir. Bununla birlikte, bu yöntemlerin uygulanması ile regresyon modellerinin geliştirilmesinde esas olan istatistiksel varsayımların bütünüyle sağlandığı konusundaki tartışmalar devam etmekte ve bu yeni regresyon analizi yöntemlerinin kullanımı ile istatistiksel varsayımların sağlandığı konusunda ise tam bir fikir birliği elde edilememiştir. Regresyon modellerinin eleştiri alan bu özellikleri ile birlikte, artım ve büyümenin tahmin edilmesinde regresyon modellerine alternatif bir yaklaşım olarak da; ormancılıkta son yıllarda istatistiksel varsayımların sağlanmasına ihtiyaç duymayan ve karmaşık ilişkilerin modellenmesinde başarılı tahmin sonuçları verebilen Yapay Sinir Ağlarının kullanımı öne çıkmaktadır.

Ormancılıkta, özellikle 1990 yılların başlarında Yapay Sinir Ağları farklı alanlarda kullanım alanı bulmaya başlamıştır. Guan and Gartner (1991), ağaçların kurumasının tahmin edilmesinde Yapay Sinir Ağlarını kullanmıştır. Schmoldt *et al.* (1997), Yapay Sinir Ağları ile odun kusurları sınıflaması yapmıştır. Paruelo and Tomasel (1997), bazı ekosistem fonksiyonlarının tahminini Yapay Sinir Ağları ile gerçekleştirmişlerdir. Hasenauer *et al.* (2001), Norveç ladini meşcerelerindeki ağaç kurumasını tahmin etmek üzere, çok tabakalı perceptron, cascade korelasyon yapısı ve öğrenmeli vektör sınıflandırma olmak üzere bazı ağ yapılarını karşılaştırmış ve çok tabakalı perceptron Yapay Sinir Ağları ile en iyi tahminleri elde etmiştir. Zhang *et al.* (2000), çeşitli iklim parametrelerini kullanarak Duglas Göknaarı ağaçlarının artım değerlerine ilişkin tahminleri, Yapay Sinir Ağları ile elde etmiş ve ayrıca belirli iklim senaryolarına bağlı olarak artım değerlerinin Yapay Sinir Ağları ile elde edilebileceğini ifade etmiştir. Leduc *et al.* (2001), 3 parametrelili Weibull olasılık yoğunluk fonksiyonun parametrelerini tahmin etmek üzere ileri beslemeli ve geri yayımlı Yapay Sinir Ağları

kullanmıştır. Hasenauer and Kinderman (2002), değişik yaşlı karışık meşcerelerde gençleştirme yapıları ile boy gelişimlerini Yapay Sinir Ağları ile belirlemişlerdir. Corne *et al.* (2004), meşcere kapalılığı ve tür alanları gibi çeşitli orman karakteristiklerini Yapay Sinir Ağları ile belirlemişlerdir. Diamantopoulou (2005a), çam ağaçlarının kabuklu hacmini tahmin etmek üzere üç tabakalı ve ileri beslemeli cascade korelasyon yapısına sahip Yapay Sinir Ağları kullanılmış ve doğrusal olmayan regresyon modellerine göre daha başarılı tahminler elde etmiştir. Diamantopoulou (2005b), göknar ağaçlarının farklı kesit yüksekliklerindeki gövde çaplarının tahmin edilmesinde cascade korelasyon yapısını içeren Yapay Sinir Ağları yapısı uygulamış ve istatistiksel olarak başarılı sonuçlar elde etmiştir. Diamantopoulou (2006), ağaçların gövde çaplarını tahmin etmek üzere cascade korelasyon yapısını içeren Yapay Sinir Ağları kullanmış, elde edilen çap tahminlerini kullanarak 0.0054 m^3 'lük Hata Karelerin Ortalamasının Karekökü ile ağaçların hacim tahminleri elde etmiştir. Diamantopoulou and Milios (2010), çam ağaçlarının kabuklu ve kabuksuz hacimlerini cascade korelasyon yapısını içeren Yapay Sinir Ağları ile regresyon modellerine göre daha başarılı bir şekilde tahmin etmiştir. Leite *et al.* (2011), ağaçların gövde boyunca elde edilen çaplarını tahmin etmek üzere doğrusal tip Yapay Sinir Ağları kullanarak Kozak'ın gövde çapı denklemi ile karşılaştırılmış ve Yapay Sinir Ağları ile daha başarılı ve etkin tahminler elde etmiştir. Cai *et al.* (2012), ileri beslemeli ve geri yayımlı Yapay Sinir Ağları ile çap dağılımlarına ilişkin parametre tahmininde kullanmış ve Yapay Sinir Ağlarının regresyon modellerine göre daha başarılı tahminler elde etmiştir. Castro *et al.* (2013), Okaliptüs meşcerelerinin kuruma olasılıklarını, ortalama çapı ve boyu tahmin etmek üzere farklı girdi değişkenlerine sahip çok katmanlı Yapay Sinir Ağlarını karşılaştırmıştır. Ashraf *et al.* (2013), tek ağaçların göğüs yüzeyi artımları ile hacim artımlarını; solar radyasyon, güneşli gün sayısı, toprak suyu ve toprak besin içeriği değişkenlerini girdi değişkenleri olarak kullanan Yapay Sinir Ağları ile tahmin etmiştir. Abbasi *et al.* (2013), 3 parametrelili Weibull fonksiyonunun parametrelerinin tahmin edilmesinde dağılımın ortalaması, standart sapması, medyan, basıklık ve çarpıklığı gibi değerleri girdi değişkeni olarak kullanabilen Yapay Sinir Ağlarının avantajlarını ifade etmişlerdir.


Ülkemizde ise, Yapay Sinir Ağlarının ormancılıkta kullanımına ilişkin çalışmalar sınırlı sayıdadır. Özellikle ağaçlara ilişkin artım ve büyümenin modellenmesine ilişkin çalışmalardan; Özçelik *et al.* (2008), ağaç hacimlerini tahmin edilmesinde, standard metotlar (huber formülü ve yöresel hacim denklemi), modern teknikler (paracone, centroid, control-variate, importance sampling) ve cascade korelasyon yapısını içeren Yapay Sinir Ağları karşılaştırılmış, en başarılı tahminleri Yapay Sinir Ağları ile elde edilmiştir. Özçelik *et al.* (2010), 89 adet sarıçam, 96 adet kızılçam, 107 adet Toros göknarı ve 67 adet sedir ağacı verisi kullanarak ağaç hacimlerini tahmin edilmesinde en iyi sonuçları, Cascade Korelasyon yapısını içeren Yapay Sinir Ağları ile elde etmiştir. Diamantopoulou and Özçelik (2012), ağaçların boy tahminlerinin elde edilmesinde genelleştirilmiş regresyon yapısına dayanan Yapay Sinir Ağları ile doğrusal olmayan regresyon modellerini karşılaştırmış, Yapay Sinir Ağları ile daha başarılı boy tahminleri elde etmiştir. Özçelik *et al.* (2013), Karaçam ağaçlarının boylarının tahmin edilmesinde, genelleştirilmiş boy denklemlerini, karışık etkili modellemeye dayanan doğrusal olmayan modeller ile Yapay Sinir Ağlarını karşılaştırmış, en doğru ve başarılı tahminleri geri yayımlı (Back Propagation) Yapay Sinir Ağları elde etmiştir. Özçelik *et al.* (2014), kızılçam ağaçlarının gövde çaplarına ilişkin tahminler ile gövde hacmi tahminlerinde tepe özelliklerine ilişkin değişkenlerin etkisini, Yapay Sinir Ağları ile araştırmış; özellikle Levenberg-Marquardt algoritmasını esas alan Yapay Sinir Ağlarının en başarılı tahminleri verdiğini belirlemiştir. Diamontopoulou *et al.* (2015), 2 parametrelili Weibull olasılık yoğunluk fonksiyonunun parametrelerinin tahmin edilmesinde Levenberg-Marquardt algoritmasını kullanan Yapay Sinir Ağları ile çap dağılımlarını modellemede başarılı sonuçlar elde etmiştir. Özdemir (2018), Karabük yöresi Kayın-Göknar meşcerelerinde gövde boyunca çapları Yapay Sinir Ağları ile tahmin etmiştir. Bu çalışmalar yanında, Bolat (2015); ağaç boyunu, Ercanlı vd. (2016a) ve Günlü ve Ercanlı (2017); uzaktan algılama verileri ile meşcere karbonunu, Ercanlı vd. (2016b); çap artımını, Bolat ve Ercanlı (2016) ve Ercanlı ve Bolat (2017); çap dağılımlarını, Ercanlı vd. (2015); ağaçların yaş-boy ilişkilerini, Şenyurt vd. (2015); çeşitli meşcere özelliklerini, Ercanlı vd. (2018a); yaprak alan indeksini ve Ercanlı vd. (2018b); ağaçların hacmini Yapay Sinir Ağları modelleri ile tahmin etmişlerdir. Ercanlı vd. (2018c), Doğu Ladini-Sarıçam Karışık Meşcerelerinin çap dağılımlarının

modellenmesinde farklı katman sayılarını içeren Derin Öğrenme Algoritma modelleri ve 3 parametrelili Weibull fonksiyonu ile elde edilen çap dağılımına ilişkin tahmin başarılarını karşılaştırmış, Derin Öğrenme Algoritma ($R^2=0.9184$) modelleri ile Weibull fonksiyonuna ($R^2= 0.6121$) göre tahmin başarısında belirgin bir iyileşme elde etmiştir. Ülkemiz ormancılık literatüründe, Yapay Sinir Ağ modellerinin kullanımına ilişkin bazı çalışmalar söz konusu olmasına karşın, ağaçların boy tahminleri için Yapay Sinir Ağ modellerinin kullanımını oldukça sınırlıdır. Bu çalışmada, Ülkemiz ormancılık literatürü, artım ve büyüme modellemesi konusundaki yapay zeka çalışmalarına bir katkı olarak, Ülkemizin Marmara bölgesinde yer alan Kestel ormanları Anadolu Karaçam'ı meşcerelerindeki ağaçların çap-boy ilişkilerinin modellenmesinde, Yapay Sinir Ağ modellerinin kullanım olanaklarının değerlendirilmesi amaçlanmıştır. Bu kapsamda, farklı transfer fonksiyonları ile nöron sayılarını içeren ağ modellerinin eğitimi gerçekleştirilecek ve eğitilen ağ modeli alternatifleri ile elde edilen tahminlerin başarıları, klasik tahmin yöntemi olan Doğrusal Olmayan Regresyon modelinin tahmin başarısı ile karşılaştırılacaktır.

2. MATERYAL VE YÖNTEM

2.1. Materyal

Bu çalışmada, Bursa Orman Bölge Müdürlüğü, Bursa Orman İşletme Müdürlüğü, Kestel Orman İşletme Şefliği sınırları içerisinde yer alan eşityaşlı ve saf Anadolu Karaçamı [*Pinus nigra* J.F. Arnold ssp. *pallasiana* (Lamb.) Holmboe] meşcerelerinde ölçülen 110 örnek alanlarından elde edilen veriler kullanılmıştır (). Çalışma alanına ilişkin koordinatlar $29^{\circ}13'00''$ - $29^{\circ}21'54''$ doğu boylamları ile $40^{\circ}00'00''$ - $40^{\circ}12'10''$ kuzey enlemleridir. Çalışma alanı, 800 ile 1900 metre arasında değişmekte olup, ortalama yükseklik ise, 1250 metredir. Kestel Orman işletme şefliği, 5321.2 ha normal koru ve 6738.5 ha bozuk orman alanına sahip olup, bu ormanlık alan içinde Anadolu Karaçamı alanı ise toplam 2334 ha'dır. Çalışma alanına ait bir harita, Şekil 1'de verilmiştir.




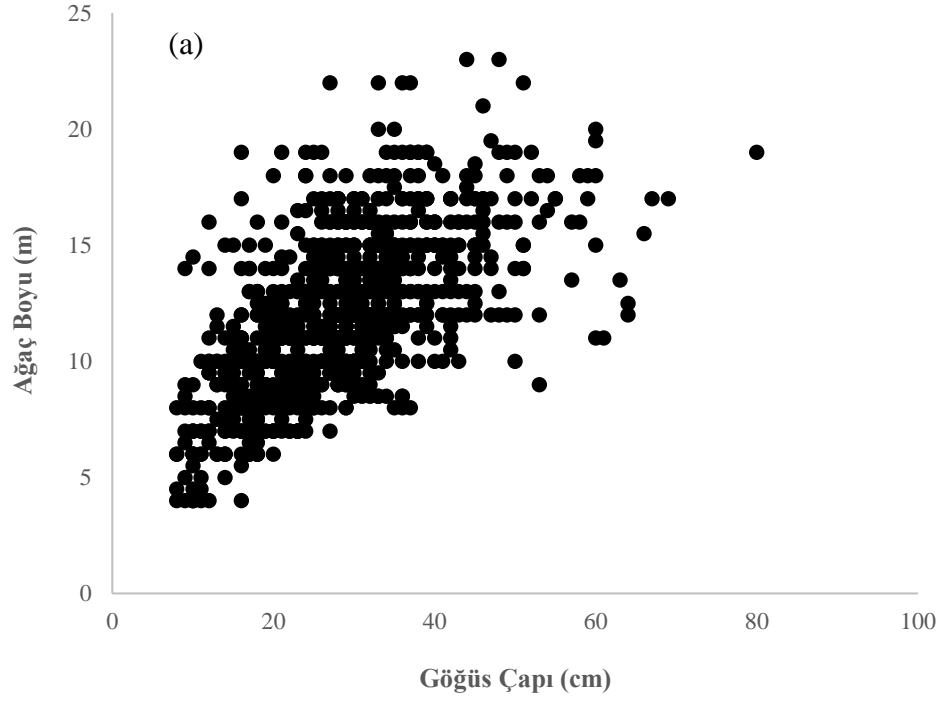
Şekil 2.1 Çalışma alanı Kestel Orman İşletme Şefliği Alanı

Bu çalışma alanı kapsamındaki örnek alanlar daire biçiminde olup, büyüklükleri meşcere kapalılığına göre 400 m² ile 800 m² arasında değişmektedir. Bu örnek alanlarda; göğüs çapları 8 cm ve daha büyük tüm ağaçlarda göğüs çapı ($d_{1.30}$) ve çap basamaklarında dengeli bir şekilde dağıtılan 8-10 ağaçta boylar ölçülmüştür. Ölçülen bu boy değerlerinin ayrıca hektarda 100 ağaç yöntemine göre belirlenmiş sayıda en boylu ağaçları içermektedir. Çap ölçümleri, çap ölçer ile mm hassasiyetinde, boy ölçümleri ise; Blume-Leiss Boy Ölçer ile cm hassasiyetinde gerçekleştirilmiştir. Ölçülen bu çap ve boy değerleri kullanılarak, örnek alanda hektarda 100 ağaç yöntemine göre belirlenmiş en kalın çaplı ağaçların ortalama çapı (D_0) ve boyunu (H_0) hesaplanmıştır. Örnek alanlarda yapılan bu ölçümler ile 953 adet çap-boy verisi elde edilmiş olup, bu veriler, regresyon analizinin gerçekleştirilmesi ile yapay sinir ağ modellerinin eğitilmesinde ve bu yöntemler ile elde edilen tahminlerin denetlenmesinde kullanılan veriler olmak üzere veriler rastgele iki gruba ayrılmıştır. I. grupta, toplam verinin yaklaşık % 85'i (811 örnek ağaç), II. grupta ise yaklaşık % 15'i (142 örnek ağaç) bulunmaktadır. Çizelge 2.1'de, verilere ilişkin çeşitli istatistiksel bilgiler verilmiştir. Şekil 2.2'de ise, eğitimde ve denetimde kullanılan veriler için ayrı ayrı olmak üzere çap-boy ilişkisi verilmiştir.

Çizelge 2.1. Çalışma materyaline ilişkin bazı istatistiksel bilgiler

| Değişkenler | | Min. | Max. | Aritmetik Ortalama (\bar{X}) | Standart Sapma (S) |
|-------------|---------------------------|-------|-------|----------------------------------|--------------------|
| Çap | Modelleme (I. Grup veri) | 8.00 | 80.00 | 28.50 | 11.33 |
| | Denetleme (II. Grup Veri) | 10.00 | 68.00 | 27.30 | 12.20 |
| Boy | Modelleme (I. Grup veri) | 4.00 | 23.00 | 12.13 | 3.55 |
| | Denetleme (II. Grup Veri) | 4.00 | 23.00 | 12.55 | 4.28 |
| D_0^* | Modelleme (I. Grup veri) | 10.00 | 80.00 | 37.52 | 11.69 |
| | Denetleme (II. Grup Veri) | 13.00 | 68.00 | 34.75 | 12.38 |
| H_0^* | Modelleme (I. Grup veri) | 5.50 | 23.00 | 13.86 | 3.26 |
| | Denetleme (II. Grup Veri) | 5.00 | 23.00 | 14.46 | 4.05 |

* D_0 ve H_0 değişkenleri; örnek alanda hektarda 100 ağaç yöntemine göre belirlenmiş en kalın çaplı ağaçların ortalama çapı ve boyunu ifade etmektedir.



Şekil 2.2. Doğrusal Olmayan Regresyon modelinin geliştirilmesinde ve Yapay Sinir Ağlarının eğitiminde (a) ve denetlemesinde (b) kullanılan verilerin çap-boy ilişkisi

2.2. Yöntem

Bu çalışmada, ağaçların boylarını tahmin etmek üzere bir istatistik yöntem olan Doğrusal Olmayan Regresyon modeli ile yapay zeka tekniği olan Yapay Sinir Ağ modelleri geliştirilmiştir.

2.2.1. Doğrusal Olmayan Regresyon Analizi

Farklı yapıdaki meşcerelerden elde edilen verilere ilişkin çap-boy ilişkilerini modellemek üzere, göğüs çapı ve ek olarak da çeşitli meşcere özelliklerini içerecek şekilde farklı Doğrusal Olmayan Regresyon denklemi (Genelleştirilmiş Boy Denklemi) önerilmiş ve kullanılmıştır (Huang *et al.* 1992, Fang and Baily 1998, Peng 1999, Gadow *et al.* 2001, Soares and Tomé 2002, Temesgen and Gadow 2004). Lei and Paresol (2001) ve Peng (2001), çap-boy ilişkisini modellemek üzere seçilen modelin; (i) parametre sayısı, (ii) biyolojik açıklanabilirlik, (iii) monotonik artış (iv) büküm noktası (inflection point) ve (v) yatay asimptot gibi matematiksel özellikleri taşıması gerektiğini ifade etmiştir.

Bu denklemlerden, balık popülasyonlarının modellenmesi için ilk olarak geliştirilen Schnute (1981)'un Doğrusal Olmayan Regresyon denklemi, yatay asimptota sahip olması ve Sigmoid trend gösterebilmesi ile farklı çap-boy ilişkilerini modellemekte oldukça başarılıdır. Ayrıca, Schnute (1981)'un denklemi, doğrusal olmayan modelleme önemli bir sorun olan yakınsak çözüme ulaşmada (convergence) oldukça başarılı sonuçlar vermektedir (Lei and Paresol 2001). Bu çalışmada, ağaçların çap-boy ilişkilerini modellemek üzere, sahip olduğu model yapısı (yatay asimptota sahip olan ve Sigmoid trend gösterebilen) ve parametre tahmininde kolay çözüm verebilen Schnute (1981)'un denklemi seçilmiştir. Schnute (1981)'un Doğrusal Olmayan Regresyon denklemi;

$$h = \left(h_1^{b_1} + (h_2^{b_1} - h_1^{b_1}) \frac{1 - e^{-b_2(d-d_1)}}{1 - e^{-b_2(d_2-d_1)}} \right)^{1/b_1} + \varepsilon \quad (1)$$

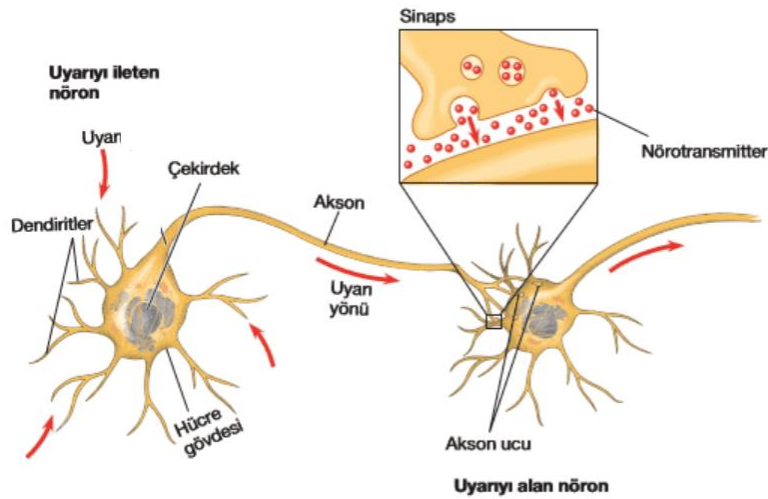
biçiminde olup, bu eşitlikte h ; tahmin edilecek ağaç boyunu (m), d ; göğüs çapını (cm), d_1 ; örnek alandaki minimum göğüs çapını (cm), d_2 ; örnek alandaki maksimum göğüs çapını (cm), h_1 ; örnek alanda d_1 çapına karşılık gelen ağaç boyunu (m), h_2 ; örnek alanda d_2 çapına karşılık gelen ağaç boyunu (m), b_1 ve b_2 model parametreleri ve ε ise model hatalarını ifade etmektedir. Genel bir uygulama olarak, çap-boy denklemlerini göğüs çapının 0 ($d = 0$) olduğu durumda, boy değerini, 1.3 m ($h = 1.3$) olarak tahmin edecek şekilde düzenlenmektedir (Castedo-Dorado *et al.* 2006). Bu özellik, örnek alandaki en küçük çapı ifade eden d_1 değişkenini; 0, örnek alandaki d_1 çapına karşılık gelen boyu ifade eden h_1 değişkenini; 1.3 olarak modele ilave edilmesi ile sağlanmaktadır. Ayrıca modelde en kalın çaplı ağacın çapının d_2 ve bu çapa karşılık gelen boyun h_2 kullanılması, veri setindeki aşırı değerlerin model tahminlerini olumsuz bir şekilde etkilemesine neden olabilmektedir (Fang and Bailey 1998). Bu nedenle; modelde d_2 ve h_2 değişkenleri yerine, örnek alanda hektarda 100 ağaç yöntemine göre belirlenmiş en kalın çaplı ağaçların ortalama çapının (D_0) ve boyunun (H_0) kullanılması önerilmektedir (Castedo-Dorado *et al.* 2006). Böylece yapılan düzenlemeler ile Schnute (1981) denklemi;

$$h = \left(1.3^{b_1} + (H_0^{b_1} - 1.3^{b_1}) \frac{1 - e^{-b_2 d}}{1 - e^{-b_2 D_0}} \right)^{1/b_1} + \varepsilon \quad (2)$$

biçiminde elde edilir. Bu denklemde, D_0 ve H_0 değişkenleri; örnek alanda hektarda 100 ağaç yöntemine göre belirlenmiş en kalın çaplı ağaçların ortalama çapını ve boyunu ifade etmektedir. Yukarıda eşitliği verilen ve çap-boy ilişkilerinin modelleyen doğrusal olmayan Schnute (1981)'un denkleminin parametre tahminlerinin elde edilmesinde, "Levenberg–Marquardt" algoritmasını esas alan SAS İstatistik Paket Programındaki MODEL prosedürü kullanılmıştır (SAS Institute Inc. 2004).


2.2.2 Yapay Sinir Ağları ile Boy Tahmini

Ağaçların çap-boy ilişkilerini modellemek üzere kullanılan diğer bir tahmin yöntemi de, yapay zeka tekniklerinden birisi olan Yapay Sinir Ağları tekniğidir. Yapay Sinir Ağları için çok farklı tanımlar olmasına karşın, temelde genel olarak insan beyninin ya da merkezi sinir sisteminin çalışma prensiplerini taklit ederek bilgisayar sistemlerine öğrenme, bilgi edinme, bilgiler arasında bağlantı ve ilişki kurma ve hatırlama gibi yetenekleri kazandırılması olarak tanımlanabilir (Kohonen 1987, Haykin 1994). Yapay Sinir Ağlarının esası, insan beynini ve sinir hücresini oluşturan biyolojik üniteler nöronların modellenmesi ve bilgisayar sistemlerinde uygulanmasına dayanır (Freeman and Skapura 1991). Yapay Sinir Ağ modellerine temel olan insan sinir hücresini kısaca tanırsak (Şekil 2.3); sinyaller hücrelerden gelen sinyalleri çekirdeğe ileten kısma dendrit (dendrite) gelir, gelen sinyalleri toplayan yapıya soma (soma) olarak adlandırılıp, toplanan bu bilgiyi diğer hücelere akson (axon) ile iletilir, aksonlardan gelen bilgi sinapslar (synaptic) ile ön işlemden geçirilerek diğer hücrelerin dendritlerine iletilir (Şeker 2017). Yapay sinir ağ modellerinde (Şekil 2.4.), nöron; işlemci elemanına, dendrit; toplama fonksiyonuna, hücre gövdesi; transfer fonksiyonuna, aksonlar; yapay nöron çıkışı ve sinapslar da; ağırlıklara karşılık gelmektedir (Öztürk ve Şahin 2018).



Şekil 2.3. İnsan sinir sisteminde nöron yapısı ve uyarı iletimi

(<http://okuyorumben.com/sinir-hucresinin-yapisi-ve-cesitleri.html>, 2019)



Şekil 2.4. Biyolojik sinir hücreleri ile yapay sinir ağlarının yapısının karşılaştırılması (Maltarollo, 2013).

Yapay Sinir Ağ modelleri, insan sinir hücrelerini ve bu hücrelerde gerçekleşen veri aktarım sürecini esas alarak, giriş katmanı (Input layer), gizli ya da ara katman (Hidden layer) ve çıktı katmanı (Output layer) olmak üzere temelde üç katmandan oluşan bir yapıda geliştirilir. Özellikle, ara katman sayısının artırılması durumunda ise, Yapay Sinir Ağ modellerinin üç katman olan temel yapısından daha fazla katman sayısına sahip, kompleks ağ modelleri elde edilebilmektedir. Yapay Sinir Ağ modellerinin katmanlı yapısının girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere 5 temel elemanı vardır (Öztemel 2006). Bu elemanlardan, farklı katmanlar arasında bağlantıyı/eşleşmeyi sağlayan aktivasyon fonksiyonu, ağ modelini tasarlayan ve ağ eğitimi gerçekleştiren araştırmacı ya da uygulayıcı tarafından değiştirilebilen bir özelliğe sahiptir. Farklı Yapay Sinir Ağları yazılımlarında çeşitli aktivasyon fonksiyonları kullanılmasına karşın, hiperbolik tanjant sigmoid (tan-sig), lojistik sigmoid (log-sig) ve doğrusal-linear (pure-lin) fonksiyon olmak üzere üç farklı

fonksiyonun kullanımı yaygındır. Bu çalışmada da kullanılan aktivasyon fonksiyonları aşağıda daha da ayrıntılı olarak açıklanmıştır.

lojistik sigmoid (log-sig) aktivasyon fonksiyonu: yapay sinir ağlarının eğitiminde en çok tercih edilen aktivasyon fonksiyonu olan lojistik sigmoid fonksiyonun değişim aralığı, 0 1 arasındadır. Bu aralıkta, lojistik sigmoid fonksiyonu, doğrusal olmayan bir değişim trendi ortaya koyar (Şekil 2.5). Bu fonksiyonun formülü olarak ifadesi aşağıda verilmiştir:

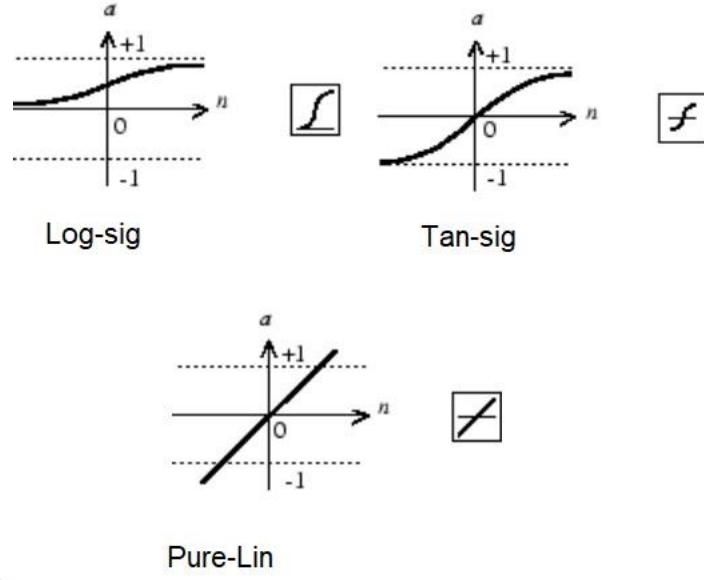
$$y = \frac{1}{1+e^{-x}} \quad (3)$$

hiperbolik tanjant sigmoid (tan-sig) aktivasyon fonksiyonu: Bu fonksiyonun değişim aralığı, -1 +1 olup, lojistik sigmoid fonksiyon gibi bu tanım aralığında, hiperbolik tanjant sigmoid fonksiyon doğrusal olmayan bir değişim gösterir (Şekil 2.5). Bu fonksiyona ilişkin formül aşağıda verilmiştir:

$$y = \frac{2}{1+e^{-2 \cdot x}} - 1 \quad (4)$$

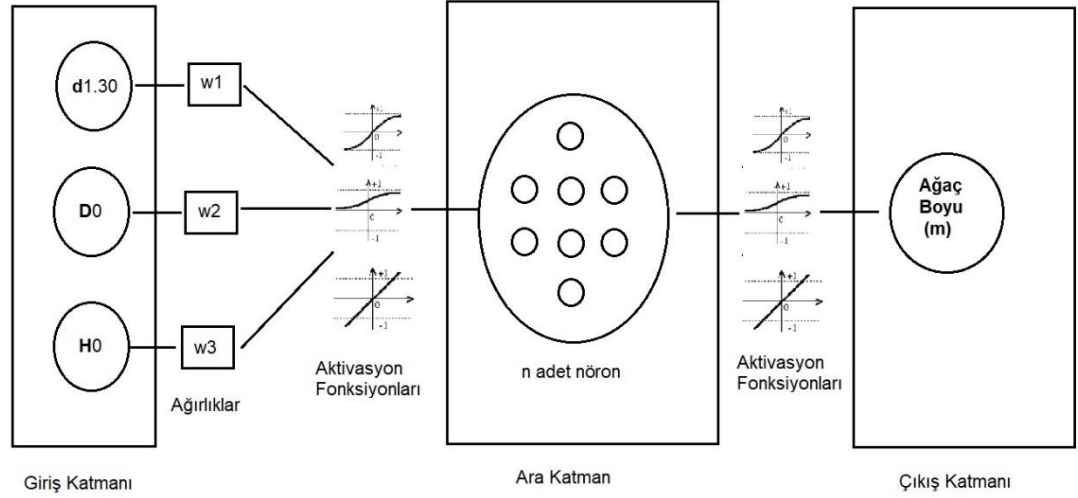
Doğrusal-linear aktivasyon fonksiyonu: Bu aktivasyon fonksiyonu doğrusal değişimi ifade edip (Şekil 2.5), bir önceki katmandan elde edilen sonuç, belirli bir katsayı ile çarpılarak, bir sonraki katmana aktarılır. Bu fonksiyonun değişim aralığı, hiperbolik tanjant sigmoid fonksiyon da olduğu gibi -1 +1'dir.

$$y = A \cdot x \quad (5)$$



Şekil 2.5. Farklı aktivasyon fonksiyonları

Bu çalışmada, verilerin eğitiminde kullanılan Yapay Sinir Ağ modeli olarak giriş katmanı (Input layer), gizli ya da ara katman (Hidden layer) ve çıktı katmanı (Output layer) olmak üzere üç katmandan oluşan ağ yapısı esas alınmıştır (Şekil 2.6.). Bu katmanlar arasındaki bağlantılar ise, daha önce söz edilen aktivasyon fonksiyonları olan hiperbolik tanjant sigmoid (tan-sig), lojistik sigmoid (log-sig) ve doğrusal (Pure-Lin) fonksiyon ile sağlanmıştır. YSA modellerinde diğer bir önemli bir konu da, araştırmacı ya da uygulayıcı tarafından belirlenebilen ara katmandaki nöron sayısıdır. Özellikle, aktivasyon fonksiyon çeşidi ve nöron sayısı, Yapay Sinir Ağ modelinin tahmin başarısını etkileyen önemli parametrelerdir. Yapay sinir ağ modellerinin çeşitli sayıya nöron içeren çok katmanlı ve paralel olarak çalışan bu yapısı, doğrusal olmayan ilişkilerin modellenmesine ve tahminlerin başarıyla elde edilmesine imkan sağlar (Nasr *et al.* 2003).



Şekil 2.6. Bu çalışmada esas alınan Yapay Sinir Ağ modeli

Yapay Sinir Ağ modeli ile verilerin eğitimi; ağaçların toplam boyu, çıktı değişkeni (target variable), göğüs çapı, örnek alanda hektarda 100 ağaç yöntemine göre belirlenmiş en kalın çaplı ağaçların ortalama çapı D_0 ve boyu H_0 değişkenleri ise giriş (input) değişkeni olarak alınarak gerçekleştirilmiştir. YSA modellerinin eğitiminde, aktivasyon fonksiyonu olarak; hiperbolik tanjant sigmoid (tan-sig), lojistik sigmoid (log-sig) ve doğrusal (pure-lin) fonksiyon olmak üzere üç farklı fonksiyon kullanılmıştır. Özellikle, YSA modellerinin üç katmanlı yapısında, giriş katmanı ile ara katman ve ara katman ile çıkış katmanı bağlantı noktalarında farklı aktivasyon fonksiyonları seçenekleri için veri eğitimleri gerçekleştirilmiştir. YSA modellerinin üç katmanlı yapısında, katmanlar arası bağlantı noktalarındaki aktivasyon fonksiyon seçenekleri Çizelge 2.2’de gösterilmiştir. Yapılan ön analizlerde, lojistik sigmoid (log-sig) aktivasyon fonksiyonunun ara katman ile çıkış katmanı bağlantı noktasında olduğu ve doğrusal (pure-lin) fonksiyonunun giriş katmanı ile ara katman ve ara katman ile çıkış katmanı bağlantı noktalarında olduğu alternatiflerin (A1, A4, A7 ve A9), değerlendirmeye alınamayacak düzeyde oldukça başarısız sonuçlar verdiği belirlenmiş olup, böylece bu aktivasyon fonksiyon alternatifleri çeşitli Yapay Sinir Ağ modeli ve regresyon modeli karşılaştırmalarından çıkarılmıştır. Böylece beş aktivasyon fonksiyonu alternatifi için eğitimler gerçekleştirilmiş ve tahminler elde edilmiştir.

Yapay sinir ađ modellerinde, tahmin başarısını etkileyen diđer bir parametre de, ara katmanda bulunan nron sayıdır. Bu alıřmada, 1'den 100 nron sayısına olmak zere, 100 farklı nron sayısı seeneđi iin veri eđitimi gerekleřtirilmiř ve tahminler elde edilmiřtir. Bylece, beř farklı aktivasyon fonksiyonu alternatifi ve 100 farklı nron sayısı alternatifi olmak zere 500 farklı Yapay sinir ađ modeli alternatifi iin veri eđitimi gerekleřtirilmiř ve tahminler elde edilmiřtir. Bu farklı Yapay sinir ađ modellerinin eđitim srecinde, en ok tercih edilen İleri Beslemeli-Geri Yayımly (feed-forward backprop artificial neural network) yapay sinir ađ yapısı kullanılmıřtır. Bu alıřmada, farklı Yapay Sinir Ađ model alternatiflerini ieren İleri Beslemeli-Geri Yayımly Yapay Sinir Ađ modellerinin eđitim srelerinin gerekleřtirilmesinde ve boy tahminlerinin elde edilmesinde, "the Mathworks MATLAB" yazılımının R2015 versiyonu iindeki Neural Network Toolbox (nntool) modl kullanılmıřtır (The MathWorks Inc. 2015).

Çizelge 2.2. Aktivasyon Fonksiyon seçenekleri

| Aktivasyon Fonksiyon Alternatifleri | Giriş Katman - Ara Katman Arası Aktivasyon Fonksiyonu | Ara Katman - Çıkış Katman Arası Aktivasyon Fonksiyonu |
|--|--|--|
| A1 | lojistik sigmoid (log-sig) | lojistik sigmoid (log-sig) |
| A2 | lojistik sigmoid (log-sig) | hiperbolik tanjant sigmoid (tan-sig) |
| A3 | lojistik sigmoid (log-sig) | linear (pure-lin) |
| A4 | hiperbolik tanjant sigmoid (tan-sig) | lojistik sigmoid (log-sig) |
| A5 | hiperbolik tanjant sigmoid (tan-sig) | hiperbolik tanjant sigmoid (tan-sig) |
| A6 | hiperbolik tanjant sigmoid (tan-sig) | linear (pure-lin) |
| A7 | linear (pure-lin) | lojistik sigmoid (log-sig) |
| A8 | linear (pure-lin) | hiperbolik tanjant sigmoid (tan-sig) |
| A9 | linear (pure-lin) | linear (pure-lin) |

2.2.3. YSA modellerinin Tahminlerinin Karşılaştırılması ve Denetlemesi

500 farklı Yapay Sinir Ağ modellerinden ağaçların boy tahminlerinden en başarılı olan YSA yapılarının belirlenmesinde, çeşitli istatistiksel ölçüt değerleri kullanılmıştır. Bu ölçütler; (1) ölçülen boy değerleri ile tahmini boy değerleri arasındaki korelasyon katsayısı R , (2) Ortalama Mutlak Hata (OMH), (3) max. Ortalama Mutlak Hata (OMH), (4) Hata Karelerin Ortalamasının Karekökü (HKOK), (5) Yüzde Hata Kareler Ortalamasının Karekökü (HKOK%), (6) Ortalama Hata (Bias), (7) Yüzde Ortalama Hata (Bias%), (8) Belirtme Katsayısı (R^2), (9) Akaike Bilgi Ölçütü (AIC) ve (10)

Bayesian Bilgi Ölçütü (BIC) değeri olmak üzere on farklı başarı ölçütüdür. Kullanılan bu ölçütlere ilişkin formüller aşağıda verilmiştir.

$$r = \left(\sum_{i=1}^n [(h_i - \bar{h}_i) \cdot (\hat{h}_i - \hat{\hat{h}}_i)] / \sqrt{\sum_{i=1}^n (h_i - \bar{h}_i)^2 \cdot \sum_{i=1}^n (\hat{h}_i - \hat{\hat{h}}_i)^2} \right) \quad (6)$$

$$OMH = \sum_{i=1}^n |h_i - \hat{h}_i| / n \quad (7)$$

$$max. OMH = max(|h_i - \hat{h}_i| \dots \dots \dots |h_n - \hat{h}_n|) \quad (8)$$

$$HKOK = \sqrt{\sum_{i=1}^n (h_i - \bar{h}_i)^2 / (n - k)} \quad (9)$$

$$HKOK\% = \left(\left[\sqrt{\sum_{i=1}^n (h_i - \hat{h}_i)^2 / (n - k)} \right] / \bar{h}_i \right) \cdot 100 \quad (10)$$

$$Bias = \sum_{i=1}^n (h_i - \hat{h}_i) / n \quad (11)$$

$$Bias\% = \left(\left[\sum_{i=1}^n (h_i - \hat{h}_i) / n \right] / \bar{h}_i \right) \cdot 100 \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (h_i - \hat{h}_i)}{\sum_{i=1}^n (h_i - \bar{h}_i)} \quad (13)$$

$$AIC = n \cdot \ln(HKOK) + 2 \cdot k \quad (14)$$

$$BIC = n \cdot \ln(HKOK) + n \cdot \ln(k) \quad (15)$$

Bu formüllerde, h_i : arazide ölçülen ve gözlemlenen boy değerleri olup, \hat{h}_i : Yapay Sinir Ağ modelleri ve Schnute (1981)'un Doğrusal Olmayan Regresyon modeli ile tahmin edilen boy değerlerini ifade etmektedir. \bar{h}_i : gözlemlenen boy değerlerinin ortalaması olarak hesaplanmıştır. Formüllerdeki k değeri; tahminlerde kullanılan girdi değişken sayısını, n; veri sayısını göstermektedir. Bu ölçüt değerlerinden, 0 ile 1 arasında değer alan belirtme katsayısının, mümkün olduğunca 1'e yakın bir değer alması istenilmektedir. Diğer ölçüt değerlerinin küçük değerler alması, daha başarılı tahminlerin elde edildiğini göstermektedir.

Farklı tahmin modellerine ilişkin hesaplanan bu on farklı başarı ölçütünün birlikte değerlendirilebilmesinde, Poudel and Cao (2013) tarafından önerilmiş Rölatif Sıralama Yöntemi esas alınmıştır. Poudel and Cao (2013)'un Rölatif Sıralama Yöntemi, başarı ölçütlerinin uzaklık ve yakınlıklarını da dikkate almakta, böylece farklı modellerin çok sayıdaki ölçüte göre daha etkin ve başarılı bir sıralama yapılabilir (Özçelik ve Çevlik 2017, Özdemir 2018). Rölatif sıralama yöntemine göre rölatif sıra değeri aşağıdaki formülle hesaplanmıştır (Poudel and Cao 2013).

$$R_i = 1 + \frac{(m-1)(S_i - S_{min.})}{(S_{max.} - S_{min.})} \quad (16)$$

Bu formülde, R_i : i. modelin rölatif sırasını, S_i : i. modele ilişkin başarı ölçüt değerini, $S_{min.}$: en düşük başarı ölçüt değerini, $S_{max.}$: en yüksek başarı ölçüt değerini göstermektedir. Rölatif Sıralama Yönteminde, en küçük toplam rölatif sıra değerine sahip tahmin modeli; en başarılı tahmin modeli olarak alınmaktadır.

Ağaçların boy değerlerini tahmin etmede en başarılı olarak belirlenen Yapay Sinir Ağ modelinin çalışma alanındaki meşcerelere uygunluğunun denetlenmesinde (validation), modellerinin eğitiminde kullanılmamış 142 ağaçtan oluşan bir veri seti kullanılmıştır. Bunun için modellerinin eğitiminde kullanılmamış olan 142 adet ağacın boyu, en başarılı olarak belirlenen Yapay Sinir Ağ modeli ile tahmin edilmiş, bu tahmin değerleri ile gözlem değerleri arasındaki % 95 güvenle istatistiksel bir fark olup olmadığı ise İki Eş Arasındaki Farkın Önemlilik testi ile analiz edilmiştir (Kalıpsız 1988; Batu 1995). İki farklı şekilde elde edilen bu boy değerleri arasında, istatistiksel olarak bir farklılık olmaması durumunda ($p > 0.05$); söz konusu Yapay Sinir Ağ modelinin çalışma alanı için uygun olduğu sonucuna varılır. Bununla birlikte ölçülen ve tahmini boy değerleri arasında istatistiksel olarak anlamlı bir fark olması durumunda ise ($p < 0.05$) Yapay Sinir Ağ modelinin, çalışma alanı için uygun olmadığı sonucuna varılabilir.

3. BULGULAR ve TARTIŞMA

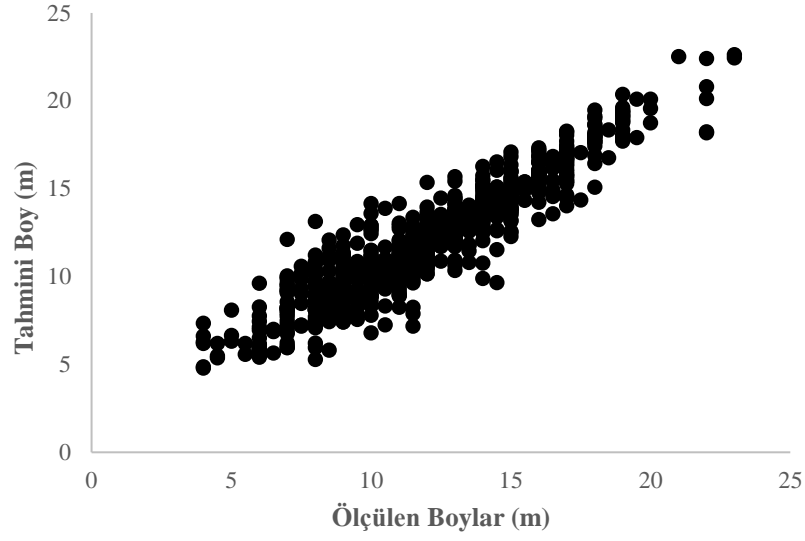
Çizelge 3.1’de, farklı aktivasyon fonksiyonu seçeneği için en başarılı olarak belirlenen nöron sayısı seçeneğini içeren Yapay Sinir Ağ Modelleri ve Schnute (1981)’un Doğrusal Olmayan Regresyon modeline ilişkin r , OMH, max. OMH, HKOK, HKOK%, Bias, Bias%, R^2 , AIC ve BIC başarı ölçüt değerleri verilmiştir. Çizelge 3.2’de ise, bu başarı ölçüt değerleri kullanılarak Cao ve Poudel (2013)’in Rölatif Sıralama Yöntemine ilişkin rölatif sıra değerleri verilmiştir. Bu ölçüt değerlerinden r ; 0.7402 ile 0.9336, OMH; 0.8792 ile 1.5914, max. OMH; 4.2283 ile 52.2797, HKOK; 1.2514 ile 2.8594, HKOK%; 10.3153 ile 23.5690, Bias; -0.8380 ile 0.6413, Bias%; -6.9078 ile 5.2863, R^2 ; 0.3534 ile 0.8761, AIC; 187.9084 ile 858.0389 ve BIC; 202.0032 ile 872.1337 arasında değişmektedir. Bu başarı ölçütleri değerlendirildiğinde; lojistik sigmoid (log-sig)’in giriş katmanı ile ara katmanı bağlantı noktasında olduğu ve hiperbolik tanjant sigmoid (tan-sig)’in de ara katman ile çıkış katmanı bağlantı noktasında olduğu aktivasyon fonksiyonu seçeneğine (A2) ve 75 nörona sahip YSA modelinin ağaçların boy değerlerini tahmin etmede en başarılı Yapay Sinir Ağ modeli olduğu görülmektedir (Çizelge 3.1 ve 3.2). Schnute (1981)’un regresyon modelinden belirgin tahmin başarısı ile öne çıkan Yapay Sinir Ağ modelinin r ; 0.9317, OMH; 0.9183, max. OMH; 5.1449, HKOK; 1.2660, HKOK%; 10.4356, Bias; -0.0229, Bias%; -0.1886, R^2 ; 0.8732, AIC; 197.3114 ve BIC; 211.4062 olarak hesaplanmıştır. Şekil 3.1’de, En başarılı Yapay Sinir Ağ modeli ile tahmin edilen boyların ölçülen boylara göre değişimi, Şekil 3.2’de ise, Schnutte (1981)’in denklemi ile tahmin edilen boyların ölçülen boylara göre değişimi görülmektedir. Özellikle, Şekil 3.1’deki değişimin, Şekil 3.2’e göre 45^0 eğime daha yakın bir değişim göstermesi, en başarılı olarak belirlenen Yapay Sinir Ağ modelinin tahminlerin, Schnutte (1981)’un doğrusal olmayan regresyon denklemine göre daha başarılı olması ile açıklanabilir.

Çizelge 3.1. Farklı Aktivasyon fonksiyonlarında en başarılı olarak belirlenen nöron sayısı seçenekleri için Yapay Sinir Ağ modelleri ve Doğrusal Olmayan Regresyon modeline ilişkin r , OMH, max. OMH, HKOK, HKOK%, Bias, Bias%, R^2 , AIC and BIC başarı ölçüt değerleri

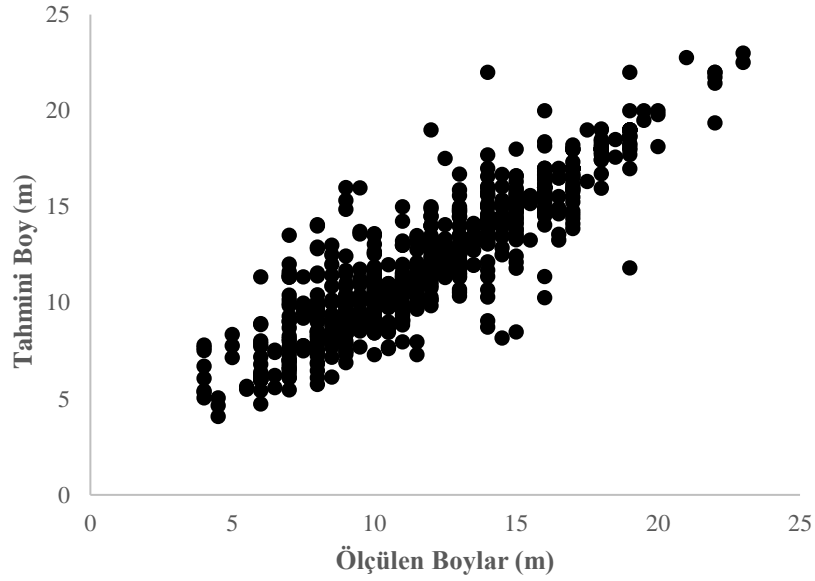
| Transfer Fonksiyonu Seçeneği | Nöron Sayısı | r | OMH | Max. OMH | HKOK | HKOK % | AIC | BIC | Bias | Bias% | R^2 |
|-----------------------------------|--------------|--------|--------|----------|--------|---------|----------|----------|----------|---------|--------|
| A2 | 75 | 0.9317 | 0.9183 | 5.1449 | 1.2660 | 10.4356 | 197.3114 | 211.4062 | -0.02288 | -0.1886 | 0.8732 |
| A3 | 97 | 0.9254 | 0.9135 | 6.9271 | 1.3214 | 10.8915 | 231.9892 | 246.0840 | -0.0103 | -0.0849 | 0.8619 |
| A5 | 80 | 0.9292 | 0.9090 | 5.7120 | 1.2883 | 10.6187 | 211.4145 | 225.5093 | 0.0241 | 0.1990 | 0.8687 |
| A6 | 98 | 0.9336 | 0.8804 | 7.2962 | 1.2514 | 10.3153 | 187.9084 | 202.0032 | -0.0682 | -0.5623 | 0.8761 |
| A8 | 82 | 0.9053 | 1.1053 | 4.6471 | 1.4865 | 12.2525 | 327.4783 | 341.5731 | 0.0171 | 0.1409 | 0.8252 |
| A9 | 86 | 0.9051 | 1.1106 | 4.5895 | 1.4813 | 12.2097 | 324.6445 | 338.7393 | 0.0151 | 0.1242 | 0.8265 |
| Doğrusal Olmayan Regresyon Modeli | | 0.8914 | 1.0470 | 8.0000 | 1.6427 | 13.5403 | 408.5338 | 422.6286 | 0.1797 | 1.4810 | 0.7866 |

Çizelge 3.2. Farklı Aktivasyon fonksiyonlarında en başarılı olarak belirlenen nöron sayısı seçenekleri için Yapay Sinir Ağ modelleri ve Doğrusal Olmayan Regresyon modeline ilişkin r , OMH, max. OMH, HKOK, HKOK%, Bias, Bias%, R^2 , AIC and BIC başarı ölçüt değerlerine göre hesaplanan rölatif sıra değerleri

| Transfer Fonksiyonu Seçeneği | Nöron Sayısı | r | OMH | Max. OMH | HKOK | HKOK % | AIC | BIC | Bias | Bias% | R^2 | Σ |
|-----------------------------------|--------------|---------|---------|----------|---------|---------|---------|---------|---------|---------|---------|----------|
| A2 | 75 | 6.700 | 33.833 | 12.407 | 6.428 | 6.428 | 9.391 | 9.391 | 16.374 | 16.374 | 4.324 | 121.649 |
| A3 | 97 | 26.123 | 29.834 | 34.586 | 26.998 | 26.998 | 40.336 | 40.336 | 7.383 | 7.383 | 17.271 | 257.248 |
| A5 | 80 | 14.480 | 26.083 | 19.464 | 14.687 | 14.687 | 21.976 | 21.976 | 17.276 | 17.276 | 9.456 | 177.362 |
| A6 | 98 | 1.000 | 2.076 | 39.181 | 1.000 | 1.000 | 1.000 | 1.000 | 48.774 | 48.774 | 1.000 | 144.805 |
| A8 | 82 | 88.356 | 190.854 | 6.212 | 88.403 | 88.403 | 125.547 | 125.547 | 12.241 | 12.241 | 59.212 | 797.015 |
| A9 | 86 | 88.853 | 195.338 | 5.495 | 86.474 | 86.474 | 123.018 | 123.018 | 10.791 | 10.791 | 57.820 | 788.073 |
| Doğrusal Olmayan Regresyon Modeli | | 131.277 | 141.923 | 47.939 | 146.510 | 146.510 | 197.878 | 197.878 | 128.438 | 128.438 | 103.444 | 1370.236 |



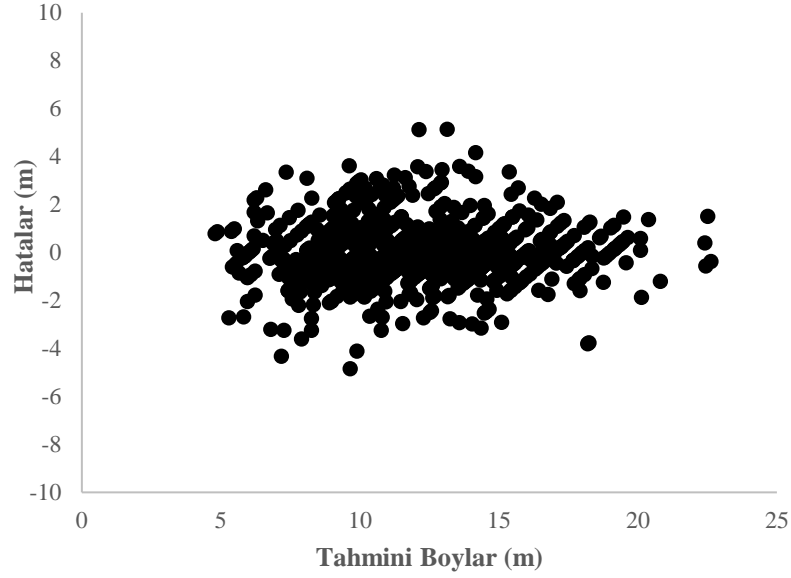
Şekil 3.1. En başarılı Yapay Sinir Ağ modeli ile tahmin edilen boyların ölçülen boylara göre değişimi



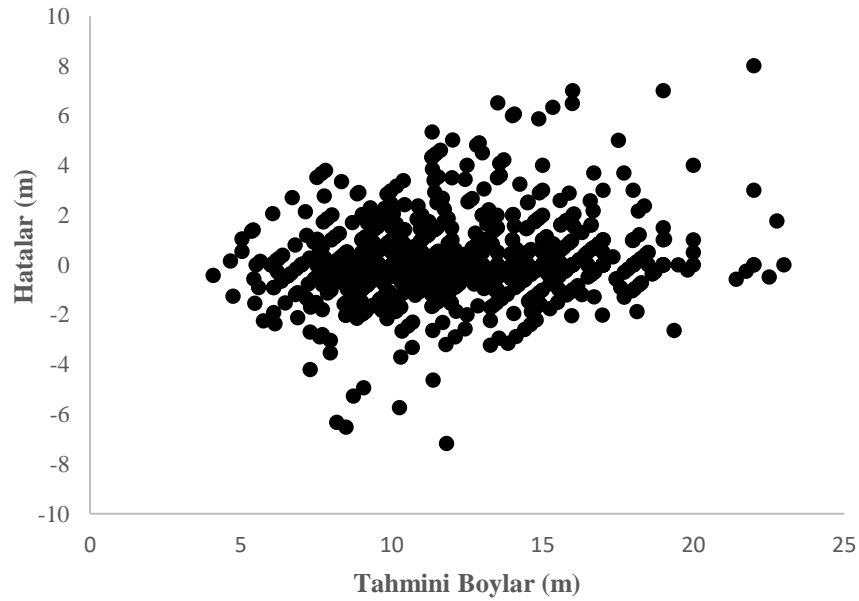
Şekil 3.2 . Schnutte (1981)'in denklemi ile tahmin edilen boyların ölçülen boylara göre değişimi

Şekil 3.3 ve 3.4'te ise, en başarılı Yapay Sinir Ağ modeli (A2 aktivasyon fonksiyonu ile 75 nöronu içeren ağ modeli) ve Schnutte (1981)'un regresyon denklemi ile elde edilen tahminlere göre hataların değişimi görülmektedir. Bu şekiller değerlendirildiğinde, YSA

modelinde ile hataların deęiřimi, Schnutte (1981)'in denklemi ile elde edilen hata deęiřimine gre daha rasgele ve daha kçük deęerlerde elde edilmiřtir. Bu řekildeki deęiřim, Schnutte (1981)'in denklemine gre en bařarılı Yapay Sinir Aę modelinin boy tahminlerindeki bařarısı ile aıklanabilir.



řekil 3.3. En bařarılı YSA modeline iliřkin hataların ile tahmin edilen boylara gre deęiřimi



řekil 3.4. Schnutte (1981)'in denklemine iliřkin hataların ile tahmin edilen boylara gre deęiřimi

Çizelge 3.3'te, Yapay Sinir Ağ modellerinin farklı aktivasyon fonksiyonları seçeneklerine göre elde edilen r , OMH, max. OMH, HKOK, HKOK%, R^2 , AIC ve BIC başarı ölçüt değerlerinin ortalama değerleri verilmiştir. Çizelge 3.4'te ise, ortalama başarı ölçütlerine göre hesaplanan rölatif sıralar değerleri verilmiştir. Çizelge 3.3. ve 3.4.'te bu değerler değerlendirildiğinde, A2 aktivasyon fonksiyonu seçeneğinin, ağaçların boy tahminlerinde en başarılı sonuçları veren aktivasyon alternatifi olduğu görülmektedir.

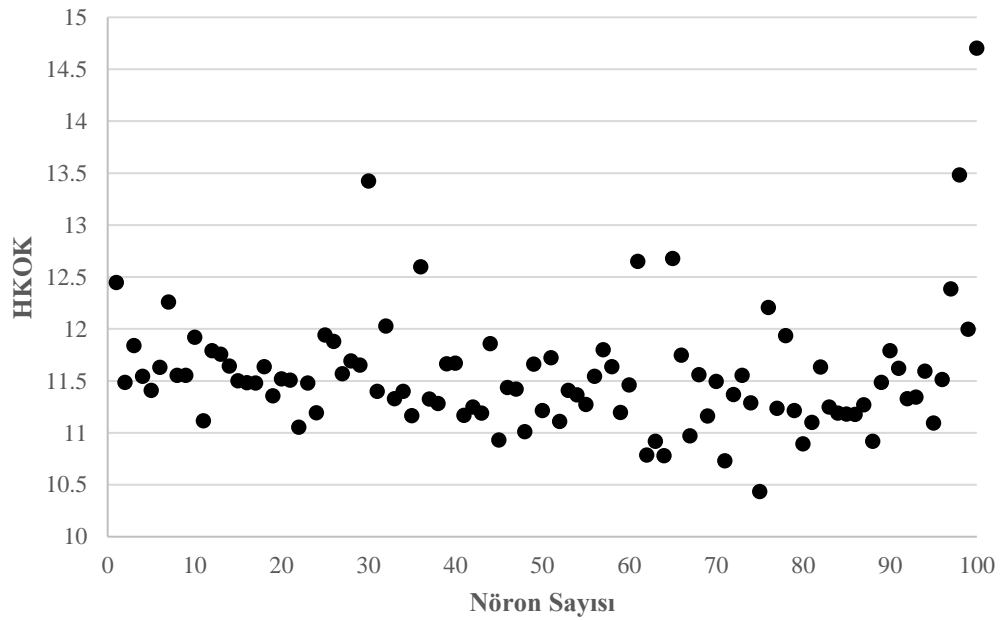
Çizelge 3.3. Aktivasyon fonksiyonu alternatiflerine göre r , OMH, max. OMH, HKOK, HKOK%, R^2 , AIC ve BIC başarı ölçütlerinin ortalamaları

| Aktivasyon Fonksiyonu Alternatifi | r | OMH | Max. OMH | HKOK | HKOK % | AIC | BIC | R^2 |
|-----------------------------------|--------|--------|----------|--------|---------|----------|----------|--------|
| A2 | 0.9162 | 1.0065 | 7.0688 | 1.4019 | 11.5558 | 279.0468 | 293.1416 | 0.8442 |
| A3 | 0.9132 | 1.0087 | 8.0726 | 1.4263 | 11.7566 | 290.0172 | 304.1120 | 0.8371 |
| A5 | 0.9139 | 1.0183 | 7.1034 | 1.4281 | 11.7717 | 293.2963 | 307.3911 | 0.8380 |
| A6 | 0.9107 | 1.0257 | 9.2675 | 1.4606 | 12.0389 | 308.5405 | 322.6353 | 0.8287 |
| A8 | 0.9024 | 1.1582 | 4.4803 | 1.5157 | 12.4933 | 343.2124 | 357.3072 | 0.8183 |
| A9 | 0.9046 | 1.1397 | 4.4670 | 1.4937 | 12.3122 | 331.3901 | 345.4849 | 0.8235 |

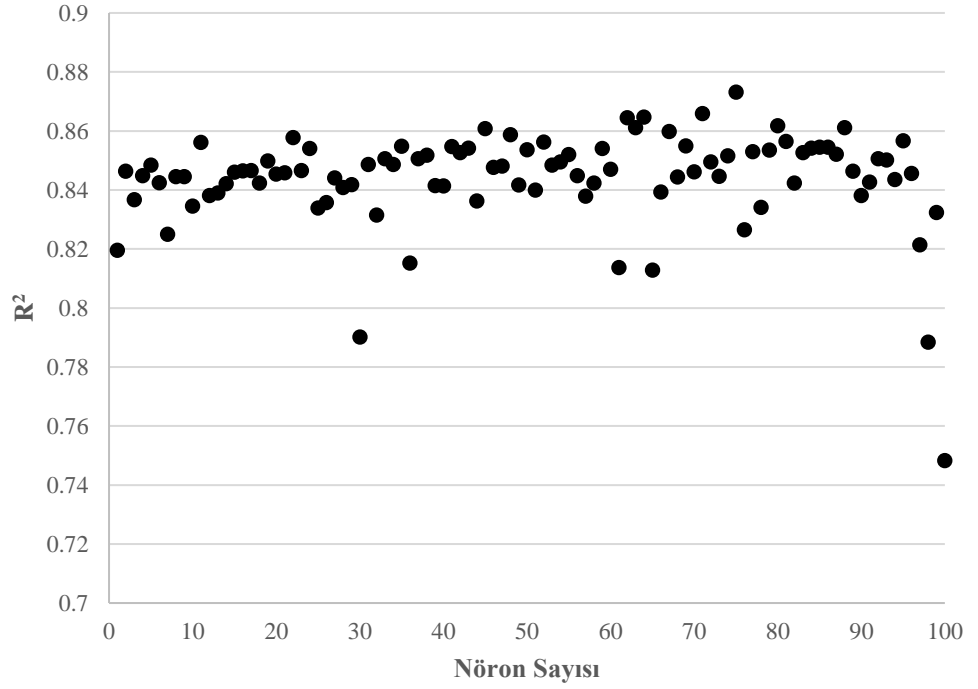
Çizelge 3.4. Aktivasyon fonksiyon alternatiflerine göre r , OMH, max. OMH, HKOK, HKOK%, R^2 , AIC ve BIC başarı ölçütlerinin rölatif sıra değerleri

| Aktivasyon Fonksiyonu Seçeneği | r | OMH | Max. OMH | HKOK | HKOK % | AIC | BIC | R^2 | Σ |
|--------------------------------|-------|-------|----------|-------|--------|-------|-------|-------|----------|
| A2 | 1.000 | 1.000 | 3.710 | 1.000 | 1.000 | 1.000 | 1.000 | 1.000 | 10.710 |
| A3 | 2.093 | 1.072 | 4.755 | 2.071 | 2.071 | 1.855 | 1.855 | 2.365 | 18.137 |
| A5 | 1.840 | 1.389 | 3.746 | 2.152 | 2.152 | 2.110 | 2.110 | 2.198 | 17.697 |
| A6 | 3.002 | 1.634 | 6.000 | 3.577 | 3.577 | 3.298 | 3.298 | 3.986 | 28.372 |
| A8 | 6.000 | 6.000 | 1.014 | 6.000 | 6.000 | 6.000 | 6.000 | 6.000 | 43.014 |
| A9 | 5.192 | 5.391 | 1.000 | 5.034 | 5.034 | 5.079 | 5.079 | 4.988 | 36.798 |

Şekil 3.5 ve 3.6’da, en başarılı olarak belirlenen aktivasyon fonksiyonu A2 alternatifini içeren Yapay Sinir Ağ modelinin farklı nöron sayıları için HKOK ve Belirtme Katsayısı (R^2)’nın değişimi verilmiştir. Bu şekiller değerlendirildiğinde, özellikle nöron sayısı değişimine göre HKOK ve Belirtme Katsayısında belirli bir eğilimde, artan ya da azalan bir değişim elde edilmemiştir. Bu bakımdan, nöron sayısının Yapay Sinir Ağ modellerinin tahmin başarısı üzerinde olumlu ya da olumsuz bir etkisinin olmadığı görülmektedir.




Şekil 3.5. Nöron sayılarına göre HKOK değişimi



Şekil 3.6. Nöron Sayılarına göre belirtme katsayısının (R^2) değişimi

En başarılı olarak belirlenen A2 aktivasyon fonksiyonu alternatifini ile 75 nörona sahip Yapay Sinir Ağ modeli kullanılarak, ağ eğitiminde kullanılmamış olan 142 adet ağacın boyu tahmin edilmiştir. Bu ağaçların arazide ölçülen boy değerleri ile tahmin edilen boyları arasında, % 95 güven düzeyinde bir fark olup olmadığı, İki Eş arasındaki Farkın Önemlilik Testi (Paired t test) ile test edilmiştir. Yapılan bu analize ilişkin t istatistiği; -1.588, serbestlik derecesi 141 ve önem düzeyi de; 0.115 olarak hesaplanmış olup, gözlem ve tahmin değerleri arasında önemli bir farkın olmadığına yönelik H_0 hipotezi kabul edilmiştir. Böylece, en başarılı Yapay Sinir Ağ modelinin çalışma alanındaki meşcerelerin boy tahminlerinde %95 güven düzeyinde kullanılabileceği sonucu varılmıştır. Şekil 3.7’de, en başarılı Yapay Sinir Ağ modeli ile 142 adet ağacın tahmin edilen boyların ölçülen boylara göre değişimi verilmiştir.



Şekil 3.7. En başarılı YSA modeli ile 142 adet ağacın tahmin edilen boyların ölçülen boylara göre değişimi

4. SONUÇ VE ÖNERİLER

Bu çalışmada, ağaçların boy tahminlerinin elde edilmesinde, bir Yapay Zeka tekniği olan Yapay Sinir Ağlarının (YSA) kullanım olanaklarının araştırılması amaçlanmıştır. Bu amaçla, farklı aktivasyon fonksiyonu ve nöron sayısı alternatiflerini içeren 500 farklı Yapay Sinir Ağ modelinin eğitimi gerçekleştirilmiş, çeşitli başarı ölçütlerine göre Yapay Sinir Ağ modelleri ve Schnute (1981)'un Doğrusal Olmayan Regresyon modeline ilişkin tahmin başarıları karşılaştırılmıştır. Çeşitli aktivasyon fonksiyonu ve nöron sayısı alternatifini içeren Yapay Sinir Ağ modellerinin karşılaştırılmasında, lojistik sigmoid (log-sig)'in giriş katmanı ile ara katmanı bağlantı noktasında olduğu ve hiperbolik tanjant sigmoid (tan-sig)'in de ara katman ile çıkış katmanı bağlantı noktasında olduğu (A2 aktivasyon fonksiyonu alternatifi) ve 75 nörona sahip YSA modelinin, en başarılı boy tahmin sonuçlarını verdiği belirlenmiştir. Bu en başarılı YSA modeli ile elde edilen tahminlerde, regresyon modeline göre seçeneğine göre r, OMH, max. OMH, HKOK, HKOK%, Bias, Bias%, R², AIC ve BIC değerlerinde sırasıyla, -%4.518, %12.296, %35.689, %22.929, %22.929, %51.703, %49.978, -%11.016 oranlarında iyileşmeler elde edilmiştir. Ayrıca, hata grafiklerinde (Şekil 3.1, 3.2, 3.3 ve 3.4) değerlendirildiğinde, en başarılı Yapay Sinir Ağ modeli ile Schnute (1981)'in Doğrusal Olmayan Regresyon modeline göre göre başarılı sonuçlar elde edildiği görülmektedir. Özellikle, çeşitli başarılı ölçütleri ile hata grafiklerinde elde edilen bu iyileşmeler, bu çalışmanın temel araştırma konusu olan Yapay Sinir Ağ modellerinin, ağaçların boy tahminlerinde kullanılabilirliği konusunda önemli bulgular sunmaktadır. Tüm bu ölçüt değerleri ve hata grafikleri değerlendirildiğinde, Yapay Sinir Ağ modellerinin ağaçların boy tahminlerinde başarıyla kullanılabileceği sonucuna varılabilir. Özellikle, en başarılı Yapay Sinir Ağ modelleri ile ağ modellerinin eğitiminde kullanılmamış 142 adet ağaca ilişkin elde edilen tahminler ile gözlem değerlerinin %95 güven düzeyi ile İki Eş Arasındaki Farkın Önemlilik testi ile farksız elde edilmesi de, Yapay Sinir Ağ modellerinin ağaçların boy tahminlerinde başarıyla kullanılabileceğine sonucunu desteklemektedir.

Bu çalışmayla benzer şekilde, Brandão (2007), Ranson *et al.* (2007), Silva *et al.* (2008), Diamantopoulou and Özçelik (2012), Özçelik *et al.* (2013) ve Vendruscolo *et al.* (2015), ağaçların boy tahminlerinin elde edilmesinde Yapay Sinir Ağ modelleri ile doğrusal olmayan regresyon modellerini karşılaştırmış, Yapay Sinir Ağ modelleri ile daha başarılı boy tahminleri elde etmiştir. Bu bakımdan, çalışmamızda Yapay Sinir Ağ modelleri ile ağaçların boy tahminlerinde elde edilen tahmin başarısındaki elde edilen iyileşmeler, diğer çalışmalardaki sonuçlarla benzer olup, böylece bu yüksek lisans çalışmasında elde edilen sonuçlar, Yapay Sinir Ağ modellerinin boy tahminlerindeki kullanılabilirliğini konusundaki genel sonuçları desteklemektedir.

Bu çalışmada, diğer bir araştırma konusu da, özellikle farklı aktivasyon fonksiyonu seçenekleri ile nöron sayısı alternatiflerinden ağaçların boy tahminlerinde en başarılı optimal ağ yapısının belirlenmesidir. Özellikle, aktivasyon fonksiyonu seçenekleri için elde edilen başarı ölçüt değerlerine ilişkin ortalama değerler değerlendirildiğinde (Çizel 3.3), lojistik sigmoid (log-sig)'in giriş katmanı ile ara katmanı bağlantı noktasında olduğu ve hiperbolik tanjant sigmoid (tan-sig)'in de ara katman ile çıkış katmanı bağlantı noktasında olduğu aktivasyon fonksiyonunu (A2) alternatifinin en başarılı tahmin sonuçları verdiği belirlenmiştir. Ayrıca, farklı Çizelge 3.4'teki değerler değerlendirildiğinde, aktivasyon fonksiyonu seçenekleri arasında başarı ölçütlerine ilişkin rölatif sıra değerleri bakımından belirli ölçüde farklar olduğu görülecektir. Diğer taraftan, Şekil 3.5 ve 3.6 incelendiğinde; 1 nöron dan 100 nöron a kadar farklı nöron sayılarına göre HKOK ve R^2 değerlerinde artan ya da azalan bir değişim elde edilmediği görülecektir. Bu bakımdan, aktivasyon fonksiyonu değişimine göre çeşitli başarı ölçütlerinde görülen iyileşmeler, nöron sayısının artışına göre elde edilememiştir. Dolayısıyla, özellikle fazla nöron sayılarını içeren Yapay Sinir Ağ modellerinin kullanımı yerine, uygun ve başarılı aktivasyon fonksiyonu secimi, başarılı ve tutarlı tahminlerin elde edilmesinde daha önemli olduğu sonucuna ulaşılabilir. Bu çalışmanın araştırma konusu olan aktivasyon fonksiyonunun ve nöron sayılarının Yapay Sinir Ağ modelleri ile elde edilecek tahminlerin başarısına etkisi olarak da, nöron sayısının artırılması yerine, giriş, gizli ve çıktı katmanları arasında geçişi sağlayan uygun aktivasyon fonksiyonunun seçiminin önemli olduğu sonucuna ulaşılmıştır. Nöron sayılarının

artırılması, Yapay Sinir Ağ modellerinin tahmin başarısını artırmadığı gibi, oldukça karmaşık ve uygulaması zor olan Yapay Sinir Ağ modellerinin elde edilmesine neden olabilmektedir.

Yapay Sinir Ağ modellerinin uygulanabilirliğini değerlendirirken, bu modellerin ağaçların çap-boy ilişkilerinin tahminlerindeki başarıları yanında, Yapay Sinir Ağ modellerinin uygulanabilirliğini kısıtlayan bazı özellikleri de dikkate almak gerekir. Genel olarak, modelleme çalışmalarında, denklem yapıları, parametre değerleri ile birlikte verilebilen regresyon modelleri tercih edilebilmektedir. Bununla birlikte, çeşitli sayıda katman ve nörondan oluşan Yapay Sinir Ağ modelleri, onlarca ve hatta yüzlerce ağırlık değerlerini içeren model yapılarına sahip olabilmektedir. Bu bakımdan, çok sayıda ağırlık değerine sahip olan derin öğrenme algoritmasının denklem yapısının verilmesi ve excel vb. uygulamalarının yapılması mümkün olmayacaktır. Bununla birlikte, Yapay Sinir Ağ model uygulamaları, ancak çeşitli bilgisayar yazılımları ve programları desteği ile mümkün olup, bilgisayar çağında yaşadığımız göz önüne alındığında, bunun da çok zor olmayacağı açık olarak ortaya çıkmaktadır. Günümüzde uygulamaları ve kullanımı öne çıkan çeşitli yazılımların, başta orman planlamacıları olmak üzere bir çok farklı uygulayıcının Yapay Sinir Ağ modeli ve çeşitli yapay zeka modellerini kullanımına imkan sağlayabilmektedir. Özellikle, çeşitli araştırmacılar ya da uygulayıcılar tarafından eğitimleri gerçekleştirilen Yapay Sinir Ağ modellerinin ücretsiz ve herkesin kullanımına açık yapay zeka platformunda hazırlanmış uygulamalarının çeşitli paydaşlarla ve diğer kullanıcılarla paylaşılması, bu modellerin daha kolay ulaşılabilir ve uygulanabilir olmasını sağlayabilecektir. Diğer taraftan, birçok özelliği ile klasik istatistik yöntemi olan regresyon modellerine göre avantajları ve başarıları birçok çalışmada ortaya konmuş başta Yapay Sinir Ağ modelleri olmak üzere çeşitli yapay zeka modellerinin gelişiminin ve farklı alanlarda uygulanmasının önündeki en önemli engel, belirli bir veri seti için eğitimi gerçekleştirilen Yapay Sinir Ağ modellerinin farklı bir veri setlerinde uygulanmasının, ancak belirli bir platformda eğitilen yapay zeka modelinin diğer uygulayıcılarla ve araştırmacılarla paylaşılması ile mümkün olmasıdır.

Son yıllardaki artım ve büyüme modellemesi konusundaki literatür incelendiğinde; çeşitli tek ağaç ve meşcere özelliklerinin modellemesinde sahip oldukları çeşitli avantajları ile Yapay Sinir Ağ modelleri, belirli ölçüde klasik istatistik yöntemlerinin yerine geçmeye ve sıklıkla kullanılmaya başlamışlardır. Böylece, çeşitli tek ağaç ve meşcee özelliğini modelleyen çok sayıda Yapay Sinir Ağ modeli geliştirilmiştir. Bunun birlikte, optimal Yapay Sinir Ağ modelinin belirlenmesi üzerine ise çalışmalar sınırlı sayıdadır. Yapay Sinir Ağ modellemesi konusunda yapılan çalışmalarda, araştırmacı tarafından belirlenen belirli bir nöron sayısı ve aktivasyon fonksiyonuna sahip Yapay Sinir Ağ modeli ile klasik regresyon modelleri karşılaştırılmıştır. Bu çalışmalarda, Yapay Sinir Ağ modelinin sahip olduğu oldukça ileri düzeydeki doğrusal olmayan (nonlinear) model yapısı ve çeşitli istatistiksel varsayımların sağlanmasını gerektirmeyen özelliği ile çeşitli tek ağaç ve meşcere özelliklerinin tahmininde oldukça başarılı sonuçlar elde edilmiştir. Ancak, çeşitli aktivasyon fonksiyonları ile nöron sayılarını içeren farklı Yapay Sinir Ağ model yapılarının karşılaştırılması ve ideal Yapay Sinir Ağ modelinin belirlenmesi, artım ve büyüme modellemesinde önemli bir ihtiyaç olarak karşımıza çıkmaktadır. Bu çalışmada da olduğu gibi, farklı Yapay Sinir Ağ modellerinin karşılaştırılması ve başarılı YSA model yapılarının belirlenmesi gerekmektedir. Bu ideal Yapay Sinir Ağ modeline karar vermede çeşitli başarı ölçütlerinin değerlendirilmesi yanında, Yapay Sinir Ağ modellerinin çeşitli artım ve büyüme kanuniyetlerini de sağlayıp sağlamadığının değerlendirilmesi de gerekmektedir.

Yapay Sinir Ağ modelleri, çeşitli tek ağaç ve meşcere gelişimini, temelde genel olarak merkezi sinir sisteminin çalışma prensiplerini taklit ederek geliştirilmiş oldukça karmaşık doğrusal olmayan model yapısını esas alarak modellemekte, böylece bu karmaşık modeller ile ağaçların ve meşcerelerin çeşitli özelliklerini tahmin etmede de oldukça başarılı sonuçlar verebilmektedir. Başta orman amenajman planları olmak üzere bir çok ormancılık uygulamasında, pratik olmaları nedeniyle çok tercih edilen regresyon denklemlerine göre özellikle karmaşık model yapıları ile tahminlere imkan sağlayan Yapay Sinir Ağ modelleri, ormancılığımız için daha doğru ve tutarlı tahminlerinin elde edilmesine imkan sağlayabileceklerdir. Ülkemiz ormancılığında, Ekosistem Tabanlı Çok Amaçlı Planlamanın daha da önem kazanması ile artım ve büyüme modellemesi ile

başarılı ve etkin tahminlere olan gereksinim önem kazanacaktır. Başta asli ağaç türlerimiz olmak üzere farklı ağaç türlerimizin değişik yetişme ortamları ve meşcere kuruluşları için Yapay Sinir Ağ modelleri olmak üzere çeşitli yeni ve etkin modelleme tekniklerinin kullanımı ve başarılı tahmin sistemlerin geliştirilmesi öncelik arz etmektedir. Bu bakımdan, ülkemiz ormancılığında, bu yeni ve başarılı tahmin sistemlerinin geliştirilmesine ilişkin çalışmalar ağırlık verilmeli, Dünya’da tek ağaç ve meşcere özelliklerinin tahmininde yeni bir teknik olarak öne çıkan ve birçok uygulaması olan Yapay Sinir Ağ modellerinin kullanımı sağlanmalıdır.



KAYNAKLAR

- Abbasi, B., Rabelo, L., Hosseinkouchack, M. 2008. Estimating parameters of the three-parameter Weibull distribution using a neural network. *European Journal of Industrial Engineering*, 2, 428-445.
- Adame, P., del Río, M. and Cañellas, I., 2008. A mixed nonlinear height–diameter model for pyrenean oak (*Quercus pyrenaica* Willd.). *Forest Ecology and Management*, 256, 88–98.
- Anonim. 2019. Web Sitesi. <http://okuyorumben.com/sinir-hucresinin-yapisi-ve-cesitleri.html>, Erişim Tarihi: 01.03.2019
- Ashraf, M. I., Zhao, Z., Bourque, A., MacLean, D.A. and Meng, F. 2013. Integrating biophysical controls in forest growth and yield predictions generated with artificial intelligence technology. *Canadian Journal of Forest Research*, 43, 1162–1171.
- Avery, T. E. and Burkhart, H. E. 1983. *Forest Measurements*. McGraw-Hill Series in Forest Resources, McGraw-Hill Book Company, New York, 331 p.
- Başkent, E. Z. 1999. Ekosistem Amenajmanı ve Biyolojik Çeşitlilik. *Turkish Journal of Agriculture and Forestry*, 23, Ek Sayı, 353-363.
- Bolat, F. 2015. Predictions for Oriental Beech Tree Heights Based on Artificial Neural Network in Kestel Forests. The 10th International Beech Symposium, 1-6 September, 2015, Kastamonu, Turkey.
- Bolat, İ. and Ercanlı, İ. 2016. Using Artificial Neural Network in Describing Diameter Distribution in an Even-Aged Forest. *International Forestry Symposium*, 7-10 December 2016, Kastamonu-Turkey
- Brandão, F. G., 2007. Estimativa da altura total de *Eucalyptus* sp. utilizando lógica fuzzy e neuro fuzzy. Master's Thesis. Universidade Federal de Lavras.
- Budhathoki, C. B., Lynch, T. B. and Guldin, J. M. 2008. A mixed-effects model for dbh–height relationship of shortleaf pine (*Pinus echinata* Mill.). *Southern Journal of Applied Forestry*, 32, 5–11.
- Cai, S., Kang, X. and Zhang, L. 2012. Simulation of Trunk diameter distribution for three broadleaved trees based on artificial neural networks. *International Journal of Advancements in Computing Technology*, 4, 520-527.
- Calama, R., Montero, G. 2004. Interregional nonlinear height– diameter model with random coefficients for stone pine in Spain. *Canadian Journal of Forest Research*, 34, 150–163.
- Castedo-Dorado, F., Anta, M. B., Parresol, B. R. and González, J. G. Á. 2005. A stochastic height-diameter model for maritime pine ecoregions in Galicia (northwestern Spain). *Annals of Forest Science*, 62, 455-465.
- Castedo-Dorado, F., Diéguez-Aranda, U., Barrio, M., Sánchez, M. and von Gadow, K. 2006. A generalized height-diameter model including random components for radiata pine plantations in northeastern Spain. *Forest Ecology and Management*, 229, 202 – 213.
- Castro, R., Soares, C., Leite, H., Lopes de Souza, A., Nogueira, G. and Martins, F. 2013. Individual growth model for *Eucalyptus* stands in Brazil using Artificial Neural Network. *International Scholarly Research Notices Forestry*, 1, 1-12.
- Clutter, J. L., Fortson, J. C., Pienaar, L. V., Brister, G. H. and Bailey, R. L. 1983. *Timber management: a quantitative approach*. John Wiley & Sons, Inc.

- Corne, S. A., Carver, S. J., Kunin, W. E., Lennon, J. J. and Van Hees, W. W. S. 2004. Predicting forest attributes in southeast Alaska using artificial neural networks, *Forest Science*, 50, 259–276.
- Curtis, R. O., 1967. Height-diameter and height-diameter-age equations for second-growth Douglas-fir. *Forest Sci* 13, 365-375.
- Diamantopoulou, M. J. 2005a. Artificial neural networks as an alternative tool in pine bark volume estimation. *Computers and Electronics in Agriculture*, 48, 235–244.
- Diamantopoulou, M. J., 2005b, Predicting fir trees stem diameters using Artificial Neural Network models. *Southern Forests: a journal of Forestry Science*, 205, 39-44.
- Diamantopoulou, M. J. 2006. Tree-Bole Volume Estimation on Standing Pine Trees Using Cascade Correlation Artificial Neural Network Models. *Agricultural Engineering International: the CIGR ejournal*. Manuscript IT 06 002. Vol. VIII.
- Diamantopoulou, M. J. and Milios, E. 2010. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models, *Biosystems Engineering*, 105, 306–315.
- 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. *Biosystem Engineering*, 133, 33-45.
- Diamantopoulou, M. J. and Özçelik, R. 2012. Evaluation of different modeling approaches for total tree-height estimation in Mediterranean Region of Turkey. *Forest Systems*, 21, 3, 383-397.
- Doğanay, B. 2007. Uzunlamasına çalışmaların analizinde karma etki modelleri, Ankara Üniversitesi, Sağlık bilimleri Enstitüsü Yüksek Lisans Tezi, 94 s.
- Eraslan, İ. 1982. Orman Amenajmanı. İstanbul Üniversitesi Orman Fakültesi, Yayın No:318.
- Ercanlı, İ., Kahriman, A. and Bolat, F. 2015. Applications of Artificial Neural Network for Predicting the Relationships Between Height And Age for Oriental Beech. The 10th International Beech Symposium, 1-6 September, 2015, Kastamonu, Turkey.
- Ercanlı, İ. and Bolat. 2017. Diameter distribution Modeling based on Artificial Neural Networks for Kunduz Forests. International Symposium on New Horizons in Forestry-ISFOR 2017, Isparta University, Faculty of Forestry, 18-20 October, Isparta, Turkey.
- Ercanlı, İ., Günlü, A., Şenyurt, M., Bolat, F., Kahriman, A. 2016a. Artificial neural network for predicting stand carbon stock from remote sensing data for even-aged scots pine (*pinus sylvestris* l.) Stands in the taşköprü-çiftlik forests. 1st International Symposium of Forest Engineering and Technologies (FETEC 2016), Bursa Technical University, Faculty of Forestry, 2-4 June 2016, Bursa-TURKEY.
- Ercanlı, İ., Kahriman, A., Yavuz, H. 2016b. Predicting Oriental Spruce and Scots Pine Tree Diameter Increments Based on Artificial Neural Network Located in Mixed Oriental Spruce-Scots Pine Stands at Trabzon and Giresun Forest District. International Forestry Symposium, 7-10 December 2016, Kastamonu-Turkey

- Ercanlı, İ., Günlü, A., Şenyurt, M., Keleş, S. 2018a. Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey. *Forest Ecosystems*, 5-29.
- Ercanlı, İ., Kurt, A. K., Şenyurt, M., Günlü, A. and Keleş, S., 2018b, Tarsus Yöresi Anadolu Karaçamı Ağaçlarında Hacim Tahminlerinin Yapay Sinir Ağları ile Elde Edilmesi, *Anadolu Orman Araştırmaları Dergisi*, Cilt 4, Sayı 1, 25-37.
- Ercanlı, İ., Bolat, F. and Yavuz, H., 2018c. Ormanların Çap Dağılımlarının Modellenmesinde Derin Öğrenme Algoritmalarının Kullanımı: Trabzon ve Giresun Ormanları Doğu Ladini-Sarıçam Karışık Meşcereleri Örneği. *Anadolu Orman Araştırmaları Dergisi*, Cilt 4, Sayı 2, 122-132.
- Fang, Z. and Bailey, R. L. 1998. Height– diameter models for tropical forests on Hainan Island in southern China. *Forest Ecology and Management*, 110, 315-327.
- Fekedulegn, D., Mac Siurtain, M.P. and Colbert, J.J., 1999. Parameter estimation of nonlinear growth models in forestry. *Silva Fenn* 33, 327-336.
- Ferguson, I. S. and Leech, J. W. 1978. Generalized least squares estimation of yield functions. *Forest Science*, 24, 27–42.
- Freeman, J. and Skapura, D. 1991. *Neural networks-algorithms, applications, and programming techniques*. Addison-Wesley, Boston, 550 p.
- Fulton, M.R., 1999. Patterns in height-diameter relationships for selected tree species and sites in eastern Texas. *Canadian Journal of Forest Research*, 29, 1445-1448.
- Gadow K., Real, P. and Álvarez-González, J. G. 2001. *Modelización del Crecimiento y la Evolución de los Bosques*. IUFRO World Series, Vol. 12, Vienna.
- Guan, B. T. and Gertner, G. 1991. Modeling red pine tree survival with an artificial neural network, *Forest Science* 37, 5, 1429-1440.
- Günlü, A. and Ercanlı, İ. 2017. Evaluating some artificial neural networks and multiple linear regression model for predicting carbon of pure oriental beech stand in Göldağ forests. *International Symposium on New Horizons in Forestry-ISFOR 2017*, Isparta University, Faculty of Forestry, 18-20 October, Isparta, Turkey.
- 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.
- Hasenauer, H. and Kinderman, G. 2002. Methods for assessing regeneration establishment and height growth in uneven-aged mixed species stands, *Forestry*, 75, 4, 385–394.
- Haykin, S. 1994. *Neural Networks: A Comprehensive Foundation*. Macmillan, New York, p. 696
- Huang, S., Titus, S. J. and Wiens, D. P. 1992. Comparison of nonlinear height diameter functions for major Alberta tree species. *Canadian Journal of Forest Research*, 22, 1297–1304.
- Huang, S., Price, D. and Titus, S. J. 2000. Development of ecoregion-based height–diameter models for white spruce in boreal forests. *Forest Ecology and Management*, 129, 125–141.
- İyit, N., Genç, A. ve Arslan, F. 2006. Analysis of repeated measures for continuous response data using General Linear Model and Mixed Models, *Proceedings of the international conference on modeling and simulation*, Konya, TURKEY, 937-942.

- İyit, N. 2008. İlişkili Veri Analizinde Lineer Karma Modellerin Yapılandırılması, Selçuk Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, Konya, 162 s
- Kapucu, F. 1996. Orman Amenajmanı. K. T. Ü. Basımevi, Trabzon
- Kohonen, T. 1987. State of the Art in Neural Computing. IEEE First International Conference on Neural Networks, San Diego, California, June 1987, Vol. 1, 77-90
- Krumland, B. E. and Wensel, L. C. 1978. A generalized height– diameter equation for coastal California species. *Western Journal of Applied Forestry*, 3, 113–115.
- Larsen, D. R. and Hann, D. W. 1987. Height–diameter equations for seventeen tree species in southwest Oregon. Research paper 49. Oregon State University, Forest Research Laboratory, Corvallis, OR.
- Leduc, D. J., Matney, T. G., Belli, K. L. and Baldwin, V. C. 2001. Predicting Diameter Distributions of Longleaf Pine Plantations: A Comparison between Artificial Neural Networks and other accepted methodologies, Southern Research Station Technical Report RS-25, 1-17.
- Lei, Y. and Parresol, B. R. 2001. Remarks on height-diameter modeling (Res Note SRS-10), USDA For Service, Southern Research Station, Asheville, NC.
- Leite, H. G., Marques da Silva, M. L., 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 and Research*, 130, 263–269.
- López-Sánchez, C. A., Varela, J. G., Dorado, F. C., Alboreca, A. R., Soalleiro, R.R., Alvarez Gonzalez, J. G. and Rodriguez, F. S. 2003. A height–diameter model for *Pinus radiata* D.Don in Galicia (Northwest Spain). *Annals of Forest Science*, 60, 237–245.
- Lynch, T. B, Holley A. G. and Stevenson, D. J. 2005. A random-parameter height-dbh model for cherrybark oak. *Southern Journal of Applied Forestry*, 29, 22–26.
- Maltarollo V. G., Honorio K. M. and da Silva A. B. F. 2013. Applications of artificial neural networks in chemical problems. *Artificial Neural Networks-Architectures and Applications* ed. Suzuki K., editor. (Rijeka: InTech;) 203–223. 10.5772/51275
- Martin, F. C. and Flewelling, J. W. 1998. Evaluation of tree height prediction models for stand inventory. *Western Journal of Applied Forestry*, 13, 109–119.
- MATLAB and Statistics Toolbox Release. 2015. The MathWorks, Inc., Natick, Massachusetts, United States.
- Mehtätalo, L. 2004. A longitudinal height–diameter model for Norway spruce in Finland. *Canadian Journal of Forest Research*, 34,131–140.
- Moore, J.A., Zhang, L. and Stuck, D. 1996. Height-diameter equations for ten tree species in the Inland Northwest. *Western Journal of Applied Forestry*, 11, 132-137.
- Nasr, G. E., Badr, E. A., and Joun, C. 2003. Backpropagation neural networks for modeling gasoline consumption. *Energy Conversion and Management*, 44, 6, 893-905.
- Özçelik, R., Diamantopoulou, M.J., Wiant, H. R. 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, 73-81.

- Özçelik, R., Diamantopoulou, M.J., Wiant, H. V. and Brooks, J. R. 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. *Journal of Biogeosciences and Forestry*, 7, 132-139.
- Özçelik, R. ve Çevlik, M. 2017. Batı Akdeniz yöresi doğal sedir meşcereleri için hacim denklemleri. *Turkish Journal of Forestry*, 18, 1, 37-48.
- Özdemir, G. 2018. Karabük yöresi kayın-göknar karışık meşcerelerinde gövde çaplarının yapay sinir ağları ile tahmin edilmesi, Yüksek Lisans Tezi, Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalı, 112 s.
- Öztemel, E. 2006. Yapay Sinir Ağları (2. Baskı). İstanbul: Papatya Yayıncılık, 232 s.
- Öztürk, K. ve Şahin, M. E. 2018. Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış, *Takvim-i Vekayi*, 6, 2, 25-36
- Parresol, B. R. 1992. Baldcypress height–diameter equations and their prediction confidence interval. *Canadian Journal of Forest Research*, 22, 1429– 1434.
- Paruelo, J. M. and Tomasel, F. 1997. Prediction of functional characteristics of ecosystems: a comparison of artificial neural networks and regression models. *Ecological Modelling*, 98, 173-186.
- Paulo, J. A., Tomé, J., Tomé, M. 2011. Nonlinear fixed and random generalized height–diameter models for Portuguese cork oak stands. *Annals of Forest Science*, 68, 295-309
- Peng, C. 1999. Nonlinear height- diameter models for nine boreal forest tree species in Ontario (OFRI-Rep 155), Ministry of Natural Resources Institutes.
- Peng, C., Zhang, L. and Liu, J. 2001. Developing and validating nonlinear height–diameter models for major tree species of Ontario’s boreal forests. *Northern Journal of Applied Forestry*, 18, 87–94.
- 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.
- Ranson, K.J., Masek, J., Fu, A. and Wang, D., 2007. Predicting tree height and biomass from glas data., 10th International Symposium on Physical Measurements and Signatures in Remote Sensing – ISPMSRS’07.
- Robinson, A. P. and Wykoff, W. R. 2004. Imputing missing height measures using a mixed-effects modeling strategy. *Canadian Journal of Forest Research*, 34, 2492–2500.
- SAS Institute Inc., 2004. SAS/STAT 9.1 User's Guide: statistics, Version 9.1, SAS Institute Inc., Cary, NC., 816 p.
- Saunders, M. R., Wagner, R. G. 2008. Long-term spatial and structural dynamics in Acadian mixedwood stands managed under various silvicultural systems. *Canadian Journal of Forest Research*, 38, 498–517.

- Schmoldt, D. L., Pei, L. and Abbott, L. A. 1997. Machine vision using artificial neural networks with local 3D neighborhoods. *Computers and Electronics in Agriculture*, 16, 255–271.
- Schnute, J., 1981. A versatile growth model with statistically stable parameters. *Canadian Journal of Fisheries and Aquatic*, 38, 1128-1140.
- Schröder, J., 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, 18-23.
- Sharma, M. and Zhang, S. Y. 2004. Height–diameter models using stand characteristics for *Pinus banksiana* and *Picea mariana*. *Scandinavian Journal of Forest Research*, 19, 442–451.
- Sharma, M., Parton, J. 2007. Height-diameter equations for boreal tree species in Ontario using a mixed-effects modeling approach. *Forest Ecology and Management*, 249, 187–198.
- Silva, R.M.A., Brandão, F.G., Baleeiro, G.B., Valentim, F.L., Mendonça, A.R. and Pires, D.M. 2008. Fuzzy and neuro-fuzzy estimates of the total height of eucalyptus trees., *ACM Symposium on Applied Computing*, New York, USA. ACM, New York, NY, USA, pp. 1772–1776.
- Soares, P. and Tomé, M. 2002. Height–diameter equation for first rotation eucalypt plantations in Portugal. *Forest Ecology and Management*, 166, 99–109.
- Şeker, A. 2017. Derin öğrenme yöntemleri ve uygulamaları hakkında bir İnceleme, Doktora Semineri, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 49 s.
- Şenyurt, M., Ercanlı, İ., Yavuz, H. and Kahriman, A. 2015. Predicting Stand Yield Parameters Based On Artificial Neural Network for Oriental Beech in Kestel Forests, Bursa. *The 10th International Beech Symposium*, 1-6 September, 2015, Kastamonu, Turkey.
- van Laar, A. and Akça, A. 2007. Forest mensuration: in *Managing Forest Ecosystems*, Dordrecht, The Netherlands, Springer. 383 p.
- Temesgen, H. and Gadow, K.V. 2004. Generalized height–diameter models—an application for major tree species in complex stands of interior British Columbia. *European Journal of Forest Research*, 123, 45-51.
- 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, 253 – 262.
- Vendruscolo, D. G. S., Drescher, R., Souza, H. S., Moura, J. P. V. M., Mamoré, F. M. D., Siqueira, T. A. S. 2015. Estimation of eucalyptus height by means of nonlinear regression and artificial neural networks. *Revista Brasileira de Biometria*, 33, 4, 556-569
- Wang, C. H., Hann, D.W. 1988. Height-diameter equations for sixteen tree species in the central western Willamette Valley of Oregon. In. Oregon State University, Forest Research Laboratory.
- Wykoff, W. R., Crookston, N. L. and Stage, A. R. 1982. User’s guide to the stand prognosis model. USDA For. Serv. Gen. Tech. Rep. INT-133.

- Ye, S. 2005. Covariance structure selection in linear mixed models for longitudinal data, M. Sc. Thesis, department of Bioinformatics and Biostatistics, University of Louisville, Kentucky, USA.
- Zhang, L., 1997. Cross-validation of non-linear growth functions for modelling tree height–diameter relationships. *Annals of Botany*, 79, 251-257.
- Zhang, Q. B., Hebda, R. I., Zhang, Q. J. and Alfaro, R. I. 2000. Tree-Ring Growth Responses to Climatic Variables Using Artificial Neural Networks, *Forest Science*, 46, 2, 229-239.



ÖZGEÇMİŞ

Adı Soyadı : Doğa EYÜBOĞLU
Doğum Yeri : Trabzon
Doğum Tarihi : 02.11.1989
Medeni Hali : Evli
Yabancı Dili : İngilizce
Adres : Emek Mah. 29.Sok. 21/1 ÇANKAYA/ANKARA
Tel : 0 545 795 1851
E-posta : eyubogludogaa@gmail.com
Eğitim Durumu
Lise : Yunus Emre Lisesi / Trabzon (2003-2006)
Lisans : Karadeniz Teknik Üniversitesi Orman Fakültesi (2008-2014)
Yüksek Lisans : Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü
Orman Mühendisliği Anabilim Dalı (2016-)
Çalıştığı Kurum / Kurumlar ve Yıl
1. Oyka Kağıt Ambalaj Sanayi A.Ş., Zonguldak (2016 – 2018)
2. Oyak Denizcilik ve Liman İşletmeleri A.Ş., Ankara (2018-)