DÜZCE ÜNİVERSİTESİ

Düzce Üniversitesi Orman Fakültesi Ormancılık Dergisi
e-ISSN: 2148-7855

TÜR Araştırma Makalesi
YAYIM 30 Aralık 2025
DOI 10.58816/duzceod.1801720

Hava Tabanlı LiDAR ile Tepe Altı Yüksekliğinin Tahmininde Makine Öğrenmesi Tabanlı Bir Yaklaşım

Tufan Demirel*[1]

[1] İstanbul Üniversitesi–Cerrahpaşa, Orman Fakültesi, Orman Mühendisliği Bölümü, İstanbul, Türkiye.

Orman ekosistemleri, karbon tutma, biyolojik çeşitlilik ve diğer ekosistem hizmetleri açısından kritik öneme sahiptir. Bu bağlamda, orman yapısal parametrelerinin doğru ve güncel ölçülmesi, sürdürülebilir ormancılık ve ekosistem yönetimi için gereklidir. Tepe altı yüksekliği (TAY), ormanların dikey yapısını tanımlamada temel bir parametre olup, biyokütle ve tomruk kalitesi modelleri ile orman yangını simülasyon modellerinde önemli bir rol oynar. Ancak klasik arazi ölçümleri zaman alıcı ve erişimi güç alanlarda uygulanabilirlik açısından sınırlıdır. Bu çalışmada, saf sahil çamı (*Pinus pinaster*) meşcerelerinde Hava tabanlı LiDAR verileri ve makine öğrenmesi algoritmalarından XGBoost kullanılarak TAY tahmin modeli geliştirilmiştir. 32 örnek alanda arazi ölçümleri gerçekleştirilmiş ve örnek alanlara ait TAY değerleri hesaplanmıştır. Hava tabanlı LiDAR verilerinden 56 yükseklik ve nokta bulutu metrikleri türetilmiş, yüksek korelasyonlu değişkenler elenerek 23 metrik modelde kullanılmıştır. XGBoost modeli için hiperparametre optimizasyonu Grid Search yöntemiyle yapılmış ve en iyi performans nrounds=50, max_depth=3 ve eta=0,3 parametreleri ile elde edilmiştir. Modelin genelleme performansı LOOCV ile değerlendirildiğinde yüksek doğruluk sağlanmış (R^2=0,80; RMSE=0,28 m; MAE=0,21 m) ve tahminler gözlenen TAY değerleri ile güçlü uyum göstermiştir. Değişken önem analizi, elev_skewness, elev_max ve elev_AIH_30th metriklerinin TAY üzerinde önemli bir etkiye sahip olduğunu ortaya koymuştur. Sonuçlar, XGBoost algoritmasının LiDAR verilerine dayalı TAY tahmininde güvenilir ve etkin bir yöntem olduğunu göstermektedir.

ANAHTAR KELİMELER
XGBoost, sahil çamı, uzaktan algılama

AÇIK ERİŞİM

*SORUMLU YAZAR
Tufan DEMİREL
tufan.demirel@iuc.edu.tr

GELİŞ 11 Ekim 2025
KABUL 5 Aralık 2025

ATIF

Demirel, T. (2025). Hava tabanlı LiDAR ile tepe altı yüksekliğinin tahmininde makine öğrenmesi tabanlı bir yaklaşım. *Düzce Üniversitesi Orman Fakültesi Ormancılık Dergisi, 21*(2), 304–316. https://doi.org/10.58816/duzceod.1801720

TELİF HAKKI

© 2025 Demirel. Bu, Creative Commons Atıf-GayriTicari 4.0 (CC BY-NC) koşulları altında dağıtılan açık erişimli bir makaledir. Bu lisans, orijinal yazar(lar)a ve kaynağa uygun şekilde atıfta bulunulması, lisansa bir bağlantı sağlanması ve yapılan değişikliklerin belirtilmesi koşuluyla, ticari olmayan amaçlarla herhangi bir ortam veya formatta kullanıma, paylaşmaya, uyarlamaya, dağıtmaya ve çoğaltmaya izin verir.

A Machine Learning Approach for Predicting Canopy Base Height from Airborne LiDAR

Forest ecosystems are critically important in terms of carbon sequestration, biodiversity, and other ecosystem services. In this context, accurate and up-to-date measurement of forest structural parameters is essential for sustainable forestry and ecosystem management. Canopy Base Height (CBH) is a key parameter for characterizing the vertical structure of forests and plays an important role in biomass and log quality models as well as forest fire simulation models. However, conventional field measurements are time-consuming and limited in applicability in areas with difficult access. In this study, a CBH prediction model was developed for pure maritime pine (*Pinus pinaster*) stands using airborne LiDAR data and the XGBoost machine learning algorithm. Field measurements were conducted in 32 sample plots, and CBH values were calculated for these plots. 56 elevation and point cloud metrics were obtained from aerial LiDAR data, and highly correlated variables were extracted. The remaining 23 metrics were used for modeling. Hyperparameter optimization for the XGBoost model was performed using Grid Search, with the best performance achieved using nrounds=50, max_depth=3, and eta=0.3. The model's generalization performance was evaluated via LOOCV, demonstrating high accuracy (R^2=0.80; RMSE=0.28 m; MAE=0.21 m), and predictions showed strong compatibility with observed CBH values. Variable importance analysis revealed that elev_skewness, elev_max, and elev_AIH_30th metrics had significant effects on CBH. The results indicate that the XGBoost algorithm is a reliable and effective method for CBH prediction based on LiDAR data.

KEYWORDS
XGBoost, maritime pine, remote sensing

1. GİRİŞ

Orman ekosistemleri, yalnızca hammadde sağlamakla kalmayıp karbon tutma, biyolojik çeşitliliğin korunması, besin döngüsü ile su ve enerji dengesinin sürdürülmesi gibi çok yönlü ekosistem hizmetleriyle insan yaşamına doğrudan katkı sağlar (Lee vd., 2010). Dolayısıyla bu doğal kaynakların sürdürülebilir yönetimi, toplum refahı ve ekolojik denge açısından büyük önem taşımaktadır (FAO, 2023). Orman ekosistemlerini karakterize eden yapısal parametrelerin doğru ve güncel biçimde ölçülmesi, ekosistem hizmetlerini anlamanın yanı sıra ormancılık uygulamalarını iyileştirmek ve sürdürülebilir orman yönetimi stratejileri geliştirmek açısından kritik bir gerekliliktir (García vd., 2018; Kaushal ve Baishya, 2021). Ağaç sayısı, göğüs çapı, ağaç boyu, tepe altı yüksekliği, taç genişliği ve tepe hacmi gibi yapısal parametreler ormancılıkta planlama, izleme ve yeni yönetim stratejilerinin geliştirilmesinde yaygın olarak kullanılmaktadır (Dean vd., 2009).

Tepe altı yüksekliği (TAY), yer yüzeyinden canlı taç altına kadar olan mesafeyi ifade eder (Küçük vd., 2009) ve ormanların dikey yapısını tanımlamada temel parametrelerden biridir (Hall vd., 2005; Næsset ve Økland, 2002). Örnek alan ölçeğinde TAY, tomruk kalitesinin önemli bir göstergesi olarak kabul edilirken; aynı zamanda orman büyümesinin değerlendirilmesi ve biyokütle modellerinin oluşturulmasında da temel bir değişken olarak kullanılmaktadır (Maltamo vd., 2018). Ayrıca, minimum TAY değeri, orman yangını simülasyon modellerinde kritik bir girdi parametresi olarak değerlendirilmektedir (Maguya vd., 2015; Küçük vd., 2021). TAY genellikle geleneksel arazi ölçümleriyle belirlenmektedir. Ancak bu ölçümler zaman alıcı, maliyetli ve yoğun emek gerektiren çalışmalardır (Erdody ve Moskal, 2010; Kelly vd., 2017). Ayrıca, klasik yöntemler güvenilir veri üretmekle birlikte, yoğun bitki örtüsüne sahip, dik topoğrafyalı veya erişimi güç alanlarda uygulanabilirlik açısından sınırlılıklar taşımaktadır (Luo vd., 2018).

Bu bağlamda, uzaktan algılama teknolojileri özellikle LiDAR (Light Detection and Ranging) orman yapısının üç boyutlu özelliklerini yüksek doğrulukla ve geniş alanlarda belirlemede önemli avantajlar sunmaktadır (Hermosilla vd., 2014). LiDAR sensörleri, orman örtüsüne nüfuz ederek dikey yapı bilgilerini, dolayısıyla TAY ölçümlerini yüksek doğrulukla elde edebilmektedir (Andersen vd., 2005; Zhao vd., 2011; Hermosilla vd., 2014; Maguya vd., 2015; Guo vd., 2021; Coskuner vd., 2023; Viedma vd., 2024; Bahadır vd., 2025).

Literatürdeki LiDAR temelli TAY tahmin yöntemleri genellikle regresyon analizine veya doğrudan ölçüm-tahmin yaklaşımlarına dayanmaktadır (Luo vd., 2018). Doğrudan ölçüm yaklaşımları, LiDAR nokta bulutundan bireysel ağaçların morfolojik özelliklerini doğrudan belirlemeyi hedeflemektedir. Ancak bu tür yöntemlerin uygulanmasında çeşitli zorluklar bulunmaktadır. Özellikle, yoğun ve çok katlı orman örtüsünde taçların birbirine girmesi, LiDAR nokta bulutunda tepe ve taç altı bölgelerinin doğru biçimde ayrıştırılmasını güçleştirmektedir (Luo vd., 2018). Bu durum, özellikle düşük yoğunluklu LiDAR verilerinde, ağaçların taç altı noktalarının yeterince temsil edilmemesine ve dolayısıyla TAY tahmininde hatalara yol açabilmektedir. Bunun yanında, tarama geometrisi, lazer darbe yoğunluğu, nokta bulutunun dikey çözünürlüğü ve orman formasyon tipi gibi faktörler doğrudan ölçüm yaklaşımlarının doğruluğunu önemli ölçüde etkilemektedir (Vauhkonen, 2010).

Regresyon tabanlı yaklaşımlar, saha ölçümleriyle LiDAR verilerinden türetilen metrikler arasındaki istatistiksel ilişkileri kullanarak tahmin modelleri geliştirmeye yöneliktir. Bu metrikler bağımsız değişken olarak kullanıldığında, TAY tahmininde yüksek doğruluk elde edilebilmektedir. Andersen vd. (2005) envanter verileri kullanılarak çeşitli LiDAR metrikleri ile örnek alan ölçeğinde tahmin edilen parametreler arasındaki ilişkileri belirlemek amacıyla regresyon analizleri uygulanmıştır. LiDAR verileri kullanılarak TAY regresyon modeli ile tahmin edilmiş ve modelin performansı R^2=0,77 ve RMSE = 3,9 m olarak rapor edilmiştir. Erdody ve Moskal (2010) tarafından yapılan bir çalışmada, TAY tahmini için LiDAR ve yüksek çözünürlüklü hava fotoğraflarının birlikte kullanıldığı veri füzyonu

© 2025 Demirel.

yaklaşımı test edilmiştir. Araştırma, LiDAR verisinin tek başına TAY tahmininde görüntü verisine göre görece daha düşük doğruluk sağladığını (R^2 = 0,77; RMSE = 1,63 m) ortaya koymuştur. Her iki verinin birleştirilmesi ise model performansında yalnızca sınırlı bir iyileşme sağlamıştır (R^2 = 0,84; RMSE = 1,44 m). Hermosilla vd. (2014) tarafından yapılan bir başka araştırmada, ABD Oregon'daki Douglas göknarı ormanlarında tam dalga formlu LiDAR metrikleri ile geliştirilen regresyon modelinin doğrulama sonuçları R^2 = 0,78, RMSE = 3,34 m olarak belirlenmiştir. Kelly vd. (2017) ise Kaliforniya'daki karışık çam ormanlarında parsel düzeyinde CBH tahmini için regresyon analizini uygulamış ve R^2 = 0,51 ile RMSE = 1,62 m değerlerinde bir model performansı elde etmiştir. Benzer şekilde, Botequim vd. (2019) Güneybatı İspanya'daki çam ve meşe ormanlarında örnek alan düzeyinde TAY tahmini için geliştirdikleri regresyon modelinde R^2 değerlerinin 0,75–0,95 arasında değiştiğini rapor etmişlerdir. Stefanidou vd. (2020) karmaşık topoğrafyaya sahip heterojen ormanlarda voxel(hacimsel piksel) tabanlı yöntem ile regresyon analizini karşılaştırmış, regresyon modelinin daha yüksek doğruluk (R^2 = 0,61; RMSE = 0,73 m) sağladığını, voxel tabanlı yaklaşımın ise heterojen yapı nedeniyle zayıf performans (R^2 = 0,15; RMSE = 171) gösterdiğini bildirmiştir.

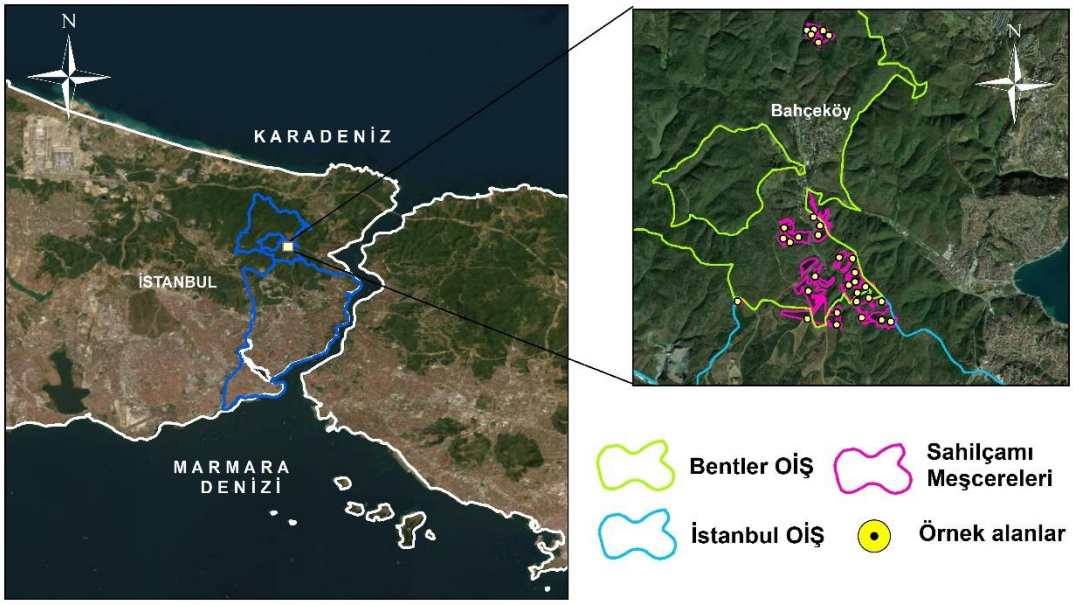
Makine öğrenmesi tekniklerinin LiDAR verileriyle entegrasyonu, tahmin modeli oluşturma konusunda önemli bir potansiyel taşımaktadır. Geleneksel istatistiksel yaklaşımlar, orman yapısal parametrelerinde doğası gereği bulunan karmaşık ve doğrusal olmayan ilişkileri modellemede genellikle yetersiz kalmaktadır. Buna karşın, makine öğrenmesi algoritmaları bu karmaşık ilişkileri yakalama ve modelleme konusunda görece üstün performans sergilemekte, klasik doğrusal istatistiksel modellerden daha yüksek doğruluk sağlamaktadır. Ayrıca çok boyutlu veri setleriyle çalışmada yüksek bir uyarlanabilirlik göstermektedir (Dalla Corte vd., 2020). Literatür incelendiğinde, TAY tahmininde genellikle doğrusal ilişkilere dayanan regresyon modellerinin kullanıldığı görülmektedir. Ancak, orman ekosistemlerinin karmaşık ve heterojen yapısı, doğrusal modellerin bu ilişkileri tam olarak yansıtmasını güçleştirmektedir. Özellikle Akdeniz iklim kuşağında yer alan ve yapısal olarak değişkenlik gösteren Sahil çamı (*Pinus pinaster*) ormanlarında, doğrusal olmayan ilişkileri yakalama kapasitesine sahip makine öğrenmesi algoritmalarının TAY tahminindeki potansiyeli yeterince araştırılmamıştır. Bu çalışma, LiDAR verilerinden türetilen metrikler kullanılarak, Extreme Gradient Boosting (XGBoost) algoritmasının Sahil çamı (*Pinus pinaster*) ormanlarında TAY tahminindeki başarısını değerlendirmeyi ve doğrusal modellere alternatif, yüksek doğruluk düzeyine sahip bir tahmin yaklaşımı ortaya koymayı amaçlamaktadır.

2. MATERYAL VE YÖNTEM

2.1. Çalışma Alanı

Bu çalışma, Bahçeköy Orman İşletme Müdürlüğü, Bentler Orman İşletme Şefliği ve İstanbul Orman İşletme Müdürlüğü, İstanbul Orman İşletme Şefliği sınırlarında kalan saf sahil çamı (*Pinus pinaster*) meşcerelerinde gerçekleştirilmiştir (Şekil 1). Bölgenin iklimi tipik Akdeniz özellikleri göstermekte olup, yazlar sıcak ve kuru, kışlar ise ılıman ve yağışlıdır. Topografya açısından eğimsiz ve hafif eğimli alanlardan dik yamaçlara kadar değişen engebeli bir yapıya sahiptir.

© 2025 Demirel.



Şekil 1. *Çalışma alanı ve örnek alanların dağılımı*

2.2. Arazi Verileri

2020 yılı Temmuz ayında gerçekleştirilen arazi ölçümleri, sahil çamı meşcerelerinde rastgele seçilen 32 dairesel örnek alanda yapılmış olup, her örnek alan 400 m² (yaklaşık 11,28 m yarıçap) büyüklüğündedir. Çalışma alanında çoğunluğu orta ve kalın ağaçlık çağında (göğüs çapı>35 cm) olmak üzere sınırlı sayıda Sahil çamı (Pinus pinaster) meşceresi bulunmaktadır. Bu nedenle, mevcut tüm meşcereler örneklemeye dahil edilmiştir. Meşcere tiplerine göre örnek alanların dağılımı Çizelge 1'de sunulmaktadır.

Çizelge 1. *Örnek alanların meşcere tiplerine dağılımı*

Meşcere Tipi	Örnek Alan Sayısı
Çma3	2
Çmb3	2
Çmbc3	3
Çmc3	4
Çmcd3	21

Her bir örnek alanda, göğüs çapı 8 cm'den büyük olan tüm ağaçlar için TAY, toplam ağaç boyu ve taç genişliği ölçülmüş, ayrıca ağaç türleri belirlenmiştir. Örnek alanlardaki tüm ağaçların TAY ve ağaç boyları Haglöf VL5 Lazer Mesafe/Yükseklik Ölçer ile hassas bir şekilde ölçülmüştür. TAY, en alt canlı dal seviyesinin yüksekliği olarak tanımlanmıştır. Ancak ana ağaç tacından izole olmuş, en alt canlı dalların yüksekliği, TAY olarak kabul edilmemiştir. Böyle durumlarda en alt canlı dalların ortalama yüksekliği esas alınmıştır.

Örnek alanların çalışma alanına dağılımı, yükseklik, bakı, eğim ve ağaç yoğunluğu gibi değişkenleri temsil edecek şekilde yapılmış; erişilebilirlik ve alt vejetasyon da göz önünde bulundurulmuştur. Ayrıca, meşcere kenar etkilerinden kaçınmak amacıyla, mümkün olduğunca meşcere kenarları ile vadi tabanı ve sırt gibi topoğrafik değişim noktalarından örnek alan alınmamıştır. Hava tabanlı LiDAR veri tarihi ile arazi çalışmaları arasındaki dönemde herhangi bir doğal veya insan müdahalesine maruz kalan alanlar örneklemden çıkarılmıştır. Örnek alanların merkezi konumlarını belirlemek için GNSS/RTK GPS alıcısı kullanılmıştır. Örnek alan koordinatları ±0,25–0,50 m doğruluk ile

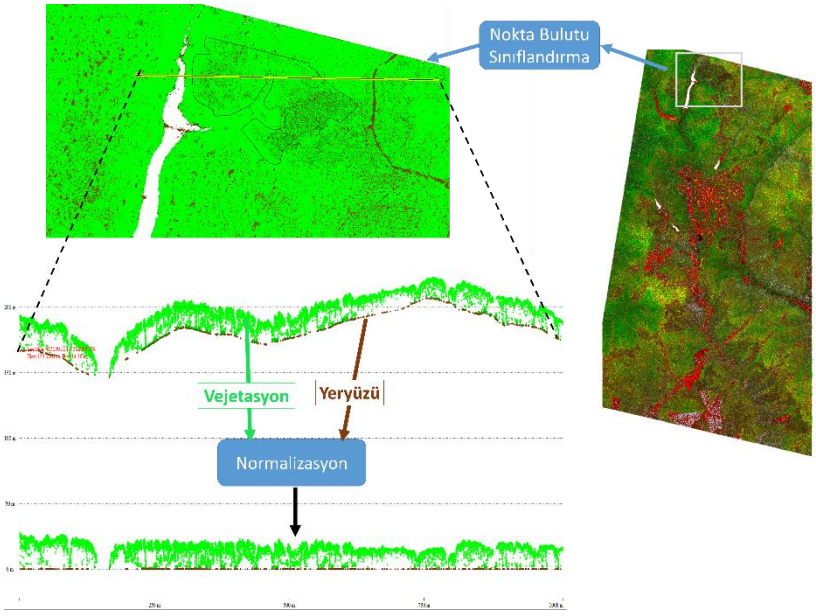
© 2025 Demirel.

kaydedilmiş olup, hava tabanlı LiDAR verileri ile saha ölçümlerinin doğru bir şekilde eşleştirilmesini sağlamaktadır.

2.3. Hava Tabanlı LiDAR Verisi ve Metrik Çıkarımı

Hava tabanlı LiDAR verileri, 22 Temmuz 2018 tarihinde, RIEGLE LMS-Q680i LiDAR sensör platformu ile donatılmış bir Cessna T206 uçağı kullanılarak elde edilmiştir. Lazer sensörü, her lazer darbesi için yedi geri dönüş kaydedebilmiştir. Darbe tekrarlama frekansı 400 kHz olarak uygulanmış ve uçuş yüksekliği yerden yaklaşık 720 m olarak belirlenmiştir. Platformun tarama açısı −35° ile +35° arasında değişmiş olup, LiDAR verilerinin dikey ve yatay doğrultulardaki konumsal doğruluğu sırasıyla XY = ±6 cm ve Z = ±7 cm olarak ölçülmüştür. Elde edilen verilerin ortalama yoğunluğu yaklaşık 12 nokta/m² seviyesindedir.

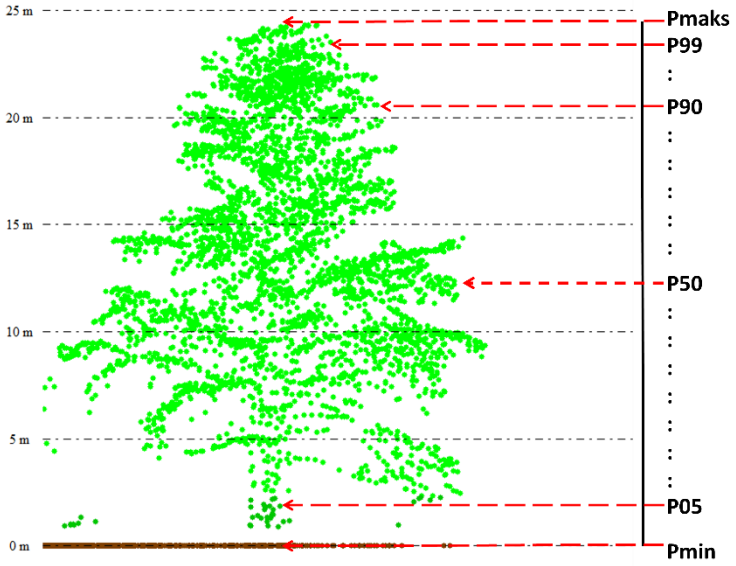
Orman yapısal özelliklerini tahmin etmek için kullanılacak LiDAR metrikleri, topografyanın etkilerinin giderildiği normalize edilmiş bir nokta bulutundan türetilmelidir (Koukoulas ve Blackburn, 2005). Normalize edilmiş nokta bulutu elde etmek amacıyla, LiDAR verileri öncelikle aykırı (gürültü) noktalardan temizlenmiştir. Daha sonra, IPTD (Iterative Point-based Terrain Detection) algoritması kullanılarak noktalar yeryüzü ve vejetasyon olarak iki sınıfa ayrılmıştır. Bu iki sınıf elde edildikten sonra, her noktanın göreli yüksekliği, lazer noktasının yüksekliği ile yeryüzü noktasının arasındaki fark alınarak hesaplanmış ve böylece yerden yüksekliği temsil eden topografya etkisi giderilmiştir (normalize) edilmiş nokta bulutu elde edilmiştir (Şekil 2).



Şekil 2. *Hava tabanlı LiDAR veri işleme*

LiDAR metrikleri, TAY tahminine yönelik modelleme çalışmasında potansiyel bağımsız değişkenler olarak kullanılmak üzere her bir LiDAR penceresi (dairesel örnek alan) için hesaplanmıştır. Bu metrikler, normalize edilmiş nokta bulutlarından LiDAR360 yazılımının deneme sürümü (GreenValley International, 2023) kullanılarak türetilmiştir. Yazılımın “Calculate Forest Metrics by Polygon” aracı ile her bir örnek alanı temsil eden ve örnek alan büyüklüğüne karşılık gelen XY koordinatlı dairesel poligonlar üzerinden yükseklik metrikleri (Elevation Metrics) elde edilmiştir (Şekil 3).

© 2025 Demirel.



Şekil 3. *LiDAR verilerinden yükseklik metriklerinin çıkarımı*

Bu çalışmada, yükseklikle ilişkili 46 ve nokta bulutu yoğunluğu ile ilişkili 10 parametre hesaplanmıştır. Hesaplanan metrikler arasında maksimum, minimum, ortalama ve medyan yükseklik ile yükseklik yüzdelikleri ve nokta bulutu yoğunluğu metrikleri bulunmaktadır (Çizelge 2).

Çizelge 2. *LiDAR nokta bulutu verilerinden türetilen yükseklik metrikleri*

Metrik	**Açıklama**
Maximum (Z_max)	Birimdeki en yüksek nokta yüksekliği
Minimum (Z_min)	Birimdeki en düşük nokta yüksekliği
Mean (Z_mean)	Birimdeki yüksekliklerin ortalaması
Median (Z_median)	Birimdeki yüksekliklerin medyanı
Standard Deviation, SD	Birimdeki Z değerlerinin standart sapması.
Variance	Birimdeki Z değerlerinin varyansı.
Average Absolute Deviation (MAD)	Yüksekliklerin ortalama mutlak sapması
MAD Median	Medyan mutlak sapma
Coefficient of Variation (CV)	Yüksekliklerin standart sapmasının ortalamaya oranı
Skewness	Yükseklik değerlerinin simetrisi
Kurtosis	Yükseklik değerlerinin basıklığı
AIH (15)	Accumulated Height Index; %1-%99 arası kümülatif yükseklikler
AIH Interquartile Distance	AIH25%-AIH75% yükseklik farkı
Elevation Percentiles (15)	%1-%99 yükseklik yüzdelikleri
Percentile Interquartile Distance	25%-75% yükseklik farkı
Generalized Mean (2nd & 3rd power)	Yüksekliklerin 2. ve 3. kuvvetli genelleştirilmiş ortalamaları
Density Metrics (10)	Nokta bulutunun yükseklik aralığına göre yoğunluk oranları
Canopy Relief Ratio (CRR)	Örtü tabakası yüksekliği oranı
Leaf Area Index, LAI	Yaprak Alan İndeksi
Gap Fraction	Boşluk Oranı

2.4. Veri Analizi ve Değerlendirme

Örnek alanlarda gerçekleştirilen ölçümlerden elde edilen bireysel ağaçlara ait TAY verileri kullanılarak, her bir örnek alan için ortalama TAY değerleri hesaplanmıştır. Bu örnek alanlarla eşleşen LiDAR verileri topografik etkilerden arındırılıp normalize edildikten sonra, orman dokusunun hem yükseklik hem de örtü özelliklerini yansıtan çok sayıda yapısal metrik üretilmiştir. Ancak LiDAR verilerinden türetilen metriklerin sayıca fazla olması ve aralarında güçlü ilişkilerin bulunması, modelleme öncesinde değişken filtrelenmesini zorunlu hale gelmesine neden olmuştur. Benzer bilgiyi taşıyan çok sayıda yüksek korelasyonlu değişkenin aynı modelde yer alması, çoklu doğrusal

© 2025 Demirel.

bağlantı sorununa yol açarak tahmin doğruluğunu olumsuz etkileyebilmektedir. Bu nedenle modelin basitleştirilmesi, istikrarının artırılması ve TAY üzerindeki açıklayıcı etkilerin daha güvenilir biçimde belirlenebilmesi amacıyla sistematik bir değişken seçim süreci yürütülmüştür. Bu süreçte öncelikle türetilen tüm metrikler arasında Pearson korelasyon katsayıları hesaplanmış, ardından değişken çiftleri arasındaki ilişkiler incelenmiştir. Bu çalışma kapsamında kullanılan makine öğrenmesi algoritması (XGBoost) değişkenler arasındaki yüksek korelasyonu kısmen tolere edebilse de, model performansını artırmak ve yorumlanabilirliği sağlamak amacıyla eşik değer olarak r> 0,90 kabul edilmiştir. Öncelikle bu değerin üzerinde kalan yüksek korelasyonlu değişken çiftleri korelasyon matrisi yardımıyla belirlenmiştir. Her bir korelasyon grubunda, TAY ile daha yüksek ilişki gösteren tek bir metrik veri setinde tutulmuş; diğer değişkenler modelden çıkarılmıştır. Son aşamada, her korelasyon grubundan yalnızca bilgi değeri en yüksek olan metriklerin seçilmesiyle değişken sayısı önemli ölçüde azaltılmıştır. Böylece hem model performansı korunmuş hem de çoklu bağlantı kaynaklı önyargı azaltılmıştır. Hazırlanan bu veri seti ile tahmin modeli oluşturulmuştur (Çizelge 3).

Çizelge 3. *Tahmin modelinde kullanılan yükseklik metrikleri*

Metrik	**Açıklama**
Maximum (Z_max)	Birimdeki en yüksek nokta yüksekliği
Minimum (Z_min)	Birimdeki en düşük nokta yüksekliği
Standard Deviation, SD	Birimdeki Z değerlerinin standart sapması.
MAD Median	Medyan mutlak sapma
Skewness	Yükseklik değerlerinin simetrisi
Kurtosis	Yükseklik değerlerinin basıklığı
AIH (%1, %10, %30)	%1, %10, %30 Kümülatif yükseklikler
Elevation Percentiles (%1)	%1 yükseklik yüzdesi
Percentile Interquartile Distance	25%-75% yükseklik farkı
Density Metrics (0, 1, 2, 3, 4, 5, 6, 7, 9)	Nokta bulutunun yükseklik aralığına göre yoğunluk oranları
Canopy Relief Ratio (CRR)	Örtü tabakası yüksekliği oranı
Leaf Area Index, LAI	Yaprak Alan İndeksi
Gap Fraction	Boşluk Oranı

XGBoost, Chen ve Guestrin (2016) tarafından tanıtılan gradyan artırma (gradient boosting) topluluk tekniğinin yenilikçi bir uygulamasıdır. Bu yöntem, zayıf öğrenicilerin bir kümesini eklemeli bir stratejiyle bir araya getirerek güçlü bir tahmin modeli oluşturur. Modelin eğitim süreci, tüm veri kümesi kullanılarak ilk öğrenicinin eğitilmesiyle başlar. Daha sonra, bir önceki öğrenicinin tahminlerinden elde edilen artık hatalar üzerinde eğitilmek üzere yeni bir öğrenici eklenir (Chen ve Guestrin 2016). Bu yinelemeli süreç, belirlenen durdurma kriteri sağlanana kadar devam eder. Nihai tahmin sonuçları, tüm bireysel öğrenicilerin tahminlerinin birleştirilmesiyle elde edilir.

XGBoost algoritmasının başarısını etkileyen temelde 10 farklı hiperparametre bulunmasından dolayı modelinin ayarlanması oldukça karmaşıktır. Hiperparametreler içerisinde en önemlileri ise *max_depth*, *eta*, ve *nrounds* olarak kabul edilmektedir. *max_depth* her bir karar ağacının maksimum derinliğini belirleyen bir hiperparametredir. Bu parametre, modelin öğrenme kapasitesini doğrudan etkiler; yüksek değerler modelin karmaşık örüntüleri öğrenmesine olanak tanırken aşırı uyum riskini artırır. Daha düşük değerler ise modelin genelleme yeteneğini artırmakla birlikte, karmaşık ilişkilerin yeterince yakalanamamasına neden olabilir. *eta*, öğrenme oranını ifade eder ve modelin her bir iterasyonda ağırlık güncelleme hızını kontrol eder. Düşük *eta* değerleri modelin daha yavaş ancak daha istikrarlı bir şekilde öğrenmesini sağlar. *nrounds*, yineleme sayısını ifade eder ve modelin ne kadar öğrenici oluşturacağını belirler. Genellikle düşük *eta* değerleriyle birlikte daha yüksek *nrounds* sayıları tercih edilir. Böylece model adım adım optimize edilerek daha iyi genelleme performansı elde edilir.

Bunun yanında herhangi bir hiperparametrede yapılan değişiklik diğer hiperparametrelerin optimum değerlerini de etkileyebilmektedir. Dolayısıyla XGBoost'ta hiperparametre optimizasyonu kritik bir

© 2025 Demirel.

öneme sahiptir. Grid Search(ızgara arama) yaklaşımı, makine öğrenmesi yaklaşımlarında hiperparametre ayarlaması için kullanılan geleneksel bir yöntemdir. Bu yöntem, verilen hiperparametre değerlerinin tüm olası kombinasyonlarını ayrıntılı bir şekilde dener ve en iyi modeli bulmaya çalışır. Bu çalışmada hiperparametre optimizasyonu için Grid Search yaklaşımı kullanılmıştır. Bu yaklaşımla oluşturulan 2304 farklı kombinasyon oluşturulmuş ve en küçük RMSE değerine sahip olan kombinasyon model parametresi olarak seçilmiştir. XGBoost algoritması R (v.4.5.1) ortamında "xgboost" (v.1.7.11) (Chen ve Guestrin 2016) paketi kullanılarak uygulanmıştır.

Oluşturulan tahmin modelinin genelleme performansını değerlendirmek amacıyla veri setinin sınırlı olması sebebiyle çapraz doğrulama tekniği olarak LOOCV (Leave-One-Out Cross Validation-birini dışarı bırakarak çapraz doğrulama) yöntemi kullanılmıştır. LOOCV yöntemi ile veri setindeki her bir örnek, sırayla test verisi olarak ayrılmakta; kalan tüm örnekler kullanılarak model eğitilmekte ve dışarı bırakılan örneğin tahmini yapılmaktadır. Bu işlem veri setindeki tüm örnekler için tekrarlanmakta ve modelin genel performansı, tüm tahminlerin ortalaması alınarak değerlendirilir. Model performansı kök ortalama kare hata (RMSE), ortalama mutlak hata (MAE) ve belirtme katsayısı (R^2) ile değerlendirilmiştir. RMSE (Denklem 1) ve MAE (Denklem 2), tahmin edilen ve gözlenen TAY değerleri arasındaki mutlak farkların büyüklüğünü ortaya koyarak modelin genel doğruluğunu yansıtmaktadır. R^2 (Denklem 3) ise LiDAR verilerine dayalı tahminlerin açıklayıcılık ve güvenilirlik düzeyini göstermektedir. Daha yüksek R^2 ve daha düşük RMSE ile MAE değerleri, modelin tahmin doğruluğunun arttığını ifade etmektedir.

$$\text{RMSE}= \sqrt{\sum_{i=1}^{n} \frac{(TAY_{Gerçek}-\text{TAY}_{LiDAR})^2}{n}} \quad (1)$$

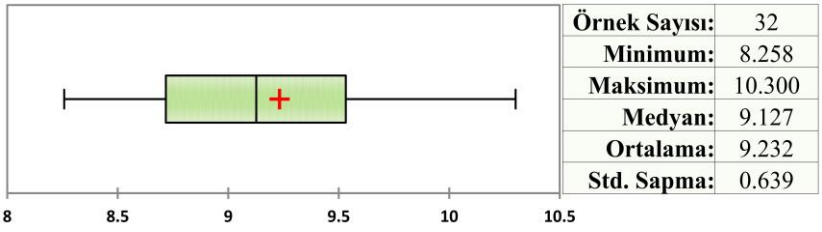
$$\text{MAE}= \frac{1}{n}\sum_{i=1}^{n} TAY_{Gerçek} - \text{TAY}_{LiDAR} \quad (2)$$

$$R^2= 1 - \frac{\sum_{i=1}^{n}(\text{TAY}_{Gerçek}-\text{TAY}_{LiDAR})^2}{\sum_{i=1}^{n}(\text{TAY}_{Gerçek}-\text{TAY}_{Ort.})^2} \quad (3)$$

Burada, *n* gözlem sayısını, $TAY_{Gerçek}$ yersel verilerden elde edilen tepe altı yüksekliği, TAY_{LiDAR} LiDAR verilerden elde edilen tepe altı yüksekliği, $TAY_{Ort.}$ yersel verilerden elde edilen tepe altı yükseklik ortalamasını ifade etmektedir.

3. BULGULAR

Arazi ölçümlerinden elde edilen TAY değerleri 8,25 m ile 10,3 m arasında değişmiş, ortalama 9,23 ± 0,6 m olarak belirlenmiştir (Şekil 4). Bu sonuç, çalışma alanındaki saf sahilçam meşcerelerinin dikey yapı çeşitliliğinin sınırlı, ancak belirgin olduğunu göstermektedir.



Örnek Sayısı:	32
Minimum:	8.258
Maksimum:	10.300
Medyan:	9.127
Ortalama:	9.232
Std. Sapma:	0.639

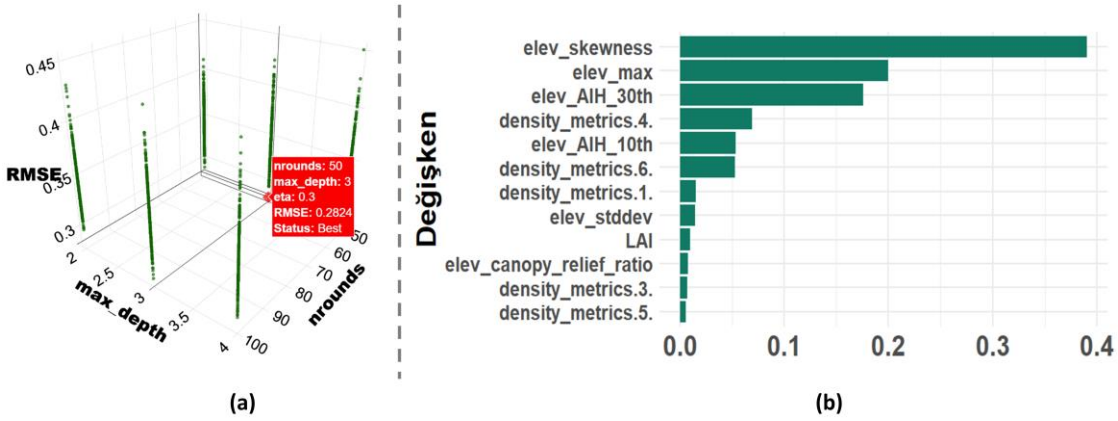
Şekil 4. *Örnek alanlardan elde edilen TAY verisinin özet istatistikleri*

Korelasyon analizi sonucunda 56 LiDAR metriğinden yüksek korelasyon (r > 0,9) gösteren değişkenler elenmiş ve 23 metrik modele dahil edilmiştir. Tahmin modeli oluşturmadan önce XGBoost modeli için hiperparametre optimizasyonu yapılmıştır. Kapsamlı bir grid search ile toplam 2304 parametre kombinasyonu değerlendirilmiştir. Değerlendirme kriteri olarak RMSE dikkate alınmış ve en küçük RMSE değerine sahip kombinasyon modelde kullanılmıştır. Optimizasyon

© 2025 Demirel.

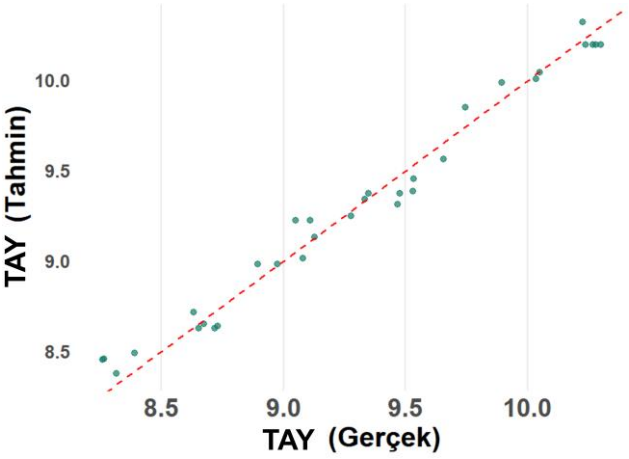
sonucunda, model performansını en iyi şekilde artıran temel üç parametre nrounds=50, max_depth=3 ve eta=0,3 olarak belirlenmiştir (Şekil 5a).

XGBoost algoritmasının değişken önem analizi sonuçlarına göre TAY üzerinde en yüksek etkiye sahip ilk üç metrik örnek alanın yükseklik dağılımının çarpıklığını gösteren *elev_skewness*, örnek alandaki maksimum yüksekliği belirten *elev_max* ve bitki örtüsünün %30 yüksekliği altındaki kümülatif yoğunluğunu temsil eden *elev_AIH_30th* olarak sıralanmıştır (Şekil 5b).



Şekil 5. *XGBoost algoritmasının hiperparametreleri(a) ve değişken önem dereceleri(b)*

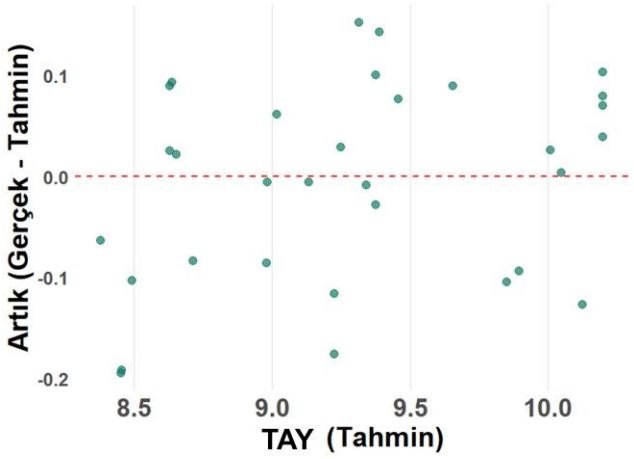
XGBoost modeli, çapraz doğrulama (LOOCV) sonucunda örnek alan düzeyinde yüksek bir doğruluk elde etmiştir (R^2 = 0,80, RMSE = 0,28 m, MAE = 0,21 m). Tahmin edilen ve gözlenen TAY değerleri arasındaki ilişki, 1:1 doğrusu etrafında güçlü bir uyum göstermiştir (Şekil 6). Bu durum, modelin hem doğruluk hem de genelleme kapasitesi bakımından güvenilir sonuçlar ürettiğini ortaya koymaktadır.



Şekil 6. *Tahmin edilen ve gözlenen TAY değerlerinin 1:1 doğrusu etrafındaki dağılımı*

Artık grafiği incelendiğinde, tahmin hatalarının rastgele dağıldığı ve belirli bir sistematik sapma göstermediği görülmüştür (Şekil 7). Bu bulgu, modelin homojen ve dengeli tahminler ürettiğini, herhangi bir TAY aralığında önyargılı olmadığını doğrulamaktadır.

© 2025 Demirel.



Şekil 7. *Artık grafiği*

Genel olarak, *elev_skewness*, *elev_max* ve *elev_AIH_30th* gibi metriklerin modelde baskın rol oynaması, tepe altı yüksekliğinin örnek alanların dikey yapı dağılımı ve örtü yoğunluğu ile yakından ilişkili olduğunu göstermektedir. Bu sonuçlar, XGBoost algoritmasının LiDAR verilerine dayalı TAY tahmininde güvenilir ve güçlü bir alternatif sunduğunu doğrulamaktadır.

4. TARTIŞMA

Bu çalışmada, saf sahil çamı (*Pinus pinaster*) meşcerelerinde XGBoost algoritması ile hava tabanlı LiDAR verilerine dayalı olarak TAY tahminleri gerçekleştirilmiştir. Oluşturulan modelin performansı yüksek doğrulukla doğrulanmıştır (R^2 = 0,80, RMSE = 0,28 m, MAE = 0,21 m). Elde edilen sonuçlar, çalışma alanındaki meşcerelerin dikey yapısal varyasyonunun sınırlı olmasına karşın, LiDAR tabanlı makine öğrenmesi yaklaşımlarının TAY tahmininde güvenilir ve güçlü bir araç olduğunu göstermektedir.

Çalışmamızda XGBoost ile elde edilen değişken önemi analizi, literatürde önerilen TAY tahmin metrikleriyle uyumlu olarak *elev_skewness* (yükseklik dağılımının çarpıklığı), *elev_max* (maksimum yükseklik) ve *elev_AIH_30th* (taç altı %30 kümülatif yoğunluk) metriklerini ön plana çıkarmıştır. Bu üç değişken Andersen vd. (2005), Erdody ve Moskal (2010) ve özellikle Hermosilla vd. (2014) tarafından yapılan çalışmalarda rapor edilen LiDAR metrikleri ile de önemli ölçüde uyumludur. Özellikle *elev_skewness*, *elev_max* ve *elev_AIH_30th* gibi metriklerin modelde baskın olması, TAY'nin dikey yapı dağılımı ve örtü yoğunluğu ile ilişkili olduğunu doğrulamaktadır.

TAY kısa zaman aralıklarında yapısal olarak büyük değişim göstermemektedir. Literatürde, özellikle çam plantasyonlarında ağaç tepesi dinamiklerinin oldukça öngörülebilir bir seyir izlediği, taç taban yüksekliğinin kısa zaman aralıklarında çok az veya hiç yükselmediği belirtilmiştir (Valentine vd., 2013). Bu nedenle, bu çalışmada kullanılan LiDAR verileri (2018) ile arazi envanter ölçümleri (2020) arasındaki iki yıllık farkın, örnek alanlarda TAY ölçümleri üzerinde önemli bir etkisinin olmadığı düşünülmektedir.

Arazi ölçümlerinden elde edilen TAY değerlerinin dar bir aralıkta (8,25–10,3 m) yoğunlaşması, çalışma alanındaki sahil çamı meşcerelerinin doğal yayılış alanı dışında plantasyon teknikleri ile oluşturulması ve çoğunlukla yakın tarihli dikimlerden oluşması nedeniyle gelişim çağı farklılıklarının sınırlı olmasına bağlanabilir. Bu durum, modelin hata dağılımını dar bir aralıkta sınırlandırmış ve RMSE değerlerinin düşük olmasına yol açmıştır. Bu bulguyu destekler şekilde Botequim vd. (2019) tarafından sahil çamı için sınırlı bir örneklem (n=14) ile yapılan modelleme çalışmasında RMSE değeri 0,23 m olarak bulunmuştur. Bu çalışmada da varyasyon darlığı nedeniyle benzer sonuçların elde edildiği düşünülmektedir. Literatürdeki benzer LiDAR temelli çalışmalarda, daha heterojen orman yapılarında RMSE değerlerinin 0–2 m arasında değiştiği görülmektedir (Erdody ve Moskal

© 2025 Demirel.

2010; Kelly vd., 2017; Stefanidou vd., 2020). Dolayısıyla dar varyasyonlu meşcerelerde değerlendirme ölçütleri olarak determinasyon katsayısı (R^2) ile karşılaştırma yapmak daha güvenilir ve yol gösterici olabilir.

Bu bağlamda, çalışmadaki R^2 = 0,80 değeri, oluşturulan modelin LiDAR metrikleri ile TAY varyasyonunu büyük ölçüde açıklayabildiğini göstermektedir. XGBoost algoritmasının performansı, literatürde sıklıkla kullanılan doğrusal regresyon modelleri ile karşılaştırıldığında, özellikle doğrusal olmayan ilişkileri yakalama yeteneği sayesinde öne çıkmaktadır. Birçok araştırmada R^2 değerleri 0,51 ile 0,78 arasında değişmektedir (Erdody ve Moskal 2010; Hermosilla vd., 2014; Kelly vd., 2017; Stefanidou vd., 2020). Bu bakımdan XGBoost algoritması gibi makine öğrenimi algoritmalarının daha başarılı sonuçlar verdiği söylenebilir. Buna karşın Botequim vd. (2019) tarafından yapılan çalışmada sahil çamı için geliştirilen TAY modelinde R^2 değeri 0,95 bulunmuştur. Bu durum çok yüksek model performansını ifade etmektedir. Ancak bu çalışmada sınırlı bir örneklem (n=14) ile yapılan modelleme çalışmasında doğrusal regresyon analizi de kullanıldığı dikkate alındığında aşırı uyum sorunu gösterdiği düşünülmektedir.

5. SONUÇLAR

Çalışmanın sınırlılıkları, bulguların yorumlanmasında dikkate alınmalıdır. Öncelikle, çalışma alanındaki meşcerelerin homojen yapısı ve örneklem sayısının sınırlılığı, modelin genellenebilirliğini kısıtlamaktadır. Daha heterojen ve farklı yaş sınıfları ve gelişim çağlarına sahip meşcerelerde model performansının doğrulanması gerekmektedir. Ayrıca, LiDAR verilerinin elde edilmesinin maliyetli ve her çalışma alanında erişilebilir olmaması, uygulamanın yaygınlaştırılmasını sınırlayabilir. Bu nedenle, gelecekteki çalışmalarda veri füzyonu teknikleri kullanılarak yüksek çözünürlüklü uydu görüntüleri/hava fotoğrafları veya mobil LiDAR verileri ile entegrasyonun araştırılması önerilmektedir.

Bulgular ayrıca, makine öğrenmesi algoritmalarının LiDAR temelli ormancılık uygulamalarında henüz tam olarak değerlendirilmediğini göstermektedir. Bu çalışma, XGBoost algoritmasının, klasik regresyon modellerinin sınırlı kaldığı doğrusal olmayan ilişkileri yakalayabilme kapasitesini ortaya koyarak literatüre önemli bir katkı sağlamaktadır. Öte yandan, modelin değişken önem sonuçları, saha çalışmaları ve yönetim uygulamaları için hangi LiDAR metriklerinin kritik olduğunu belirlemekte ve bu sayede gelecekteki veri toplama ve modelleme süreçlerini optimize edebilecek rehber niteliği taşımaktadır.

Sonuç olarak, LiDAR verilerine dayalı XGBoost modeli, dar varyasyonlu saf sahil çamı meşcerelerinde bile yüksek doğrulukla TAY tahmini yapabilmekte, değişken önemi analizleri ile literatürle uyumlu bulgular sunmaktadır. Bu sonuçlar, makine öğrenmesi algoritmalarının ormancılıkta yapısal parametre tahminlerinde güçlü bir alternatif sunduğunu ve sürdürülebilir orman yönetimi stratejilerinde potansiyel kullanım alanlarını desteklediğini göstermektedir. Gelecekte, farklı tür kombinasyonlarına sahip meşcerelerde ve geniş örneklem sayılarıyla benzer çalışmaların gerçekleştirilmesi, modelin genellenebilirliğini ve uygulama alanını daha da artıracaktır.

Yazar Beyanları

Çıkar çatışması yoktur. Çalışma için maddi destek alınmamıştır. Etik kurul onayı gerekmemektedir. Üretken yapay zekâ araçları kullanılmamıştır. Daha önce sunulmamış veya yayımlanmamıştır. Veriler talep üzerine erişime açılacaktır.

© 2025 Demirel.

KAYNAKLAR

Andersen, H., McGaughey, R. J. ve Reutebuch, S. E. (2005). Estimating forest canopy fuel parameters using LIDAR data. *Remote Sensing of Environment*, *94*(4), 441–449. https://doi.org/10.1016/j.rse.2004.10.013

Bahadir, M., Karsli, F., Yildirim, F. S. ve Misir, M. (2025). Tree crown segmentation and estimation of metrics from point clouds with improved local maximum method. *The Photogrammetric Record*, *40*(191), e70015. https://doi.org/10.1111/phor.70015

Botequim, B., Fernandes, P. M., Borges, J. G., González-Ferreiro, E. ve Guerra-Hernández, J. (2019). Improving silvicultural practices for Mediterranean forests through fire behaviour modelling using LiDAR-derived canopy fuel characteristics. *International Journal of Wildland Fire*, *28*(11), 823. https://doi.org/10.1071/wf19001

Chen, T. ve Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *KDD '16: proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining* içinde (ss. 785 – 794). https://doi.org/10.1145/2939672.2939785

Coskuner, K. A., Vatandaslar, C., Ozturk, M., Harman, I., Bilgili, E., Karahalil, U., Berber, T. ve Gormus, E. T. (2023). Estimating Mediterranean stand fuel characteristics using handheld mobile laser scanning technology. *International Journal of Wildland Fire, 32*(9), 1347–1363. https://doi.org/10.1071/wf23005

Dalla Corte, A. P. D., Souza, D. V., Rex, F. E., Sanquetta, C. R., Mohan, M., Silva, C. A., Zambrano, A. M. A., Prata, G., De Almeida, D. R. A., Trautenmüller, J. W., Klauberg, C., De Moraes, A., Sanquetta, M. N., Wilkinson, B. ve Broadbent, E. N. (2020). Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. *Computers and Electronics in Agriculture*, *179*, 105815. https://doi.org/10.1016/j.compag.2020.105815

Dean, T. J., Cao, Q. V., Roberts, S. D. ve Evans, D. L. (2009). Measuring heights to crown base and crown median with LiDAR in a mature, even-aged loblolly pine stand. *Forest Ecology and Management, 257*(1), 126–133. https://doi.org/10.1016/j.foreco.2008.08.024

Erdody, T. L. ve Moskal, L. M. (2010). Fusion of LiDAR and imagery for estimating forest canopy fuels. *Remote Sensing of Environment*, *114*(4), 725–737. https://doi.org/10.1016/j.rse.2009.11.002

FAO. (2023). *The State of the World's Forests 2023: Forests and health.* Food and Agriculture Organization of the United Nations.

García, M., Saatchi, S., Ustin, S. ve Balzter, H. (2018). Modelling forest canopy height by integrating airborne LiDAR samples with satellite Radar and multispectral imagery. *International Journal of Applied Earth Observation and Geoinformation*, *66*, 159–173. https://doi.org/10.1016/j.jag.2017.11.017

Green Valley International. (2023). *LiDAR360 user guide*. Green Valley International Ltd. https://www.greenvalleyintl.com/gvi/web/us/file/EN-User-Guide-LiDAR360.pdf

Guo, Q., Su, Y., Hu, T., Guan, H., Jin, S., Zhang, J., Zhao, X., Xu, K., Wei, D., Kelly, M. ve Coops, N. C. (2021). LIDAR boosts 3D Ecological Observations and Modelings: A Review and perspective. *IEEE Geoscience and Remote Sensing Magazine*, *9*(1), 232–257. https://doi.org/10.1109/mgrs.2020.3032713

Hall, S. A., Burke, I., Box, D. O., Kaufmann, M. R. ve Stoker, J. M. (2005). Estimating stand structure using discrete-return lidar: an example from low density, fire prone ponderosa pine forests. *Forest Ecology and Management*, *208*(1–3), 189–209. https://doi.org/10.1016/j.foreco.2004.12.001

Hermosilla, T., Ruiz, L. A., Kazakova, A. N., Coops, N. C. ve Moskal, L. M. (2014). Estimation of forest structure and canopy fuel parameters from small-footprint full-waveform LiDAR data. *International Journal of Wildland Fire*, *23*(2), 224. https://doi.org/10.1071/wf13086

Kaushal, S. ve Baishya, R. (2021). Stand structure and species diversity regulate biomass carbon stock under major Central Himalayan forest types of India. *Ecological Processes*, *10*(1). https://doi.org/10.1186/s13717-021-00283-8

Kelly, M., Su, Y., Di Tommaso, S., Fry, D., Collins, B., Stephens, S. ve Guo, Q. (2017). Impact of error in LIDAR-derived canopy height and canopy base height on modeled wildfire behavior in the Sierra Nevada, California, USA. *Remote Sensing*, *10*(1), 10. https://doi.org/10.3390/rs10010010

Koukoulas, S. ve Blackburn, G. A. (2005). Spatial relationships between tree species and gap characteristics in broad-leaved deciduous woodland. *Journal of Vegetation Science, 16*(5), 587–596. https://doi.org/10.1111/j.1654-1103.2005.tb02400.x

Küçük, O., Goltas, M., Demirel, T., Mitsopoulos, I. ve Bilgili, E. (2021). Predicting canopy fuel characteristics in *Pinus brutia* Ten., *Pinus nigra* Arnold and *Pinus pinaster* Ait. forests from stand variables in north-western Turkey. *Environmental Engineering and Management Journal*, *20*(2), 309–318. https://doi.org/10.30638/eemj.2021.031

© 2025 Demirel.

Küçük, Ö., Bilgili, E., Durmaz, B. D., Sağlam, B. ve Baysal, İ. (2009). Örtü yangınının tepe yangınına geçişinde etkili olan faktörler. *Kastamonu University Journal of Forestry Faculty*, *9*(2), 80–85.

Lee, H., Slatton, K. C., Roth, B. E. ve Cropper, W. P. (2010). Adaptive clustering of airborne LiDAR data to segment individual tree crowns in managed pine forests. *International Journal of Remote Sensing*, *31*(1), 117–139. https://doi.org/10.1080/01431160902882561

Luo, L., Zhai, Q., Su, Y., Ma, Q., Kelly, M. ve Guo, Q. (2018). Simple method for direct crown base height estimation of individual conifer trees using airborne LiDAR data. *Optics Express*, *26*(10), A562. https://doi.org/10.1364/oe.26.00a562

Maguya, A., Tegel, K., Junttila, V., Kauranne, T., Korhonen, M., Burns, J., Leppanen, V. ve Sanz, B. (2015). Moving voxel method for estimating canopy base height from airborne laser scanner data. *Remote Sensing*, *7*(7), 8950–8972. https://doi.org/10.3390/rs70708950

Maltamo, M., Karjalainen, T., Repola, J. ve Vauhkonen, J. (2018). Incorporating tree- and stand-level information on crown base height into multivariate forest management inventories based on airborne laser scanning. *Silva Fennica*, *52*(3), 10006. https://doi.org/10.14214/sf.10006

Næsset, E. ve Økland, T. (2002). Estimating tree height and tree crown properties using airborne scanning laser in a boreal nature reserve. *Remote Sensing of Environment*, *79*(1), 105–115. https://doi.org/10.1016/s0034-4257(01)00243-7

Stefanidou, A., Gitas, I., Korhonen, L., Stavrakoudis, D. ve Georgopoulos, N. (2020). LIDAR-Based estimates of canopy base height for a dense uneven-aged structured forest. *Remote Sensing*, *12*(10), 1565. https://doi.org/10.3390/rs12101565

Valentine, H. T., Amateis, R. L., Gove, J. H. ve Mäkelä, A. (2013). Crown-rise and crown-length dynamics: application to loblolly pine. Forestry, 86(3), 371–375. https://doi.org/10.1093/forestry/cpt007

Vauhkonen, J. (2010). Estimating crown base height for Scots pine by means of the 3D geometry of airborne laser scanning data. *International Journal of Remote Sensing,* *31*(5), 1213–1226. https://doi.org/10.1080/01431160903380615

Viedma, O., Silva, C. A., Moreno, J. M. ve Hudak, A. T. (2024). LadderFuelsR: A new automated tool for vertical fuel continuity analysis and crown base height detection using light detection and ranging. *Methods in Ecology and Evolution 15*(11), 1958–1967. https://doi.org/10.1111/2041-210x.14427

Zhao, K., Popescu, S., Meng, X., Pang, Y. ve Agca, M. (2011). Characterizing forest canopy structure with lidar composite metrics and machine learning. *Remote Sensing of Environment, 115*(8), 1978–1996. https://doi.org/10.1016/j.rse.2011.04.001

© 2025 Demirel.