

Saf Kızılçam (*Pinus brutia* Ten.) Meşcerelerinde Topraküstü Biyokütle ile Yaprak Alan İndeksi Arasındaki İlişkilerin Modellenmesi: Sarıayla Orman İşletme Şefliği Örneği

Modeling the Relationship Between Aboveground Biomass and Leaf Area Index in Pure Turkish Red Pine (*Pinus brutia* Ten.) Stands: A Case Study from Sarıayla Forest Planning Unit

Serkan YAYLA¹ , Alkan GÜNLÜ^{2*} 

¹ Orman Genel Müdürlüğü, Ağaçlandırma Dairesi Başkanlığı, Ağaçlandırma Şube Müdürlüğü, Ankara

² Çankırı Karatekin Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü, Orman Amenajmanı Anabilim Dalı, Çankırı

Eser bilgisi/Article info

Araştırma makalesi / Research article

DOI: 10.17474/artvinofd.1676490

*Sorumlu yazar/Corresponding author

Alkan GÜNLÜ

e-mail: alkangunlu@karatekin.edu.tr

Gönderilme tarihi/Submission date

15.04.2025

Kabul tarihi/Acceptance date

23.12.2025

Yayınlanma tarihi/Publication date

28.02.2026

Anahtar kelimeler:

Sentinel-2

Regresyon analizi

Orman kaynakları

Keywords:

Sentinel-2

Regression analysis

Forest resources

Öz

Bu çalışma, Mersin Orman Bölge Müdürlüğü'ne bağlı Anamur Orman İşletme Müdürlüğü, Sarıayla Orman İşletme Şefliği sınırları içerisinde yayılış gösteren saf kızılçam (*Pinus brutia* Ten.) meşcerelerinde gerçekleştirilmiştir. Çalışma kapsamında toplam 257 adet örnek alandan elde edilen envanter verileri kullanılmıştır. Her bir örnek alanın topraküstü biyokütle (TÜB) değeri, Şahin (2015) tarafından saf kızılçam meşcereleri için geliştirilmiş olan tek girişli biyokütle denklemi kullanılarak hesaplanmıştır. Envanter verilerine ek olarak, Ocak ayı hariç (yeterli kalitede uydu görüntüsü bulunmadığı için) olmak üzere her ay için Sentinel-2 uydu görüntülerinden yaprak alan indeksi (YAI) raster verileri türetilmiştir. Her bir örnek alan, aylık YAI görüntüleri üzerine coğrafi olarak aktarılmış ve buna bağlı olarak her bir örnek alan için aylık bazda YAI değişkenlerinin maksimum, minimum, ortalama, toplam, değişim aralığı ve standart sapma değerleri hesaplanmıştır. TÜB ile her bir ay ve tüm aylara ilişkin YAI değişkenleri arasındaki ilişkiler çoğul regresyon analizi ile modellenmiştir. Bu kapsamda toplam 12 adet regresyon modeli geliştirilmiştir. Aylara göre geliştirilen modellerde modellerin belirleme katsayısı (R^2) 0,10 ile 0,178 arasında değişirken, tüm aylara ait verilerin birlikte değerlendirildiği modelde ise R^2 değeri 0,444 olarak bulunmuştur. Elde edilen bulgular, geliştirilen regresyon modellerinin saf kızılçam meşcerelerinde topraküstü biyokütlenin tahmininde potansiyel sunduğunu, ancak model performansının artırılması için daha kapsamlı ve çok yönlü bilimsel araştırmalara ihtiyaç duyulduğunu göstermektedir.

Abstract

This study was conducted in pure Turkish red pine (*Pinus brutia* Ten.) stands within the boundaries of Mersin Regional Directorate of Forestry, Anamur Forest Enterprise, Sarıayla Forest Planning Unit. Data from a total of 257 sample plots were utilized in the analysis in the study. The aboveground biomass (AGB) of each sample plot was estimated using a single-entry biomass equation developed specifically for pure Calabrian pine stands by Şahin (2015). In addition to inventory data, monthly raster datasets of Leaf Area Index (LAI) were produced using Sentinel-2 satellite imagery, excluding the month of January (due to the lack of sufficiently high-quality imagery). Each sample plot was geographically overlaid onto the monthly LAI images, and for each month, statistical variables including maximum, minimum, mean, total, range, and standard deviation of LAI were calculated for every sample plot. The relationships between AGB values and the LAI-derived variables (both every month and across all months) were modeled using multiple regression analysis. In total, 12 regression models were developed. The coefficient of determination (R^2) values of the monthly models ranged from 0.10 to 0.178, while the model incorporating data from all months yielded a substantially higher R^2 value of 0.444. The findings suggest that the developed regression models hold potential for estimating aboveground biomass in pure *Pinus brutia* stands; however, further comprehensive and multidisciplinary research is required to enhance model performance and applicability.

GİRİŞ

Günümüzde yenilenebilir doğal kaynaklar arasında orman biyokütlesi, sürdürülebilir kalkınma ve çevresel denge açısından kritik öneme sahiptir (Alemdağ 1981). Biyokütle; bir ağacın gövde, dal, yaprak, kabuk ve kök gibi bileşenlerinden elde edilen toplam kütle; diğer bir ifadeyle, bir meşceredeki bireylerin tamamının oluşturduğu canlı bitkisel kütleyi ifade etmektedir (Sun ve ark. 1980). Orman ekosistemlerinde biyokütle; madde döngüsü, karbon stoku, yıllık karbon yutak kapasitesi ve biyoenerji potansiyelinin hesaplanmasında temel parametrelerden biridir (Saraçoğlu 1988).

Fosil yakıt rezervlerinin azalması, enerji fiyatlarındaki dalgalanmalar ve fosil yakıt kullanımının küresel karbon emisyonlarını artırması gibi nedenlerle, biyokütle gibi yenilenebilir enerji kaynaklarına olan ilgi her geçen gün artmaktadır (Saraçoğlu 1988). Bu bağlamda, ormanların küresel karbon döngüsüne katkıları ve iklim değişikliğinin etkilerinin azaltılmasındaki rolleri göz önünde bulundurularak, orman biyokütlesinin ve depoladığı karbonun doğru bir şekilde belirlenmesi uluslararası düzeyde önemli bir araştırma alanı hâline gelmiştir (Vogt 1991, Brown 2002, Peichl ve Arain 2007).

Biyokütlenin belirlenmesinde çeşitli yöntemler kullanılmaktadır. Bunlar arasında birim alan yöntemi, orta ağaç yöntemi, regresyon analizleri, BEF katsayıları ve özellikle son yıllarda gelişen teknolojik imkânlar sayesinde yaygınlaşan uzaktan algılama teknikleri yer almaktadır (Brown 2002, Sakıcı ve ark. 2004, Peichl ve Arain 2007, Günlü ve ark. 2014). İlk üç yöntem doğrudan arazi ölçümlerine dayanırken, uzaktan algılama temelli yaklaşımlar biyokütle tahminini dolaylı olarak, geniş alanlar için daha ekonomik ve pratik bir şekilde gerçekleştirme olanağı sunmaktadır (Lu ve Batistella 2005, Baccini ve ark. 2008). Uydu görüntüleri, hava fotoğrafları ve sayısal yükseklik modelleri gibi verilerle desteklenen bu yöntemler, örnek alanlardan elde edilen arazi verilerinin uzaktan algılama değişkenleriyle ilişkilendirilmesini esas alır. Böylece yoğun iş gücü, yüksek maliyet ve zaman gerektiren geleneksel ölçüm yöntemlerine kıyasla daha verimli çözümler üretilebilmektedir (Özdemir ve Karnieli 2011, Günlü ve ark. 2014, Günlü ve Ercanlı 2020, Turgut ve Günlü 2022, Aksoy ve Günlü 2025).

Uzaktan algılama teknolojileri sayesinde; arazi kullanım değişimlerinin izlenmesi, yangın sonrası alanların güncel durumlarının belirlenmesi, meşcere parametrelerinin tahmini ve geniş alanlara ilişkin orman envanteri verilerinin elde edilmesi mümkün hâle gelmiştir. Nitekim meşcere hacmi, göğüs yüzeyi ve ağaç sayısı gibi klasik meşcere parametrelerinin yanı sıra, özellikle biyokütle ve karbon stoku gibi parametrelerin uydu görüntülerinden elde edilen bant reflektans, vejetasyon indeksleri ve tekstür gibi spektral veriler aracılığıyla modellenmesine yönelik çalışmalar hız kazanmıştır (Lu ve Batistella 2005, Baccini ve ark. 2008, Özdemir ve Karnieli 2011, Günlü ve ark. 2014, Sakıcı ve Günlü 2018, Günlü ve Ercanlı 2020, Turgut ve Günlü 2022, Bulut 2023, Bulut ve ark. 2023, Şahan ve Günlü 2024, Demir ve Günlü 2024, Aksoy ve Günlü 2025).

Yaprak Alan İndeksi (YAI), meşcere kapalılığı, fotosentez kapasitesi, su döngüsü, enerji akışı ve karbon dengesinin belirlenmesinde önemli bir biyofiziksel değişkendir. Güneş enerjisinin biyokütleyle dönüşmesinde etkili olan aktif yaprak yüzey alanını temsil eden YAI, karasal ekosistemlerin verimliliğiyle doğrudan ilişkilidir (Atwell ve ark. 1999, Tuzet ve ark. 2003).

YAI'nin doğrudan ölçümü her ne kadar yüksek doğruluk sunsa da uygulama zorluğu, zaman ve maliyet gibi nedenlerle geniş alanlara uygulanması çoğu zaman mümkün olmamaktadır. Bu sebeple, dolaylı yöntemlerle ve özellikle uzaktan algılama verileri kullanılarak YAI tahminine yönelik çalışmalara literatürde sıkça rastlanmaktadır (Running ve ark. 1999, Boyd ve ark. 2000, Chen ve ark. 2002, Colombo ve ark. 2003, Berterretche ve ark. 2005, Heiskanen 2006, Günlü ve ark. 2017, Bulut ve ark. 2021, Yer 2021, Günlü ve Bulut 2023, Aksoy 2023).

Türkiye'de konu ile ilgili yeterli çalışma olmaması nedeniyle, Sentinel-2 uydu görüntüsüne ait zaman serileri verisinden hesaplanan YAI değişkenleri kullanılarak TÜB tahmini yönelik böyle bir çalışma yapılması önem arz etmiştir. Bu bağlamda, bu çalışmada Mersin Orman Bölge Müdürlüğü, Anamur Orman İşletme Müdürlüğü, Sarıayla Orman İşletme Şefliği sınırları içerisinde yayılış gösteren saf kızılçam meşcerelerinde, Ocak ayı hariç her ay için Sentinel-2 uydu görüntüsüne ait zaman serisi verilerinden hesaplanan YAI değişkenlerinin, topraküstü biyokütle (TÜB) tahminindeki kullanılabilirliği araştırılmıştır.


Bu doğrultuda, aylık YAI verileri ile TÜB arasındaki ilişkileri modellemek amacıyla her ay için ayrı ayrı 11 adet çoğul regresyon modeli geliştirilmiştir. Ayrıca, tüm aylara ilişkin YAI verilerinin birlikte değerlendirildiği kapsamlı bir model daha oluşturularak, YAI değişkenlerinin biyokütle tahmini açısından tutarlılığı ve açıklayıcılığı değerlendirilmiştir.

MATERYAL VE YÖNTEM

Materyal

Çalışma alanı, Mersin Orman Bölge Müdürlüğü, Anamur Orman İşletme Müdürlüğüne bağlı Sarıayla Orman İşletme Şefliği sınırları içerisinde yer almaktadır. Çalışma alanı 36° 4' 58"-36° 11' 20" kuzey enlemleri ile 32° 37' 7"-32° 48' 50" doğu boylamları arasında yer almaktadır. Çalışma alanının yıllık ortalama yağış miktarı 406,1 mm, ortalama sıcaklığı ise 5,6°C'dir (Anonim 2016). Çalışma alanının coğrafi konumu Şekil 1'de gösterilmiştir.

Bu çalışmada, Sarıayla Orman İşletme Şefliği'ne ait meşcere tipleri haritası, 19.02.2016, 13.03.2016, 19.04.2016, 12.05.2016, 21.06.2016, 18.07.2016, 26.08.2016, 19.09.2016, 16.10.2016, 18.11.2016 ve 08.12.2016 tarihlerine ait Sentinel-2 uydu görüntüleri ile saf kızılçam meşcerelerinden elde edilen toplam 257 örnek alana ait envanter karnesi verileri materyal olarak kullanılmıştır. Ocak ayına ait Sentinel-2 uydu görüntüsünün yüksek oranda bulut içermesi nedeniyle bu görüntü analizlerde kullanılmamıştır.



Şekil 1. Çalışma alanının konumu

Yöntem

Envanter Verilerine İlişkin Değerlendirmeler

Sarıayla Orman İşletme Şefliğinin orman amenajman planının yenilenmesi sürecinde saf kızılçam meşcerelerinden alınan 257 adet envanter karne verileri Orman İdaresi ve Planlama Dairesi Başkanlığı'ndan temin edilmiştir. Örnek alan verileri 2015 yılı Haziran-Ağustos aylarını kapsayan zaman diliminde alınmıştır. Her örnek alanda göğüs çapı 8 cm ve üzerindeki ağaçların göğüs çapı ($d_{1.3}$) değeri kullanılarak her bir ağaç için topraküstü biyokütle (TÜB) (kg) değerleri hesaplanmıştır. Her bir ağacın TÜB değerinin hesaplanmasında Şahin (2015) tarafından saf kızılçam meşcereleri için geliştirilen tek girişli denklem (1) kullanılmıştır. Örnek alandaki ağaçların TÜB değerleri toplanarak, her bir örnek alanın toplam TÜB değeri hesaplanmıştır. Daha sonra örnek alanın büyüklüğü (400, 600 ve 800 m²) bağlı olarak her örnek alanın hektardaki TÜB değeri hesaplanmıştır.

$$\ln y = b_0 + b_1/d_{1.3} + b_2 * \ln(d_{1.3}) \quad (1)$$

Denklemin; $R_{düz}^2=0.957$ ve $S_{y,x}=88.988$

ln: Doğal logaritma

y (kg): Bir ağacın TÜB değeri

$b_0 = -2.80486$, $b_1 = 2.16137$ ve $b_2 = 2.41102$ denklemin katsayılarıdır.

$d_{1.3}$: örnek alan içindeki her bir ağacın göğüs yüksekliğindeki çapı(cm)

$R_{düz}^2$: düzeltilmiş belirtme katsayısı

$S_{y,x}$: tahminin standart hatasını temsil eder.

Sentinel-2 Uydu Görüntüsüne İlişkin Değerlendirmeler

Çalışmada 11 ay (Ocak ayı hariç) için kullanılan Sentinel-2 uydu görüntüleri ücretsiz olarak <https://apps.sentinel-hub.com/> adresinden indirilmiştir. Çalışma alanında farklı meşcere kuruluşları yer almaktadır. Özellikle 1 kapalı meşcerelerin yer aldığı alanlarda ağaçlarla birlikte alt tabakada yer alan diri örtü, taş, ot vb. gibi faktörler uydu görüntüsü üzerinde farklı spektral yansıma değerleri gösterebilmektedir. Uydu görüntülerinden elde edilen spektral yansıma değerleri, atmosferdeki su buharı, aerosol, rayleigh saçılması ve ozon gibi atmosferik bileşenlerden etkilenmektedir. Atmosferik etkiler düzeltilmediğinde bant reflektans değerlerinde sapmalar oluşmakta ve bu durum özellikle farklı kapalılık düzeylerine sahip meşcerelerde gözlenen spektral yansıma farklılıklarının doğru şekilde ortaya konulmasını engellemektedir (Vermote ve ark. 2016, Sola ve ark. 2018). Bu nedenle bu olumsuz etkileri minimum diye indirmek için uydu görüntülerine atmosferik düzeltme yapılmıştır. Böylece, yüksek kapalılığı yüksek meşcerelerde görülen gölge ve doygunluk etkileri ile düşük kapalılığa sahip meşcerelerde zeminin spektral katkısı daha sağlıklı biçimde değerlendirilebilmiştir. Çalışma kapsamında Sentinel-2 uydu görüntüsüne ait 11 ay için elde edilen zaman serili görüntüler kullanılmıştır. Çünkü tek tarihli uydu görüntülerine dayalı modeller, sadece o anki koşulları yansıtırken; zaman serilerine ait veriler ise, mevsimsel değişkenlik, büyüme döngüleri ve yıllık gelişim gibi süreçlerin modellenmesine olanak tanımaktadır (White ve ark. 2017, Nguyen ve ark. 2020). Bu nedenle, bu çalışmada hem aylık uydu görüntülerinden elde edilen veri setleri hem de 11 ay için uydu görüntülerinden elde edilen veri setleri birlikte değerlendirilmiştir. Çalışmada, Sentinel-2 görüntüsüne ait ve konumsal çözünürlüğü 10 m olan bant 2, bant 4 ve bant 8 bantları kullanılmıştır. Sentinel-2 görüntüsüne ait bazı bilgiler verilmiştir (Çizelge 1).

Çizelge 1 Çalışmada kullanılan Sentinel-2 uydu görüntüsüne ait bazı bilgiler

	Bantlar	Dalga boyu (nm)	Konumsal çözünürlük (m)
Sentinel-2	Bant 2 (Mavi)	458 – 523	10
	Bant 4 (Kırmızı)	650 – 680	10
	Bant 8 (Yakın kızıl ötesi)	785 – 900	10

Sentinel-2 uydu görüntüleri analize hazır hale getirmek için bazı ön işlemlere tabi tutulmuştur. Öncelikli olarak Sentinel-2 uydu görüntüleri QGIS Desktop 3.8.1 programı kullanılarak kalibre edilerek Sentinel-2 bant 2, bant 4 ve bant 8 reflektans görüntüleri elde edilmiştir. Daha sonra çalışma alanı sınırına göre görüntüler kesilmiştir.

Uzaktan algılama verileri aracılığıyla LAI tahmini için en yaygın yaklaşımlardan biri, spektral bitki örtüsü indislerinin kullanımına dayanmaktadır. Bu indislerin hesaplamasının basit olması nedeniyle

faydalı bir yaklaşım olarak değerlendirilmektedir (Song 2012, Sun ve ark. 2020). Her bir ay için Liu ve Huete (1995) tarafından geliştirilen ve aşağıda yer alan denklem (2) kullanılarak her bir ay için geliştirilmiş bitki örtüsü endeksi (Enhanced vegetation index) (EVI) indisi hesaplanmıştır.


$$EVI=2.5*\left(\frac{Bant\ 8 - Bant\ 4}{Bant\ 8 + 6 * Bant\ 4 - 7.5 * Bant\ 2 + 1}\right) \quad (2)$$

Her bir ay için EVI görüntüleri kullanılarak ve aşağıda yer alan denklem (3) kullanılarak her bir ay için yaprak alan indeksi (YAI) görüntüleri hesaplanmıştır (Boegh ve ark. 2002, Andalibi ve ark. 2021).

$$YAI = 3.618 * EVI - 0.118 \quad (3)$$

Gerek EVI indisinin gerekse de YAI değerlerinin hesaplanmasında ArcGIS 10.6.1 programı içinde yer alan “raster calculator” modülü kullanılarak yapılmıştır.

Hesaplanan YAI görüntüleri üzerine örnek alanlar atılarak örnek alanlara ilişkin YAI değerleri hesaplanmıştır. Örnek alanların YAI değerlerinin hesaplanmasında örnek alan büyüklüğü dikkate alınmış ve örnek alan büyüklüğüne göre (800 m² için 15.96 m, 600 m² için 13.82 m ve 400 m² için 11.28 m) buffer zon atılmış ve örnek alanlara ilişkin buffer zon içerisindeki YAI değerlerinin maksimum, minimum, ortalama, toplam, değişim aralığı ve standart sapma değişken değerleri hesaplanmıştır (Şekil 2). Bu işlemler için ArcGIS 10.6.1 programı kullanılmıştır.



Şekil 2. Örnek alanlara buffer zon atılması (600 m² büyüklüğündeki örnek alan için)

İstatistiksel Analiz

Örnek alanlara ilişkin hesaplanan topraküstü biyokütle (TÜB) değerleri ile her bir ay için Sentinel-2 uydu görüntülerinden hesaplanan yaprak alan indeksi (YAI) değerleri arasındaki istatistiksel ilişkiler çoğul regresyon analizi ile modellenmiştir. Çoğul regresyon analizinde tahmin edilmek istenen bağımlı değişken TÜB iken, bağımsız değişkenler ise YAI değişkenleri olan maksimum, minimum, ortalama, toplam, değişim aralığı ve standart sapma değerleridir. TÜB'yi, YAI değişkenlerine göre tahmin eden çoğul regresyon model yapısı denklem (4) yer almaktadır.

$$TÜB = \beta_0 + \beta_1 * X_1 + \beta_2 * X_2 + \beta_3 * X_3 + \dots + \beta_n * X_n + \varepsilon \quad (4)$$

Denklemde; TÜB: topraküstü biyokütle, $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ denklem parametrelerini, $X_1, X_2, X_3, \dots, X_n$ Sentinel-2 uydu görüntülerinden her bir ay için hesaplan YAI değişkenleri (maksimum, minimum, ortalama, toplam, değişim aralığı ve standart sapma) ve ε ise model hatasını ifade etmektedir. Çalışmada, her bir ay için çoğul regresyon denklemi geliştirilmiştir. Ayrıca çalışmada bütün aylara ilişkin YAI değişkenleri kullanılarak TÜB'nin tahmin edilmesine yönelik çoğul regresyon denklemi geliştirilmiştir. Sonuç olarak bu çalışmada toplam 12 adet çoğul regresyon modeli geliştirilmiştir.

Regresyon modellerin geliştirilmesinde SPSS istatistik paket programından yararlanılmıştır (SPSS 2007). Çalışma kapsamında toplam 257 adet örnek alan verisi kullanılmıştır. Bu veriler rasgele ikiye ayrılarak, verinin %75'i (n=193) modellerin oluşturulmasında ve %25'i (n=64) ise modellerin test edilmesinde kullanılmıştır. Sentinel-2 uydu görüntüsünden elde edilen verilere bağlı olan farklı bağımsız değişkenlerden, %95 güvenle anlamlı değişkenlerin belirlenmesinde, Aşamalı (Stepwise) değişken seçimi yöntemi kullanılmıştır.

TÜB'nin, her bir ay için Sentinel-2 uydu görüntülerinden hesaplan YAI değişkenleriyle birlikte tahmin edilmesinde istatistiksel olarak anlamlı model seçenekleri belirlenmiştir. Model başarılarının değerlendirilmesinde düzeltilmiş belirtme katsayısı ($R^2_{düz}$) denklem (5) ve standart hata ($S_{y,x}$) ölçütleri denklem (6) dikkate alınmıştır. Bunlara ilişkin formüller aşağıda verilmiştir.

Düzeltilmiş Belirtme Katsayısı:

$$R^2_{düz} = 1 - \frac{(1 - R^2)(N - 1)}{N - p - 1} \quad (5)$$

Tahminin Standart Hatası:

$$S_{y,x} = \sqrt{\frac{\sum (TÜB_i - \widehat{TÜB}_i)^2}{n - p}} \quad (6)$$

Yukarıdaki formüllerde; y_g : ölçülen değeri, y_t : tahmin edilen değeri, y_{og} ölçülen değerlerin ortalamasını, n : veri sayısını, p : parametre sayısını $TÜB_i$: gözlem toprak üstü biyokütleyi, $\widehat{TÜB}_i$: tahmin edilen toprak üstü biyokütleyi göstermektedir.

Geliştirilen çoğul regresyon modellerinden, düzeltilmiş belirtme katsayısı $R^2 (R^2_{düz})$ ve standart hata ($S_{y,x}$) ölçütlerine göre en başarılı model belirlendikten sonra, bu modelin çalışma alanındaki saf kızılçam meşcerelerine uygunluğunun denetimi, toplam örnek alan verisin %25'ni oluşturan 64 örnek alan verisi ile yapılmıştır. Seçilen en iyi modelin denetiminde kullanılan örnek alanların (64 adet) arazide envanter aşamasında elde edilen göğüs çapı değerlerinden hesaplanan TÜB değerleri ile geliştirilen modellerle tahmin edilen TÜB değerleri eşleştirilmiş t testi (Paired t test) kullanılarak karşılaştırılmıştır (Kalıpsız 1984, Batu 1995). İki farklı şekilde elde edilen TÜB değerleri arasında, birincide istatistiksel olarak anlamlı bir farklılık yoksa ($p>0.05$), bu durumda modelin çalışma alanı için uygun olduğu, ikincide ise TÜB değerleri arasında istatistiksel olarak anlamlı bir fark olması durumunda ise ($p<0.05$) uygun olmadığı sonucuna varılabilir. Çalışmanın metodolojisine ilişkin akış diyagramı verilmiştir (Şekil 3).



Şekil 3. Çalışmada kullanılan yöntemle ilişkin iş akış şeması


BULGULAR

Çalışmada 11 ay için geliştirilen regresyon modellerin model belirtme katsayıları oldukça düşük olup (Şubat ayı için 0.178, Mart ayı için 0.131, Nisan ayı için 0.118, Mayıs ayı için 0.123, Haziran ayı için 0.123, Temmuz ayı için 0.143, Ağustos ayı için 0.10, Eylül ayı için 0.148, Ekim ayı için 0.15, Kasım ayı için 0.146 ve Aralık ayı için ise 0.108) 0.10 ile 0.178 arasında değişmektedir. Bu nedenle bu modellere ilişkin model sonuçlarını gösteren çizelgelere burada yer verilmemiştir. Çalışma kapsamında en iyi model sonucunun elde edildiği tüm aylara ilişkin verilerin yer aldığı modele ilişkin sonuçlar verilmiştir (Çizelge 2).


Çizelge 2. Topraküstü biyokütleyi Sentinel-2 tüm aylar (Ocak ayı hariç) için YAI değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
Sabit Katsayısı	57.831	8.088	7.150	0.000
Mart-maksimum	30.451	10.038	3.034	0.003
Nisan-toplam	-2.855	1.356	-2.105	0.037
Mayıs-maksimum	-40.620	11.584	-3.506	0.001
Mayıs-toplam	6.490	1.558	4.167	0.000
Haziran-toplam	-4.039	1.957	-2.063	0.041
Temmuz-standart sapma	-137.394	38.142	-3.602	0.000
Temmuz-toplam	4.536	1.627	2.788	0.006
Ağustos-değişim aralığı	-97.082	30.034	-3.232	0.001
Ağustos-standart sapma	456.525	93.932	4.860	0.000
Ekim-ortalama	35.533	10.265	3.461	0.001
Ekim-toplam	-3.393	1.140	-2.976	0.003
Kasım-değişim aralığı	-25.430	6.769	-3.757	0.000
Aralık-ortalama	-12.066	3.562	-3.387	0.001
$R^2_{düz}=0.444$ $S_{y,x}=19.28036$				

Çizelge 2 incelendiğinde Sentinel-2 tüm aylar için YAI değerlerinin bağımsız değişken olarak yer aldığı modelde, modelin belirtme katsayısı ($R^2_{düz}$) 0.444 olarak bulunmuştur. En iyi tahmin sonucunu veren (Çizelge 2) modele göre tahmin edilen TÜB ile envanter karnelerinden hesaplanan TÜB'ye göre değişimi Şekil 4'te verilmiştir. TÜB'yi en iyi modele göre tahmin eden modelle elde edilen hataların, tahmin edilen TÜB'ye göre değişimi ise Şekil 5'te verilmiştir.



Şekil 4. En iyi regresyon modeline göre hesaplanan TÜB ile tahmin edilen TÜB ilişkisi



Şekil 5. En iyi regresyon modelini esas alan modelle elde edilen hatalar-tahmini TÜB ilişkisi

Eşleştirilmiş t testi sonuçlarına göre en başarılı regresyon modeli (Çizelge 2) için hesaplanan t değeri 0.369 ve p değeri 0.713 bulunmuş, $\alpha=0.05$ önem düzeyinde tahmin edilen TÜB değerleri ile gözlenen TÜB değerleri arasında istatistiksel olarak anlamlı bir fark bulunmamıştır. Diğer bir ifadeyle bu çalışma kapsamında geliştirilen en iyi regresyon modeli, bu modelin geliştirilmesi aşamasında verilerin elde edildiği saf kızılçam meşcereleri için kullanılabilir olduğunu göstermektedir.

TARTIŞMA

Literatür incelendiğinde, genellikle YAI ile meşcere özellikleri arasındaki ilişkilerin araştırıldığı ve uydu görüntülerinden elde edilen çeşitli değişkenler aracılığıyla YAI'nin tahmin edilmesine yönelik çalışmaların ön planda olduğu görülmektedir. Ancak, bu çalışmada olduğu gibi orman ekosistemlerinde TÜB'nin YAI değerlerine göre tahmin edilmesine yönelik çalışmalara Türkiye'de rastlanmamakta, literatürde ise bu konudaki araştırmalar oldukça sınırlı kalmaktadır.

Özbayram ve ark. (2015) tarafından saf kızılçam ve karaçam meşcerelerinde yürütülen çalışmada, dolaylı yöntemle hesaplanan YAI değerleri ile meşcere yaşı, meşcere ağaç sayısı, meşcere üst boyu ve meşcere göğüs yüzeyi gibi meşcere özellikleri arasındaki ilişkiler incelenmiştir. Elde edilen sonuçlara göre, saf kızılçam meşcerelerinde YAI ile meşcere yaşı, ağaç sayısı, üst boy ve göğüs yüzeyi arasında pozitif korelasyon saptanırken; saf karaçam meşcerelerinde ise YAI ile meşcere yaşı ve meşcere orta çapı arasında negatif yönde bir korelasyon belirlendiğini ifade etmiştir.

Ercanlı ve ark. (2018) yaptığı çalışmada, 2014 yılı Ağustos ayında dolaylı yöntemle hesaplanan YAI ile bazı meşcere özellikleri arasındaki ilişkiler incelenmişlerdir. Çalışmada, YAI ile meşcere ağaç sayısı ($r=0.564$), göğüs yüzeyi ($r=0.371$) ve sıklık ($r=0.512$) arasında pozitif; meşcere orta çapı ve yaşı ile

($r=-0.294$) arasında ise negatif bir ilişki bulmuşlardır. Ayrıca, çoğul regresyon analizinde meşcere parametreleri kullanılarak YAI %54.31 oranında tahmin etmişlerdir. Bu çalışmada da yalnızca Ağustos ayına ait Sentinel-2 uydu görüntüsünden elde edilen YAI değeri, TÜB'yi 0.10 düzeyinde tahmin etmiştir. Ancak, yılın tamamına ait YAI değerleri modele eklendiğinde TÜB tahmini 0.444 düzeyine ulaşmıştır. Bu da zamana bağlı YAI değişkenliğinin TÜB tahmini üzerinde etkili olduğunu göstermiştir.

Özellikle Model başarılarının Günlü ve Bulut (2023) tarafından saf karaçam meşcerelerinde gerçekleştirdikleri çalışmada, Haziran-Aralık ayları arasında dolaylı yöntemle hesaplanan YAI değerleri ile Landsat 8, Sentinel-2 uydu görüntülerinden türetilen çeşitli spektral değişkenler ve topoğrafik faktörler (eğim, bakı, yükselti) arasındaki ilişkiler modellendirilmiştir. Araştırmada, YAI'ni tahmin eden en başarılı modelin %93 doğruluk düzeyine ulaştığı belirlenmiştir. Ayrıca, Sentinel-2 görüntülerinden hesaplanan YAI değerleri ile dolaylı yöntemle elde edilen YAI değerleri arasında istatistiksel olarak anlamlı bir fark bulunmadığı ifade etmişlerdir. Aynı çalışmada, topoğrafik değişkenlerin (eğim, bakı ve yükselti) modele dahil edilmesinin, YAI tahmininde geliştirilen modellerin doğruluk düzeyini artırdığı ifade etmişlerdir. Benzer şekilde, Aksoy (2023) tarafından yürütülen çalışmada da Sentinel-2 ve Landsat 8 uydu görüntülerinden hesaplanan YAI değerleri ile dolaylı yöntemle hesaplanan YAI değerleri arasında anlamlı bir fark olmadığı ifade etmiştir.

Bulut ve ark. (2021) tarafından saf karaçam meşcerelerinde yürütülen çalışmada, Haziran-Aralık ayları arasında dolaylı yöntemle hesaplanan YAI değerleri ile çeşitli meşcere özellikleri arasındaki ilişkileri analiz etmişlerdir. Araştırma bulgularına göre, en yüksek model başarımları %64 doğruluk düzeyiyle Temmuz ve Ekim aylarında ölçülen ortalama YAI değerleriyle elde edildiğini ifade etmişlerdir. Yer (2021) tarafından gerçekleştirilen benzer bir çalışmada, saf karaçam meşcerelerinde YAI ile meşcere parametreleri arasındaki ilişkiler korelasyon analizi ile değerlendirilmiştir. Elde edilen sonuçlar, YAI ile meşcere orta çapı, göğüs yüzeyi, ağaç sayısı, bonitet indeksi, meşcere sıklığı ve tepe biyokütlesi arasında pozitif yönde anlamlı ilişkilerin bulunduğunu ifade etmiştir. Aynı çalışmada, söz konusu meşcere özelliklerinin bağımsız değişken olarak kullanıldığı çoğul regresyon modelinde YAI'nin %63.1 doğrulukla tahmin edildiği ifade edilmiştir.

Uluslararası literatürde de benzer bulgulara rastlanmaktadır. Xin ve ark. (2018) ve Parker (2020), farklı orman ekosistemlerinde YAI ile toplam üst biyokütle (TÜB) arasında anlamlı düzeyde korelasyon bulunduğunu ortaya koymuşlardır. Ma ve ark. (2014) ve Gonçalves ve ark. (2020) ise yüksek TÜB'ye sahip ormanların genellikle daha geniş bir yaprak alanına ve dolayısıyla daha yüksek YAI değerlerine sahip olduğunu ifade etmişlerdir. Albaugh ve ark. (1998), *Pinus taeda* plantasyonlarında YAI'nin gövde hacmi büyümesindeki varyasyonun %93'ünü, toplam biyokütledeki varyasyonun ise %87'sini açıkladığını ortaya koymuştur.

SONUÇ VE ÖNERİLER

Saf kızılçam (*Pinus brutia* Ten.) meşcerelerinden alınan örnek alanlara ait TÜB değerleri ile, Ocak ayı hariç yılın her bir ayına ait Sentinel-2 uydu görüntülerinden hesaplanmış YAI değişkenleri arasındaki ilişkiler, çoğul regresyon analizi yöntemiyle modellenmiştir. Her bir aya ilişkin geliştirilen regresyon modellerinin istatistiksel sonuçları incelendiğinde, model performanslarının genel olarak düşük

düzeyde kaldığı gözlemlenmiştir. Aylık bazda elde edilen modellerin model belirtme katsayısı ($R^2_{düz}$) 0.10 ile 0.178 arasında değişkenlik göstermektedir. En yüksek model belirtme katsayısı Şubat ayına ait modele ait olup ($R^2_{düz}$) =0.178 olarak bulunmuşken, en düşük katsayı ise Ağustos ayına ait modelde ($R^2_{düz}$) =0.10 olarak bulunmuştur. Buna karşılık, yılın tüm aylarına ait YAI değişkenlerinin birlikte değerlendirildiği çok değişkenli modelde, modelin açıklayıcılık düzeyi belirgin şekilde artmış ve model belirtme katsayısı ($R^2_{düz}$) =0.444 olarak bulunmuştur. Bu sonuç, TÜB ile YAI değişken değerleri arasındaki ilişkilerin modellenmesi sonucunda elde edilen model sonuçları değerlendirildiğinde özellikle aylara ilişkin elde edilen model sonuçlarının düşük olduğu buna karşın tüm aylara ilişkin YAI değişken değerlerinin birlikte değerlendirildiği modelde model başarısının artığı görülmüştür.

Gelecekte gerçekleştirilecek benzer çalışmalarda, YAI verilerinin yanı sıra topoğrafik değişkenlerin (yükselti, eğim, bakı vb.) modellerde bağımsız değişken olarak kullanılmasının, TÜB'nin tahmininde model performansını artıracığı öngörülmektedir. Bununla birlikte gelecekte yapılacak çalışmalarda YAI değişkenleri ile LİDAR, SAR, RADAR vb. farklı uydu görüntülerinden elde edilen değişkenlerin birlikte kullanılmasıyla TÜB'nin tahminine yönelik daha başarılı model sonuçları elde edilebilir.

Ayrıca, derin öğrenme, destek vektör makineleri, yapay sinir ağları, rasgele orman gibi gelişmiş makine öğrenmesi algoritmalarının uygulanması ile TÜB tahminlerinin doğruluğunun daha da iyileştirilebileceği düşünülmektedir. Bu çalışmadan elde edilen bulgular, konuya ilişkin ileride yapılacak araştırmalara katkı sunabilecek nitelikte olup, benzer araştırmalar için bilimsel bir temel altlık teşkil etmektedir.

TEŞEKKÜR/BİLGİLENDİRME

Bu çalışmada kullanılan envanter karnesi verileri ve orman amenajman planının temininde verdikleri destekten dolayı Orman Genel Müdürlüğü Orman İdaresi ve Planlama Dairesi Başkanlığı'na teşekkür ederiz. Bu çalışma, Çankırı Karatekin Üniversitesi, Fen Bilimleri Enstitüsü, Orman Mühendisliği Anabilim dalında hazırlanan "Saf kızılçam meşcerelerinde topraküstü biyokütle ile yaprak alan indeksi arasındaki ilişkilerin modellenmesi (Sarıayla Orman İşletme Şefliği Örneği)" başlıklı yüksek lisans tezinden üretilmiştir.

KAYNAKLAR

- Aksoy H (2023) Sinop Orman Bölge Müdürlüğü saf sarıçam meşcerelerinde farklı uzaktan algılama verileri kullanılarak bazı meşcere parametrelerinin modellenmesi. Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, Orman Mühendisliği Anabilim Dalı, Çankırı, 172 s.
- Aksoy H, Günlü A (2025) UAV and satellite-based prediction of aboveground biomass in scots pine stands: a comparative analysis of regression and neural network approaches. *Earth Science Informatics*, 18(1): 1–24. <https://doi.org/10.1007/s12145-024-01657-0>
- Albaugh TJ, Allen HL, Dougherty PM, Kress LW, King JS (1998) Leaf area and above- and belowground growth responses of loblolly pine to nutrient and water additions. *Forest Science*, 44: 317–328. <https://doi.org/10.1093/forestscience/44.2.317>
- Alemdağ İŞ (1981) Aboveground-mass equations for six hardwood species from natural stands of the research forest at Petawawa. Canadian Forestry Service Information Report, PI-X-6, Canada.
- Andalibi L, Ghorbani A, Moameri M, Hazbavi Z, Nothdurft A, Jafari R, Dadjou F (2021) Leaf area index variations in ecoregions of Ardabil province, Iran. *Remote Sensing*, 13(15):2879. <https://doi.org/10.3390/rs13152879>
- Anonim (2016) Mersin Orman Bölge Müdürlüğü, Anamur Orman İşletme Müdürlüğü, Sarıayla Orman İşletme Şefliği, Fonksiyonel Orman Amenajman Planı. Orman Genel Müdürlüğü, Orman İdaresi ve Planlama Dairesi, Ankara.
- Atwell BJ, Kriedeman PE, Turnbull GN (1999) Plants in Action: Adaptation in Nature, Performance in Cultivation (s. 664). Macmillan, Avustralya.

- Baccini A, Laporte N, Goetz SJ, Sun M, Dong H (2008) A first map of tropical Africa's above-ground biomass derived from satellite imagery. *Environmental Research Letters*, 3: 045011. <https://doi.org/10.1088/17489326/3/4/045011>
- Batu F (1995) Uygulamalı istatistik yöntemler. Karadeniz Teknik Üniversitesi Orman Fakültesi Genel Yayın No: 179, Fakülte Yayın No: 22, Trabzon.
- Berterretche M, Hudak AT, Cohen WB, Maiersperger TK, Gower ST, Dungan J (2005) Comparison of regression and geostatistical methods for mapping leaf area index (LAI) with Landsat ETM+ data over a boreal forest. *Remote Sensing of Environment*, 96: 49–61. <https://doi.org/10.1016/j.rse.2005.01.014>
- Boegh E, Soegaard H, Broge N, Hasager CB, Jensen NO, Schelde K, Thomsen A (2002) Airborne multispectral data for quantifying leaf area index nitrogen concentration and photosynthetic efficiency in agriculture. *Remote Sensing of Environment*, 81(2–3):179–193. [https://doi.org/10.1016/S0034-257\(01\)00342-X](https://doi.org/10.1016/S0034-257(01)00342-X)
- Boyd DS, Wicks TE, Curran PJ (2000) Use of middle infrared radiation to estimate the leaf area index of a boreal forest. *Tree Physiology*, 20:755–760. <https://doi.org/10.1093/treephys/20.11.755>
- Brown S (2002) Measuring carbon in forests: current status and future challenges. *Environmental Pollution*, 16:363–372. [https://doi.org/10.1016/S02697491\(01\)00212-3](https://doi.org/10.1016/S02697491(01)00212-3)
- Bulut S, Günlü A, Sönmez MY (2021) Saf karaçam meşcerelerinde yaprak alan indeksi ile meşcere parametreleri arasındaki ilişkilerin modellenmesi. *Bartın Orman Fakültesi Dergisi*, 23(3): 980–989. <https://doi.org/10.24011/barofd.1002569>
- Bulut S (2023) Machine learning prediction of above-ground biomass in pure calabrian pine (*Pinus brutia* Ten.) stands of the Mediterranean region, Türkiye. *Ecological Informatics*, 74: 101951. <https://doi.org/10.1016/j.ecoinf.2022.101951>
- Bulut S, Günlü A, Çakır G (2023) Modelling some stand parameters using Landsat 8 OLI and Sentinel-2 satellite images by machine learning techniques: a case study in Türkiye. *Geocarto International*, 38 (1): 2158238. <https://doi.org/10.1080/10106049.2022.2158238>
- Chen JM, Pavlic G, Brown L, Cihlar J, Leblanc SG, White HP, Hall RJ, Peddle DR, King DJ, Trofymow JA, Swift E, Van Der Sanden J, Pellikka PKE (2002) Derivation and validation of Canada-wide coarse-resolution leaf area index maps using high-resolution satellite imagery and ground measurements. *Remote Sensing of Environment*, 80:165–184. [https://doi.org/10.1016/S00344257\(01\)00300-5](https://doi.org/10.1016/S00344257(01)00300-5)
- Colombo R, Bellingeri D, Fasolini D, Marino CM (2003) Retrieval of leaf area index in different vegetation types using high resolution satellite data. *Remote Sensing of Environment*, 86:120–131. [https://doi.org/10.1016/S0034-4257\(03\)00094-4](https://doi.org/10.1016/S0034-4257(03)00094-4)
- Demir S, Günlü A (2024) Sentinel-2 uydu görüntüsü kullanılarak saf kavak meşcerelerinde meşcere hacmi ve göğüs yüzeyinin tahmin edilmesi. *Anadolu Orman Araştırmaları Dergisi*, 10(2):78–86. <https://doi.org/10.53516/ajfr.1558255>
- Ercanlı İ, Günlü A, Şenyurt M, Keleş S (2018) Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey. *Forest Ecosystems*, 5: 1–12. <https://doi.org/10.1186/s40663-018-0149-8>
- Gonçalves AO, Da Silva EHFM, Gasparotto LG, Rosa JM, do Carmo S, Júnior IMF, Marin FR (2020) Improving indirect measurements of the leaf area index using canopy height. *Pesqui. Agropecu. Bras.*, 55:1–9. <https://doi.org/10.1590/s16783921.pab2020.v55.01894>
- Günlü A, Ercanlı İ, Başkent EZ, Çakır G (2014) Estimating aboveground biomass using Landsat TM imagery: a case study of Anatolian Crimean pine forests in Turkey. *Annals of Forest Research*, 57(2):289–298. <https://doi.org/10.15287/afr.2014.278>
- Günlü A, Keleş S, Ercanlı İ, Şenyurt M (2017) Estimation of leaf area index using WorldView-2 and Aster satellite image: a case study from Turkey. *Environmental Monitoring and Assessment*, 189:1–11. <https://doi.org/10.1007/s10661-017-6254-2>
- Günlü A, Ercanlı İ (2020) Artificial neural network models by ALOS PALSAR data for aboveground stand carbon predictions of pure beech stands: a case study from northern of Turkey. *Geocarto International*, 35(1):17–28. <https://doi.org/10.1080/10106049.2018.1499817>
- Günlü A, Bulut S (2023) Modeling leaf area index using time-series remote sensing and topographic data in pure Anatolian black pine stands. *International Journal of Environmental Science and Technology*, 20(5):5471–5490. <https://doi.org/10.1007/s13762-022-04552-7>
- Heiskanen J (2006) Estimating aboveground tree biomass and leaf area index in a mountain birch forest using ASTER satellite data. *International Journal of Remote Sensing*, 27(6):1135–1158. <https://doi.org/10.1080/01431160500353858>
- Kalıpsız A (1984) Dendrometri. İstanbul Üniversitesi Orman Fakültesi Yayınları, İÜ Yayın No: 3194, OF Yayın No:354, İstanbul, 407 s.
- Liu Q, Huete A (1995) A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. *IEEE T. Geosci. Remote Sens.*, 33 (2):457–465. <https://doi.org/10.1109/TGRS.1995.8746027>
- Lu D, Batistella M (2005) Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. *Acta Amazonica*, 35(2): 249–257. <https://doi.org/10.1590/S0044-59672005000200015>
- Ma H, Song J, Wang J, Xiao Z, Fu Z (2014) Improvement of spatially continuous forest LAI retrieval by integration of discrete airborne LiDAR and remote sensing multi-angle optical data. *Agric. For. Meteorol.*, 189–190:60–70. <https://doi.org/10.1016/j.agrformet.2014.01.009>
- Nguyen TH, Jones S, Soto-Berelov M, Haywood A, Hislop S (2020) Landsat time-series for estimating forest aboveground biomass and its dynamics across space and time: a review. *Remote Sens.*, 12(1):98. <https://doi.org/10.3390/rs12010098>
- Özbayram AK, Çiçek E, Yılmaz F (2015) Kızılcım ve Karaçam meşcerelerinde yaprak alanı indeksi (YAI) ile bazı meşcere özellikleri arasındaki ilişkiler. *Kastamonu University Journal of Forestry Faculty*, 15(1):78–85. <https://doi.org/10.17475/kuofd.23267>
- Özdemir İ, Karnieli A (2011) Predicting forest structural parameters using the image texture derived from worldview-2 multispectral imagery in a dryland forest, Israel. *International Journal of Applied Earth Observation and Geoinformation*, 13: 701–710. <https://doi.org/10.1016/j.jag.2011.05.006>
- Parker GG (2020) Tamm review: leaf area index (LAI) is both a determinant and a consequence of important processes in vegetation canopies. *Forest Ecology and Management*, 477: 118496. <https://doi.org/10.1016/j.foreco.2020.118496>

- Peichl M, Arain MA (2007) Allometry and partitioning of above and belowground tree biomass in an age-sequence of white pine forests. *Forest Ecology and Management*, 253: 68-80. <https://doi.org/10.1016/j.foreco.2007.07.003>
- Running S, Baldocchi D, Gower S, Bakwin P, Hibbard K (1999) A global terrestrial monitoring network integrating tower fluxes, flask sampling, ecosystem modeling and EOS data. *Remote Sensing of Environment*, 70:108-127. [https://doi.org/10.1016/S00344257\(99\)00061-9](https://doi.org/10.1016/S00344257(99)00061-9)
- Sakıcı OE, Ercanlı İ, Kahrıman A (2004) Klasik biyokütle tahmin yöntemleri ve yeni yaklaşımlar. *Kafkas Üniversitesi Artvin Orman Fakültesi Dergisi*, 3-4: 165-171.
- Sakıcı OE, Günlü A (2018) Artificial intelligence applications for predicting some stand attributes using Landsat 8 OLI satellite data: a case study from Turkey. *Appl Ecol Env Res.*, 16(4):5269-5285. https://doi.org/10.15666/aeer/1604_52695285
- Saraçoğlu N (1988) Kızılağaç (*Alnus glutinosa* var. *barbata* (C. A. Mey.) Ledeb.) gövde hacim ve biyokütle tablolarının düzenlenmesi. Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, Trabzon.
- SPSS (2007) SPSS Base 270 User's Guide. 770 s.
- Sola I, García-Martín A, Sandoñ-Pozo L, Álvarez-Mozos J, Pérez-Cabello F, González-Audícana M, Llovería RM (2018) Assessment of atmospheric correction methods for Sentinel-2 images in Mediterranean landscapes. *International Journal of Applied Earth Observation and Geoinformation*, 73:63-76. <https://doi.org/10.1016/j.jag.2018.05.020>
- Song C (2012) Optical remote sensing of forest leaf area index and biomass. *Progress in Physical Geography*, 237: 98-113. <https://doi.org/10.1177/03091333124713>
- Sun O, Uğurlu S, Özer E (1980) Kızılçam türüne ait biyolojik kütlenin saptanması. OAE Teknik Bülten, No:104, Ankara.
- Sun Y, Qin Q, Ren H, Zhang T, Chen S (2020) Red-edge band vegetation indices for leaf area index estimation from Sentinel-2/MSI imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 58: 826-840. <https://doi.org/10.1109/TGRS.2019.2940826>
- Şahan E, Günlü A (2024) Aktif ve pasif uydu görüntüleri kullanarak saf karaçam meşcerelerinde topraküstü karbonun tahmin edilmesi. *Bartın Orman Fakültesi Dergisi*, 26(4):377-391. <https://doi.org/10.24011/barofd.1544831>
- Şahin A (2015) Mersin yöresi saf kızılçam (*Pinus brutia* Ten.) meşcerelerinde hasılat araştırmaları. Artvin Çoruh Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, Artvin.
- Turgut R, Günlü A (2022) Estimating aboveground biomass using Landsat 8 OLI satellite image in pure Crimean pine (*Pinus nigra* JF Arnold subsp. *pallasiana* (Lamb.) Holmboe) stands: a case from Turkey. *Geocarto International*, 37(3): 720-734. <https://doi.org/10.1080/10106049.2020.1737971>
- Tuzet A, Perrier A, Leuning R (2003) A coupled model of stomatal conductance, photosynthesis and transpiration. *Plant, Cell and Environment*, 26(7):1097-1116. <https://doi.org/10.1046/j.13653040.2003.01035.x>
- Vermote E, Justice C, Claverie M, Franch B (2016) Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. *Remote Sensing of Environment*, 185: 46-56. <https://doi.org/10.1016/j.rse.2016.04.008>
- Vogt K (1991) Carbon budgets of temperate forest ecosystems. *Tree Physiology*, 9:69-86. <https://doi.org/10.1093/treephys/9.1-2.69>
- White JC, Wulder MA, Hermosilla T, Coops NC, Hobart GW (2017) A nationwide annual characterization of 25 years of forest disturbance and recovery for Canada using landsat time series. *Remote Sens Environ.*, 194:303-321. <https://doi.org/10.1016/j.rse.2017.03.035>
- Xin Q, Dai Y, Li X, Liu X, Gong P, Richardson AD (2018) A steady-state approximation approach to simulate seasonal leaf dynamics of deciduous broadleaf forests via climate variables. *Agricultural and Forest Meteorology*, 249:44-56. <https://doi.org/10.1016/j.agrformet.2017.11.025>
- Yer MB (2021) Kastamonu yöresi karaçam meşcerelerinde yaprak alan indeksi ile çeşitli meşcere özellikleri arasındaki ilişkilerin belirlenmesi. Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, Kastamonu.