

Toprak Organik Karbonu Ölçek Küçültme İşlemi İçin Farklı Makine Öğrenmesi Algoritmalarının Karşılaştırılması: Kahramanmaraş/Ekinözü İlçesi Örneklem Alanı

Comparison of Different Machine Learning Algorithms for Soil Organic Carbon (SOC) Downscaling Process: Kahramanmaraş/Ekinözü District Sampling Area

Esin KARAMANLI*¹ 

*¹Çukurova Üniversitesi, Mimarlık Fakültesi Peyzaj Mimarlığı Bölümü, Adana

Eser Bilgisi / Article Info

Araştırma makalesi / Research article

DOI: [10.17474/artvinofd.1638494](https://doi.org/10.17474/artvinofd.1638494)

*Sorumlu yazar/Corresponding author

Esın KARAMANLI

e-mail: esin.karamanli@gmail.com

Geliş tarihi / Received

12.02.2025

Düzeltilme tarihi / Received in revised form

22.07.2025

Kabul tarihi / Accepted

27.07.2025

Elektronik erişim / Online available

15.10.2025

Anahtar kelimeler:

Toprak organik karbonu
Konumsal ölçek küçültme
Çevresel ortak değişkenler
Dijital toprak haritalama
Makine öğrenmesi

Keywords:

Soil organic carbon
Spatial downscaling
Environmental covariates
Digital soil mapping
Machine learning

Özet

Bu çalışma son zamanlarda dijital toprak haritalama alanında öne çıkan makine öğrenmesi algoritmalarının, çevresel ortak değişkenlere dayalı konumsal ölçek küçültme işlemi model performanslarının karşılaştırmasını sağlamak üzere kurgulanmıştır. R-Studio 4.4.2 ortamında gerçekleştirilen model denemeleri Kahramanmaraş'ın Ekinözü ilçesi idari sınırları içerisinde kalan alanı kapsamaktadır. 250 m çözünürlüğe sahip toprak organik karbonu katmanı tüm çalışma alanı için 30 m konumsal çözünürlükte düzenlenen çevresel ortak değişkenler (eğim, topografik ıslaklık indeksi, yükseklik, sıcaklık, nisbi nem, net birincil üretim, normalize edilmiş fark vejetasyon indeksi, pankromatik band) kullanılarak 30 m konumsal çözünürlükteki versiyonuna dönüştürülmüştür. Tüm model denemeleri neticesinde doğrusal ve doğrusal olmayan makine öğrenmesi algoritmalarına dayalı modellerin tahmin performansları karşılaştırılmış ve doğrusal olmayan algoritmalarla kurulan modellerin diğerlerine göre oldukça anlamlı bir farkla üstün olduğu görülmüştür. Elde edilen bulgular, Rassal Orman Algoritmasına (ROA) dayalı modelin (RMSE=3.23, MAE=3.88 ve R²=0.69); Yapay Sinir Ağları, Karar Ağaçları ve Destek Vektör makineleri de dahil olmak üzere karşılaştırılan doğrusal olmayan diğer makine öğrenmesi algoritmalarına kıyasla daha üstün bir performans sergilediğini göstermiştir. Bu sonuçlar, Ekinözü ilçesi ve çevresindeki alanlarda toprak organik karbon içeriğinin haritalanması amacı ile yapılacak çalışmalarda ROA'nın potansiyel olarak en uygun istatistiksel araç olduğunu düşündürmektedir.

Abstract

This study aimed to compare the performance of a spatial downscaling model based on environmental covariates with machine learning algorithms, which have recently gained prominence in digital soil mapping. The model trials performed in the R-Studio 4.4.2 environment cover the area within the administrative boundaries of the Ekinözü district of Kahramanmaraş. The soil organic carbon layer at 250 m resolution was converted to the 30 m resolution version by using the environmental covariates (slope, topographic wetness index, digital elevation model, temperature, relative humidity, net primary productivity, normalized difference vegetation index, panchromatic band) arranged for the entire study area at 30 m spatial resolution. As a result of all model trials, the predicted performances of models based on linear and non-linear machine learning algorithms were compared and it was seen that the models established with non-linear algorithms were superior to the others by a significant difference. The findings showed that the Random Forest Algorithm (RFA) based model performed better (RMSE=3.23, MAE=3.88 ve R²=0.69) compared to other nonlinear machine learning algorithm, including Artificial Neural Network (ANN), Decision Trees, and Support Vector Machine (SVM). These results suggest that RFA is potentially the most appropriate statistical tool for the studies to be carried out to map the soil organic carbon content in Ekinözü district and surrounding areas.

GİRİŞ

Toprak Organik Karbonu (TOK), toprakta doğal olarak bulunan bitki ve hayvan kalıntılarının ayrışmasıyla oluşan organik bileşikler içinde depolanan karbonu (Lal 2004, IPCC 2006) ifade eder. Depolanan karbon, toprak kalitesi, verimlilik ve küresel karbon döngüsü açısından kritik bir öneme sahiptir. Bunun en büyük nedeni toprakların en

büyük karasal organik karbon havuzu olmasıdır (Evlıyaoğlu 2019, Jungkunst ve ark. 2022). Türkiye toprakları; jeolojik yapıya, iklim koşullarına, arazi kullanımı ve yönetimine bağlı olarak farklı miktarlarda TOK içermektedir (ÇEM 2018). IPCC (2006)'ye göre; topraklardaki organik madde içeriğini izlemek, tahmin etmek ve ölçmek için kullanılan teknikler, Hükümetlerarası İklim Değişikliği Paneli (IPCC) envanter

raporu kapsamında kullanılan “Arazi Kullanımı, Arazi Kullanımı Değişikliği ve Ormancılık için İyi Uygulama Klavuzu (GPG-LULUCF)” referans alınarak hesaplanmalıdır (Mirici 2017). Bu klavuza göre karbon (C) içeriği, silindirik toprak kesitlerinin (Tier 1 varsayımına için 30 cm, Tier 2 varsayımı için 30 cm üzeri derinlikte) laboratuvar ortamlarında analiz edilmesi ile elde edilmekte ve çeşitli interpolasyon yöntemleri ile noktasal veri setleri konumsal veriye dönüştürülmektedir (IPCC 2003). Geniş çalışma alanları için yeterli sayıda toprak kesiti temin etmenin zorluğu (Kılıç ve ark. 2022, Karamanlı 2024) sebebiyle, az sayıda örneklem noktası ile gerçekleştirilen interpolasyon denemeleri düşük konumsal çözünürlükte ve doğrulukta TOK altlıkları üretmesine neden olmaktadır.

Birleşmiş Milletler Çölleşme ile Mücadele Sözleşmesi 12. Taraflar Konferansında (UNCCD COP12), 2030 yılına kadar ülkelerin gönüllü olarak belirttikleri Arazi Tahribatının Dengelenmesi (ATD) hedefleri için izlenmesi gereken 3 küresel göstergeden (Arazi Örtüsündeki Değişiklikler, Toprak Verimliliği Dinamikleri ve Toprak Organik Karbonu) biri TOK olarak belirlenmiştir (ÇEM 2018). İklim değişikliğinin hafifletilmesi açısından, diğer karbon-bazlı sera gazları gibi topraktaki organik karbon serbest kalır ise bu durum büyük ölçüde kendi kendini güçlendiren TOK-İklim etkileşimine yol açacaktır (Jungkunst ve ark. 2022). Bu etkileşimde, karbonun havada serbest dolaşımındaki artış, güneşten dünyaya gelen ışınların hapsolmesine neden olarak küresel ısınma etkisinin güçlenmesine yol açmaktadır (Akın 2006). Bu nedenle toprak organik karbon stok miktarının belirlenmesi, zamansal ve konumsal değişimlerin neden olduğu stok kayıplarının bertaraf edilmesi, optimal arazi kullanım dönüşüm stratejileri ile mevcut kapasitelerinin artırılması, sürdürülebilir arazi kullanım eylemlerinin geliştirilebilmesi için oldukça önemlidir. Bu kapsamda gerçekleştirilen en önemli çalışma Çölleşme ve Erozyonla Mücadele Genel Müdürlüğü (ÇEM) tarafından hazırlanan “Türkiye Toprak Organik Karbonu Projesi Teknik Özeti” ile paylaşılmıştır. Bu rapor ile Türkiye için hazırlanan 250 m konumsal çözünürlüğe sahip TOK stok altlığı paylaşılmıştır. Ancak 250 m çözünürlüğe sahip TOK stok altlıklarının, son zamanlarda arazinin karbon tutumu ve diğer ekosistem servislerine dayalı sürdürülebilir yönetimine çözüm olarak geliştirilen arazi kullanım tahsis

optimizasyonu problemlerinin çözümlemesinde (Wu ve ark. 2018, Huang ve ark. 2021, Chen ve ark. 2023) belirleyici parametre olarak kullanılması ve ilgili politikaların gelişimine katkı sağlaması (O’Rourke ve ark. 2015) uygun görülmemektedir. Genetik algoritma, parçacık sürü optimizasyonu, benzetilmiş tavlama, karınca kolonisi optimizasyonu vb. algoritmalara dayalı olarak çözümlenen bu problemlerde genel olarak kabul edilen konumsal çözünürlük 10 m, 25 m veya 30 m olarak belirlenmektedir (Liu ve ark. 2012). Bu durum ülkemiz için hazırlanan TOK altlıklarının daha yüksek çözünürlüğe sahip versiyonlarının hazırlanmasını gerekli kılmaktadır. İlgili literatürde ölçek küçültme (downscaling) olarak adlandırılan bu dönüşüm süreci (Roudier ve ark. 2017) farklı konumsal ölçeklerde toprağa karakter kazandıran değişkenler tarafından kontrol edilebilmektedir (Aşkın ve ark. 2014). Arazinin bitki örtüsü, iklim, topoğrafya ve fiziksel-kimyasal-biyolojik diğer toprak özellikleri gibi TOK içeriği ile doğrusal bir ilişkiye sahip olmayan (Kılıç ve ark. 2022) değişkenleri, Makine Öğrenmesi (ML) modelleri ile yüksek doğruluklu çözümlenmelere olanak tanımaktadır. Böylelikle, hassas ölçekli değerlerin kaba ölçekli değerlerin açıklayıcısı olduğu varsayılarak, belirlenen ölçekte varyasyonunun restorasyonu gerçekleştirilir (Hong ve ark. 2011). Süreç istenilen çözünürlükte mevcut bilgiyi (bağımsız değişken kümesi) kullanarak kaba çözünürlüklü verinin (bağımlı değişken) hassas çözünürlüğe indirgenmesi olarak da adlandırılır.

İlgili literatürde, Lineer Regresyon (Pahlavan ve ark. 2017), Rastgele Orman Algoritması (Liaw ve Wiener 2002), Yapay Sinir Ağları, Destek Vektör Makinaları (Tripathi ve ark. 2006), Elastik Net Regresyon (Vandal ve ark. 2019), Lasso Regresyon (He ve ark. 2019), Karar Ağaçları (Nourani ve ark. 2019) ve Ridge Regresyon (Cannon 2008) dijital toprak haritalama ve diğer alanlarda farklı tür verilerin ölçek küçültme işlemleri için kullanılmış ve başarılı sonuçlar elde edilmiştir. Gelişmiş ML algoritmalarının jeostatistik biliminde kullanımının yaygınlaşması, toprak örnekleri ile konumsal bağımlılık gösteren, örnekleme yapılmamış nokta ve alanlarda tahmin performanslarının gelişmesine ve dolayısıyla ölçek küçültme işlemlerinin başarı yüzdelerinin artmasına neden olmaktadır. Ancak birçok farklı ML algoritmasının bulunması ve indikatör olarak kullanılan çevresel ortak

değişken kümesinin çalışma alanlarının karakteristik yapısına dayalı olarak değişkenlik gösterebilmesi, ölçek küçültme işlemleri için model kurulum aşamalarını belirsizliklerle dolu-karmaşık süreçlere dönüştürebilmektedir. Bu sebeple Türkiye'nin farklı bölgelerinde TOK stok altlıklarının daha hassas çözümlülüklerde hazırlanmasına olanak tanıyan ölçek küçültme denemelerin nispeten küçük çalışma alanları için gerçekleştirilmesi, ulusal ölçekte ideal model ve değişken kümelerinin belirlenebilmesi için önemli görülmektedir. Bu doğrultuda Kahramanmaraş'ın Ekinözü ilçesinin çalışma alanı olarak belirlendiği bu çalışmanın amaçları:

- Örneklem alanı ve yakın çevresinde gerçekleştirilebilecek TOK altlığı ölçek küçültme işlemleri için ideal bağımsız değişken (temsili veri seti) grubunu belirlemek,
- Jeostatistiksel tabanlı modellemelerde yüksek doğruluk skorları ile öne çıkan ML algoritmalarının performanslarını karşılaştırarak ideal model yaklaşımını bulmaktır.

YÖNTEM

Çalışma Alanı

Kahramanmaraş il merkezine 173 kilometre, Elbistan ilçe merkezine ise 20 kilometre uzaklıkta konumlanan (Vikipedi 2025) Ekinözü ilçesi 37°09'15"- 36°09'15" Kuzey-Güney boylamları ve 37°12'13"- 36°16'86" Doğu-Batı enlemleri arasında yer almaktadır (Şekil 1). Doğusunda Nurhak, batısında Göksun, kuzeyinde Elbistan ve güneyinde Çağlayancerit ilçeleri ile çevrelenmiştir. İç Anadolu ve Doğu Anadolu bölgelerinin tipik özellikleri gösteren (TCKV 2025); yazları sıcak ve kurak, kışları soğuk ve kurak "Bozkır iklimi" etkindir (Yavuz 2023). 1200 metre rakımda bulunan ilçe, sınırları içerisinde 17 köy, 77 mezra barındırmaktadır. Tarım, mera, yerleşim alanları, orman arazileri, sulak alanlar-su yüzeyle ve çıplak yüzey alanları ile Türkiye topraklarının en fazla TOK içeriğini bünyesine barındıran 6 farklı arazi örtüsü-arazi kullanım türüne (ÇEM 2018) sahip olan ilçe, 692 km² alana yayılmıştır (TCKV 2025).



Şekil 1. Ekinözü İlçesi Çalışma Alanı- Ülke/il Sınırları İçerisindeki Konumu

Veri Seti

Literatürde toprak organik karbonu ile gerçekleştirilen bazı ölçek küçültme işlemleri incelenerek bu çalışmalarda kullanılan çevresel ortak değişkenler (TOK' u temsil eden bağımsız değişken kümesi) belirlenmiştir. Muñoz-Rojas ve ark. (2013) çalışmalarında kaba çözünürlüklü toprak organik karbonunun tanımlayıcıları olarak hassas çözünürlüklü sıcaklık, yükseklik, eğim, nem ve drenaj altlıklarını analizlerine dahil etmişlerdir. Roudier ve ark. (2017) normalize edilmiş fark vejetasyon indeksi (NDVI), topografik ıslaklık indeksi (TWI), dijital yükseklik modeli (DEM), eğim, net birincil üretim (NPP) ve potasyum altlıklarını, Bechini ve ark. (2011) ortalama yıllık sıcaklık, toprak-su içeriği ve toprağın işlenme türünü çalışmalarına entegre etmişlerdir. Xu ve ark. (2017) ise çalışmalarında pankromatik uzaktan algılama spektral indisinin toprak tahmin modellerinde potasyum ve azotun indikatörü olarak kullanılabilirliğini ve aralarında yüksek bir korelasyon bulunduğunu belirtmişlerdir. Bu sebeple, bu

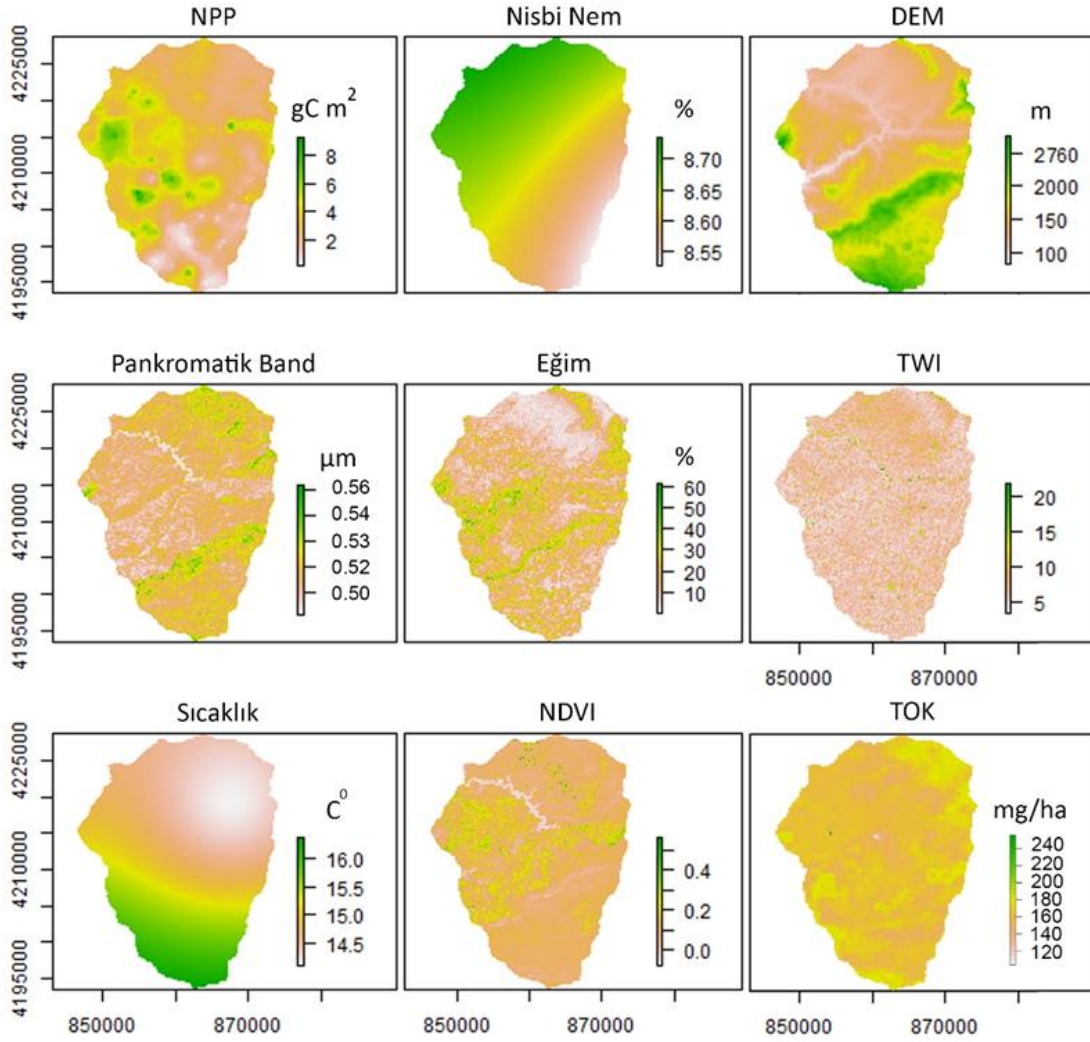
çalışmada toprak organik karbon verisinin çevresel ortak değişkenleri olarak 30 m çözünürlüklü TWI, NDVI, pankromatik band, yükseklik, nispi nem, sıcaklık ve NPP indikatörleri kullanılarak ölçek küçültme işlemi gerçekleştirilmiştir. Burada NPP, küresel ve bölgesel ölçekte karbon dinamiklerinin dağılımı ve ekosistem performansı için en önemli göstergedir. Birim alan ve zamana düşen yeşil bitkilerin fotosentezi ile ototrofik solunumu değerleri arasındaki fark olarak tanımlanır. Aynı zamanda birim alan ve zamana bitki biyokütlesine kazandırılan net karbon miktarını ifade eder (Dönmez 2012). TWI, arazi yükseklik modeli, akış yönü ve akış birikim düzeyi ile ilişkili olarak toprak nem içeriğini ifade eden indekstir (Kopecký ve ark. 2021). NDVI ise herhangi bir alanda yer alan bitki örtüsünün yoğunluğu, sağlıklı veya sağlıklı olmama durumunu ortaya koyan indekstir (Goward ve ark. 1991). Bu çalışma kapsamında kullanılan TOK verisi ve çevresel ortak değişkenlerin nasıl/nereden temin edildiği Çizelge 1'de belirtilmiştir.

Çizelge 1. Ölçek küçültme işlemi için kullanılan tok verisi ve çevresel ortak değişken kümesi

Veri Türü	Veri Temini
TWI	Kopecký ve ark. (2021)'in çalışmalarında tanımlanan yöntem ile 30 m çözünürlüklü topografik ıslaklık indeksi hazırlanmıştır. (TWI:ln(upslope/tan slope))
NDWI	Landsat 8-9 Operational Land Imager (OLI) Band 4 Red (0.64-0.67 µm) 30 m ve Band 5 Near-Infrared (0.85-0.88 µm) 30 m kullanılarak elde edilmiştir. (NDVI:band 5-band4/band5+band4)
NPP	MODIS/Terra Net Primary Production Gap-Filled Yearly L4 Global 500m SIN Grid V061 verisinin 30 m çözünürlüklü versiyonu elde edilmiştir.
Pankromatik Band	Landsat 8-9 panchromatic 0.50-0.68 micrometers 15m çözünürlüklü band yeniden örneklendirilerek (resample) 30 m çözünürlüğe dönüştürülmüştür.
Eğim	ASTER Global DEM WGS84/GTMV003_N37E036 olarak tanımlı 30 m çözünürlüklü veriden türetilmiştir.
Yükseklik	ASTER Global DEM WGS84/GTMV003_N37E036 olarak tanımlı 30 m çözünürlüklü veriden türetilmiştir.
Sıcaklık	2024 yılı günlük sıcaklık değerlerinin (AccuWeather 2024) ortalamaları ile Ters Mesafe Ağırlıklandırma (Inverse Distance Weighting (IDW)) yöntemi kullanılarak elde edilmiştir.
Nisbi Nem	NASA (2025) aracılığı ile 30 m çözünürlüklü nisbi nem altlığı temin edilmiştir.
TOK	World Soils 250 m Soil Organic Carbon (Esri 2025)

Çizelge 1'de paylaşılan tüm çevresel ortak değişkenler 30 m konumsal çözünürlükte ve özdeş coğrafi referans ile hazırlanarak, farklı veri türleri arasında konumsal tutarsızlıktan kaynaklı sorunların model performansını etkilemesinin önüne geçilmiştir. 250 m çözünürlükteki toprak organik karbon verisi (bağımlı değişken) ise Esri (2025) aracılığı ile temin edilerek ML modellerinin kurulumu için hazır hale getirilmiştir. 30 m konumsal

çözünürlükte hazırlanan NPP, nisbi nem, DEM, pankromatik band, eğim, sıcaklık, NDVI ve NPP çevresel ortak değişkenleri ve 250 m konumsal çözünürlüğe sahip TOK verisi, model eğitimi ve tahmin işlem basamakları için RStudio 4.4.2 ortamına (Şekil 2) entegre edilmiştir.



Şekil 2. Çevresel ortak değişkenler (30 m) ve TOK verisi (250 m)

Model Performanslarının Karşılaştırılması

Doğrusal ve doğrusal olmayan ML algoritmaları (Çizelge 2) kullanılarak kurulan modeller ile en yüksek tahmin performansına sahip 30 m konumsal çözünürlükte TOK verisinin elde edilmesi amaçlanmıştır. Model tahminlerinin geçerli kabul edilebilmesi için veri setinin boyutu Cochran's örneklem sayısı (Woolson ve ark. 1986) ile belirlenmiştir. Ölçek küçültme işlemi model performanslarını etkilenmemesi için çevresel ortak değişkenler ve TOK verisi üzerindeki özdeş konumlu örneklem noktalarından elde edilen veri setinin, Varyans Enflasyon Faktörleri "VIF testi" uygulanarak kontrol edilmiş ve çoklu doğrusallık problemi olup olmadığı incelenmiştir. Tüm veri seti eğitim (%80) ve test (%20)

verisi olarak ayrıştırılmış, ML algoritmaları kullanılarak eğitilen modellerin tahmin performansları test verisi kullanılarak sağlanmıştır. Çizelge 1'de belirtilen çevresel ortak değişkenler (30 m) ve TOK verisi (250 m) Çizelge 2'de belirtilen 8 farklı ML algoritması ile yordanarak model tahminleri incelenmiştir. RStudio 4.4.2 ortamında gerçekleştirilen "VIF testi" ve model denemeleri için her bir model kurulumunda ilgili regresyon türüne ait parametrelerin güncellenmesi ve veri setinin standardize edilip edilmemesi gibi farklılıklarla modellerin farklı versiyonlarına ait tahmin sonuçları elde edilmiştir. En ideal sonuca ulaşmak için gerçekleştirilen denemeler 21 farklı analiz yürütülmesini gerektirmiştir. Bu aşamada kullanılan regresyon türleri ile ilgili özet bilgi Çizelge 2'de paylaşılmıştır.

Çizelge 2. Ölçek küçültme işlemi için kullanılan regresyon türleri

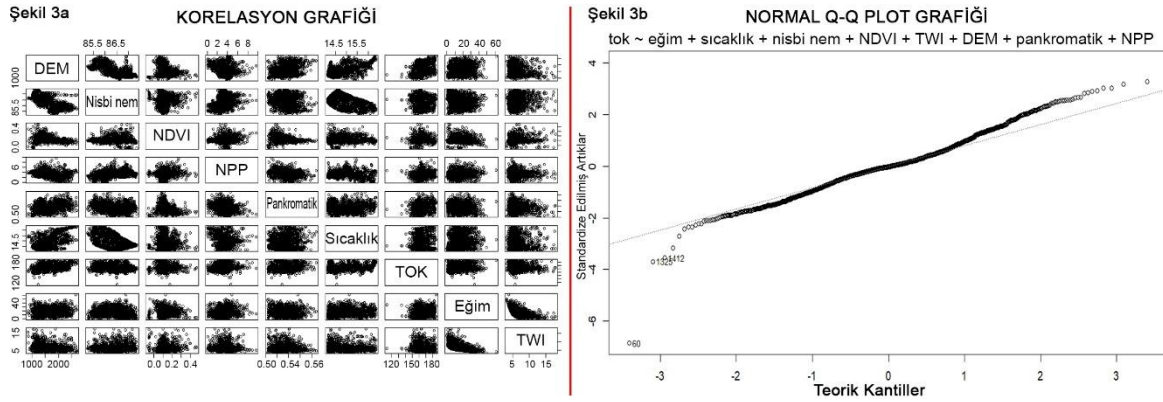
Metot	Açıklama
Ridge Regresyon	Çoklu doğrusal regresyonda sıklıkla ortaya çıkan aşırı öğrenme (overfitting) sorununu çözmek için kullanılan popüler bir tahmin yöntemidir. En küçük kareler yöntemine dayanır (McDonald 2009).
Lasso Regresyon	Değişkenler üstüne ceza terimi uygulanması ile bazı değişkenleri sıfıra indirgeyerek çalışmaktadır (Orhan ve Vergili 2022).
Elastik Net Regresyon	Değişken seçimini ile lineer regresyon için bir düzenleme prosedürüdür. Lasso ve Ridge düzlemlerini birleştirerek kullanır. İki farklı düzlemde terimini karşıladığı için “elastik” adını alır (Hans 2011).
Lineer Regresyon	Doğrusal regresyon “y” olarak isimlendirilen bir bağımlı değişkenle “x” olarak ifade edilen bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modelleme yaklaşımıdır (Kılıç 2013).
Destek Vektör Makinesi	Yüksek hacimli bir eğitim seti ile karşılaştığında farklı sınıflara ait örnekleri birbirinden en iyi şekilde ayıracak doğrusal bir hiper düzlemin bulunmasına yardımcı olan denetimli makine öğrenimi algoritmasıdır (Ayhan ve Erdoğan 2014).
Yapay Sinir Ağları	İnsan beyninin öğrenme ve hızlı karar verebilme gibi yeteneklerinin, basitleştirilmiş modeller yardımıyla karmaşık problemlerin çözümünde kullanılmasını amaçlamaktadır (Ataseven 2013).
Karar Ağaçları	Yoğun hesaplama gerektiren, regresyon problemlerine uygulanabilen yöntemlerden biridir. Geniş bir kayıt koleksiyonunu basitleştirerek küçük kayıtlara böler ve her düğüm için yeni bir karar alarak sonuca ulaştırır (Ercan ve Irmak 2022).
Rassal Orman Algoritması	Ağaç tipi sınıflandırıcılar arasında yer alır. Tüm değişkenler arasından en iyi dalı kullanarak her bir düğümü dallara ayırmak yerine, her bir düğümde rastgele olarak seçilen değişkenler arasından en iyisini kullanarak ayırıştırma sağlar (Akar ve Güngör 2012).

Test verileri ve bu verilere karşılık gelen tahmin değerleri arasında incelenen model performansları, tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkı ifade eden “Ortalama Mutlak Hata” (MAE), hata karelerinin ortalamasının karekökünü ifade eden “Kök Ortalama Kare Hatası” (RMSE) ve bağımlı değişkenin (TOK) bağımsız değişkenler (çevresel ortak değişkenler) tarafından tahmin gücünü ortaya koyan “R-Kare” (R^2) değerleri (Gültekin ve Doğan 2023) karşılaştırılarak incelenmiştir. En düşük RMSE ve MAE değerleri ile en yüksek R^2 değeri en ideal sonuca ulaşmamızı sağlamıştır.

BULGULAR

Çalışma alanının büyüklüğüne dayalı Cochran’s örneklem sayısı 222 olarak hesaplanmıştır. VIF testi neticesinde, her bir değişkenin bir diğer değişken ile kurduğu korelasyon skorları incelendiğinde NDVI ve TWI’nin “ $p=0.1$ ” ve diğer değişkenler için “ $p=0$ ” gözlemlenmiştir. TWI ve NDVI hariç gözlemlenen değerler kabul edilen eşik değerden (0.05) (Akbulut 2022) küçük (p -value<0.05) olduğu için veri setinin şans eseri bir bütün oluşturma olasılığı oldukça

düşük yani anlamlı çıkmıştır. Tüm veri seti için VIF değeri ise “7.41” tespit edilmiştir. Bu değer 10’un altında (Tatlıdil 1992, Albayrak 2008) olduğu için TWI ve NDVI doğrudan veri setinden çıkartılmamış ancak model performanslarını etkileyip etkilemediklerini izlemek için çıkartılarak da denemeler gerçekleştirilmiştir. Model kurulumları öncesi veri setinin normallığı incelenerek (Şekil 3) analize uygun olup olmadığına karar verilmiştir. Şekil 3a ham veri seti içerisindeki değişkenlerin birbirleri ile olan korelasyon ilişkilerini ifade etmektedir. Görsel üzerinde de görüldüğü gibi NDVI ve TWI kare veya dikdörtgene yakın bir dağılım yerine diğer veri türlerine göre daha konik bir dağılım göstermektedir. Veri aralıklarını normal dağılım ile kıyaslayan normal Q-Q plot grafiği ise (Pallant 2024) veri setinin normal dağılıma sahip olup olmadığını görsel olarak ifade etmek için oluşturulmuştur (Şekil 3b). Grafik üzerinde görüldüğü gibi veri setinin önemli ölçüde 45 derecelik referans çizgisi üzerinde normal dağılıma sahip olduğu gözlemlenmiştir. Referans çizgi üzerinde bulunmayan aykırı noktalar (1325, 1412 vb.) veri setinden çıkarılan anomalileri göstermektedir.



Şekil 3. Veri seti içerisindeki korelasyon ilişkileri (3a) ve Normalliğin dağılımı (3b)

Ön işlem aşamaları sonrasında veri setinin bağımsız değişken kümesi ile etkileşimli olarak yürütülen analizleri, aynı model ve farklı parametreler ile farklı doğruluk

değerlerine sahip çözümlere ulaşılmasını sağlamıştır (Çizelge 3).

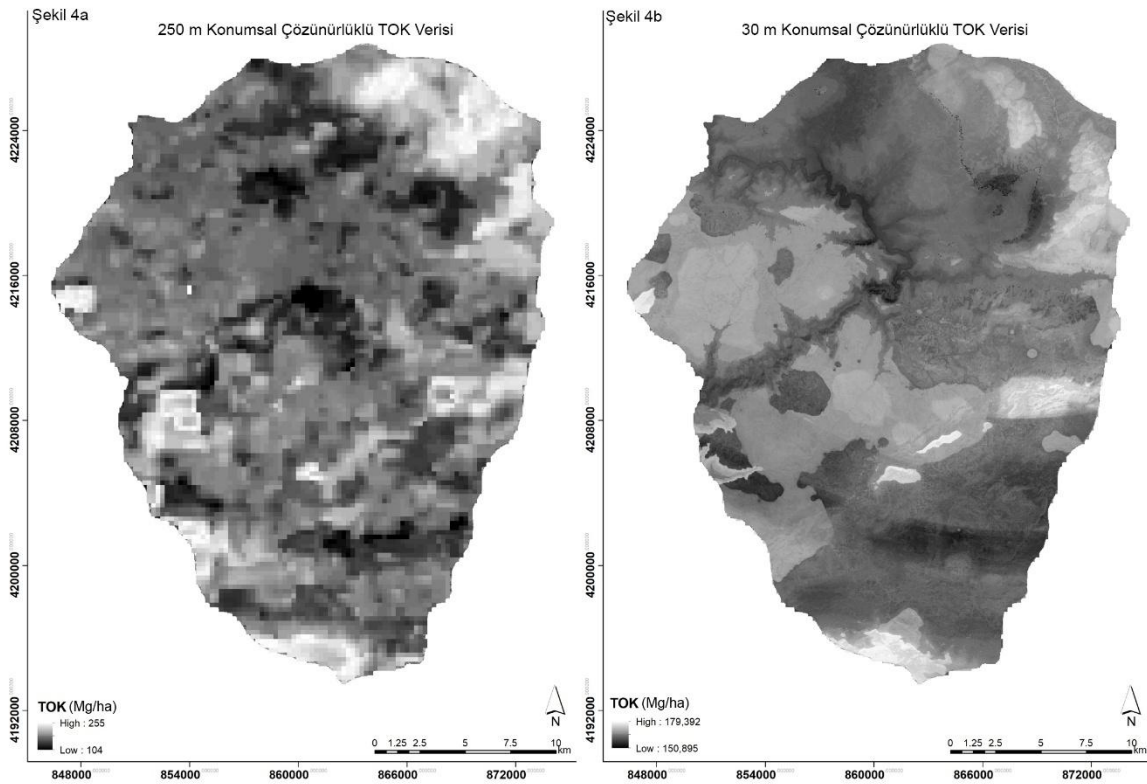
Çizelge 3. TOK Ölçek-Küçültme İşlemi İçin Gerçekleştirilen Model Denemeleri

No	Model	Model Yapısı	RMSE	MAE	R ²	
1		Tüm değişkenler ile	6.66	5.13	0.28	
2	Lineer Regresyon	TWI ve NDVI çıkartılarak (p-value>0.05)	7.34	5.65	0.29	
3		Aykırı değerlerden arındırılarak	7.37	5.69	0.32	
4	Ridge Regresyon-	Veri setine Min-Max dönüşümü uygulanarak tüm değişkenler ile	0.82	0.63	0.31	
5	L2 düzenleme	TWI ve NDVI çıkartılarak	0.82	0.63	0.31	
6	Lasso Regresyon-	Tüm değişkenler	Lambda: 0.01 (ideal lambda)	6.67	5.14	0.34
7	L1 düzenleme	TWI ve NDVI çıkartılarak	Lambda: 0	6.66	5.13	0.34
			Lambda: 0.015 (ideal lambda)	6.75	5.22	0.32
			Lambda: 0	6.74	5.22	0.32
8	Elastik Net Regresyon	Tüm değişkenler	Fitting alpha: 0.123, Lambda: 0.0993	6.74	5.22	0.27
9		TWI ve NDVI çıkartılarak	Alpha: 0.05, Lambda: 0.1	6.74	5,23	0.32
10		Tüm değişkenler	Kernel: radial, cost: 1, gamma: 0.125, epsilon: 0.1	7.49	5.56	0.27
11		Tüm değişkenler	Kernel: linear, cost: 0.5, gamma: 0.125, epsilon: 0.1	6.04	4.30	0.27
12	Destek Vektör Makineleri (SVM Type: eps-regression)	TWI ve NDVI çıkartılarak	Kernel: radial, cost: 1, gamma: 0.125, epsilon: 0.1	6.09	4.39	0.56
13		Tüm değişkenler	Kernel: linear, cost: 1, gamma: 0.125, epsilon: 0.1	7.41	5.50	0.28
14		Tüm değişkenler	Kernel: sigmoid, cost: 1, gamma: 0.125, epsilon: 0.1	87.2	57.3	0.11
15		Tüm değişkenler	Kernel: polynomial, cost: 1, degree: 3, gamma: 0.125 coef: 0, epsilon: 0.1	6.71	4.85	0.43
16		Tüm değişkenler	Kernel: radial, cost: 1, gamma: 0.25, sample metod:5	6.12	4.32	0.57
17	Karar Ağaçları	Tüm değişkenler	rpart () modülü ile method: "anova"	6.35	4.92	0.47
18		TWI ve NDVI çıkartılarak	rpart () modülü ile method: "anova"	4.09	5.38	0.68
19	Rassal Orman Algoritması	TWI ve NDVI çıkartılarak	Method:"repeatedcv", number:10, repeats=3, search:grid, mtry=8 (ideal)	3.23	3.88	0.69
20	Yapay Sinir Ağları	Min-Max dönüşümü uygulanarak		0.86	0.66	0.35
21		Ortalama ve standart sapmaya dayalı standardizasyon işlemi uygulayarak		0.70	0.90	0.30

Not: Modellerde kullanılan ideal Alpha, Lambda ve Mtry değerlerini elde etmek için Cross Validation ((CV)Çapraz Geçerlilik) işlemi uygulanmıştır.

Gerçekleştirilen denemeler neticesinde elde edilen en yüksek doğruluğa sahip model ROA ile (Çizelge 3/Model-19) elde edilmiştir. Bu modelde bağımsız değişkenler arasında kurulan regresyonun gücünü arttırmak için VIF (varyans enflasyon faktörü) değeri izlenerek TWI ve NDVI indikatörü modelden çıkartılmıştır. Böylelikle 0.6910 R² değerine sahip 30 m çözünürlükte TOK altlığı elde edilmiştir. Çizelge 3 üzerinde görüldüğü gibi en yüksek ikinci performansa sahip model ise 0.68 R² değeri ile Karar Ağaçları Algoritmasına aittir. R² değerleri birbirine oldukça yakın olmasına rağmen RMSE ve MAE değerleri

izlendiğinde ROA ile kurulan modelin gerçeğe daha yakın tahmin değerleri oluşturduğu görülmektedir. Bu sebeple Model-19 kullanılarak Ekinözü ilçesine ait 30 m çözünürlüğe sahip TOK altlığı (Şekil 4) elde edilmiştir. Şekil 4 üzerinde yer alan TOK altlıkları karşılaştırıldığında, orijinal TOK (Şekil 4a) yoğunluğunu ifade eden lekelenmelerin ölçek küçültme işlemi neticesinde elde edilen TOK altlığı (Şekil 4b) ile oldukça benzerlik gösterdiği görülmektedir. Bu durum TOK içeriğini temsilen kullanılan indikatör kümesinin toprak özelliklerinin mekânsal dağılımını 0.69 R² oranında temsiline de ifadesidir.



Şekil 4. 250 m (Kaba) (4a) ve 30 m Çözünürlükte Ölçek-Küçültülmüş TOK Verisi (Hassas) (4b)

SONUÇ ve TARTIŞMA

ROA bu çalışmada olduğu gibi toprağın fiziksel ve kimyasal karakteristiğini referans alan tahmin performansına dayalı birçok çalışmada (Grimm ve ark. 2008, Lamichhane ve ark. 2019, Kılıç ve ark. 2022, Reddy ve ark. 2024) diğer ML algoritmalarına göre daha üstün bir performans ortaya koymuştur. Örneğin Zhu ve ark. (2022) topografik indeksler, vejetasyon indeksleri ve toprak indekslerini kullanarak ROA ile diğer ML algoritmalarına göre daha yüksek doğruluğa (validasyon: 0.834) sahip TOK tahmin

modeli elde etmişlerdir. Çalışma sonucu elde edilen tahmin değeri Ekinözü ilçesi için bu araştırma çalışmasında elde edilen tahmin değerine göre önemli derecede yüksek olmasına rağmen burada dikkat edilmesi gereken en önemli husus model bağımsız değişkenlerinin ağırlıklı olarak topografik ve vejetasyon indeksleri ile kurulu olmasıdır. Ancak, bu çalışma kapsamında Model-19 kurulurken TWI ve NDVI indeksleri modelden çıkartılarak tahmin performansında artış sağlanmıştır. Bu durum mera arazilerinin hâkimiyetindeki Ekinözü ilçe arazilerinin genelinde orman varlığının seyrek bir dağılıma

sahip olmasının sonucu olarak görülmektedir. Buradan çıkarımla, model performansları ne kadar yüksek olursa olsun, ölçek küçültme işlemi gibi konumsal çözünürlüğün daha hassas bir versiyonunun elde edilmeye çalışıldığı dijital toprak haritalama tahmin çalışmalarında tahminci bağımsız değişken kümesinin çalışma bölgesine göre özelleştirilmesi oldukça önemlidir. Roudier ve ark. (2017) TOK haritalarının konumsal ölçek küçültme işlemi için model performanslarını karşılaştırdıkları çalışmalarında, 0.94 R² değeri ile ROA model performansının Lineer regresyon ve Kübist regresyona göre daha başarılı tahmin doğruluğu sağladığını tespit etmişlerdir. DEM, TWI, NDVI, potasyum ve Landsat Band 5/7 ve eğim tahminci değişkenlerini baz alarak inceledikleri model denemeleri neticesinde ROA ile model kurulumunun, model performansı ile öne çıkan diğer ML algoritmalarına göre basitliğinin önemli bir avantaj sağladı sonucuna ulaşmışlardır. Zhan ve ark. (2022) ise çalışmalarında TOK verisinin modellenmesi için Kübist regresyon, Ekstrem Gradyan Arttırım ve ROA'nın tahmin performanslarını karşılaştırmış ve en yüksek R² değerini (0.74) ROA ile elde etmişlerdir. Burada kurulan ROA modelinin bu araştırma makalesi kapsamında kurulan Model-19 ile aralarındaki en büyük fark "mtry" parametrelerindeki farklılıktır. "mtry" parametresi karar ağaçları temelli ROA ile kurulan modellerin, belirli bir zamanda dikkate alacağı ikili ağaç bölütlemesine dayalı değişken özelliklerinin sayısını ifade eder. Model-19'un parametre ayarlaması (tuning) sürecinde, "mtry" parametresi için 1 ile 8 arasında çapraz geçerlilik çalıştırılmış ve en ideal tahmin performansına "mtry: 8" ile ulaşılmıştır. Zhan ve ark. (2022)'in 30 adet çevresel yardımcı değişkene ihtiyaç duydukları çalışmalarında ise bu değer "mtry: 13" olarak belirlenmiştir. Bu farkın oluşumunda modele tanıtılan değişkenlerin sayısı oldukça önemli bir rol oynamaktadır. Değişken sayısındaki fazlalığın nedeni, tahmini hedeflenen TOK bilgisinin toprağın 1 m derinlikteki karbon miktarı bilgisini hedeflemesidir. Bu durum 1 m derinlikte değişen toprak profillerinin tanımlayıcıları olarak çok sayıda toprak indeksinin (toprak sıcaklığı, değiştirilmiş toprak bazlı bitki örtüsü indeksi vb.) kullanımına gereksinim duyulmasından kaynaklanmaktadır. Bu araştırma çalışmasında ise 30 cm derinlikteki toprak organik karbon içeriği bilgisine dayalı ölçek küçültme işlemi

hedeflenmiştir. Dolayısıyla ihtiyaç duyulan değişken sayısı ve parametre ayar değerleri farklılık göstermektedir.

Çizelge 3 incelenerek çalışma sonuçları değerlendirildiğinde, bu çalışma kapsamında kurulan model denemeleri ve ilgili literatürde karşılaşılan diğer çalışmalar arasındaki bir diğer ortak çıkarım, doğrusal olmayan ML regresyon algoritmalarının (destek vektör makineleri, rassal orman algoritması, karar ağaçları ve yapay sinir ağları), veri setinin doğrusal düzlemler ile ayrıştırılarak modeli eğittiği doğrusal regresyon algoritmalarına (lineer, elastik net, ridge ve lasso) göre oldukça anlamlı tahminler üretebildiğidir. Bu çalışma kapsamında doğrusal regresyon algoritmaları ile elde edilebilen en ideal model kurulumu Lasso regresyon (Model 6-7 (0.34 R²)) ile sağlanmıştır. Bu durumun nedeni toprak karakteristiği ve çevresel değişkenler arasındaki doğrusal olmayan ilişkileri temsil eden yardımcı değişkenlerin yine doğrusal olmayan veri ayrıştırma/tanımlama teknikleri ile modellerin eğitim (training) başarısını arttırması olarak görülmektedir.

Kahramanmaraş Ekinözü ilçesine ait 250 m çözünürlükteki TOK miktarı bilgisinin, çevresel değişkenlere dayalı ölçek küçültme işlemine tabi tutularak 30 m çözünürlükteki en ideal versiyonunun hedeflendiği bu çalışmada elde edilen model tahmin sonuçları yukarıda ifade edildiği yönleri ile diğer çalışmalarla benzerlik göstermektedir. Gerçekleştirilen birçok çalışmada olduğu gibi ROA ile kurulan ölçek küçültme modeli, TOK içeriğinin çalışma bölgesi kapsamında tahmininde, en iyi tahmin performansını sağladığını ve diğer ML algoritmalarına kıyasla daha başarılı tahmin sonuçları üretebildiğini ortaya koymuştur. Ekinözü ilçesi ve yakın civarındaki diğer çalışma alanları için farklı konumsal çözünürlüklere sahip veri setlerinin daha hassas çözünürlükteki versiyonunu hedef alan benzer amaçlı dijital toprak haritalama çalışmalarında kullanımı oldukça anlamlı kabul edilmektedir.

ÖNERİLER

ML algoritmaları ile gerçekleştirilen ölçek küçültme işlemi model performanslarının başarısı her ne kadar yüksek olursa olsun, %100 veya bu değere yakın tahmin performanslarının gerçekleştirilebilmesi oldukça zordur.

Bu amaçla yürütülen çalışmalarda TOK gibi toplam stok içeriğinin hesaplanabilmesine olanak tanıyan veri türleri için toplam stok içeriği bilgisini koruyan model kurulumlarının gerçekleştirilebilmesi oldukça önemli görülmektedir. Algoritmaların çevresel ortak değişkenleri dikkate alarak bu açığı giderebilmesi, benzer amaçla yürütülen çalışmalarda tahmin ve gerçek değer arasındaki farkı en aza indirecektir. Bu sebeple, gelecekteki çalışmaların bu doğrultuda ilerlemesi önemli görülmektedir.

KAYNAKLAR

- AccuWeather (2024) 2024 Yılı Günlük Sıcaklık Değerleri. URL: <https://www.accuweather.com>, Erişim Tarihi: 05.01.2025.
- Akar Ö, Güngör O (2012) Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 1(2):139-146. <https://doi.org/10.9733/jgg.241212.1t>
- Akbulut O (2022) Bilimsel araştırmalarda istatistiksel anlamlılığın raporlanmasında güncel yaklaşımlar: hatalar ve doğrular. *International Journal of Eastern Mediterranean Agricultural Research*, 5(1):1-19.
- Akın G (2006) Küresel ısınma, nedenleri ve sonuçları. *Ankara Üniversitesi Dil ve Tarih-Coğrafya Fakültesi Dergisi*, 46(2):29-43.
- Albayrak AS (2008) Değişen varyans durumunda en küçük kareler tekniğinin alternatifi ağırlıklı regresyon analizi ve bir uygulama. *Afyon Kocatepe Üniversitesi İİBF Dergisi*, 10(2):111-134.
- Aşkın T, Kızılkaya R, Olekhov V, Mudrykh N, Samafalova I, Türkmen F (2014) Toprak organik karbonu: jeoistatistiksel bir yaklaşım. *Toprak Bilimi ve Bitki Besleme Dergisi*, 2(1):13-18.
- Ataseven B (2013) Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10(39):101-115.
- Ayhan S, Erdoğan Ş (2014) Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 9(1):175-198.
- Bechini L, Castoldi N, Stein A (2011) Sensitivity to information upscaling of agro-ecological assessments: application to soil organic carbon management. *Agricultural Systems*, 104(6):480-490. <https://doi.org/10.1016/j.agry.2011.03.005>
- Cannon AJ (2008) Negative ridge regression parameters for improving the covariance structure of multivariate linear downscaling models. *International Journal of Climatology*, 29:761-769. <https://doi.org/10.1002/joc.1737>
- Chen N, Xin C, Zhang B, Xin S, Tang D, Chen H, Ma X (2023) Contribution of multi-objective land use optimization to carbon neutrality: a case study of Northwest China. *Ecological Indicators*, 157:1-13. <https://doi.org/10.1016/j.ecolind.2023.111219>
- ÇEM (2018) Toprak Organik Karbonu Projesi-Teknik Özet. Çölleşme ve Erozyonla Mücadele Müdürlüğü (ÇEM)-TÜBİTAK-BİLGEM-YTE, Ankara.
- Dönmez C (2012) İklim değişikliğinin etkisi altında Seyhan-üst havzası ekosistem bileşenlerinin modellenmesi ve etkileşim düzeylerinin belirlenmesi. Doktora Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.
- Ercan U, Irmak S (2022) Karar Ağaçları: Algoritmalar, Bölünmeler ve Budama. Endüstride Dijitalleşme Örnekleri. İKSAD Publishing House, No:2014/31220, Ankara.
- Esri (2025) World Soils 250 m Soil Organic Carbon. <https://www.arcgis.com/apps/mapviewer/index.html?layers=55bc9bfbcb2b341fc8b1be3936fe45f06>, Erişim Tarihi: 03.01.2025.
- Evliyaoğlu G (2019) Farklı alan kullanımlarında toprak organik karbon dinamiğinin belirlenmesi. Yüksek Lisans Tezi, Anadolu Üniversitesi Lisansüstü Eğitim Enstitüsü, Eskişehir.
- Goward SN, Markham B, Dye DG, Dulaney W, Yang J (1991) Normalized difference vegetation index measurements from the advanced very high resolution radiometer. *Remote Sensing of Environment*, 35(2-3):257-277. [https://doi.org/10.1016/0034-4257\(91\)90017-Z](https://doi.org/10.1016/0034-4257(91)90017-Z)
- Grimm R, Behrens T, Märker M, Elsenbeer, H (2008) Soil organic carbon concentrations and stocks on Barro Colorado Island- Digital soil mapping using random forests analysis. *Geoderma*, 146(1-2):102-113. <https://doi.org/10.1016/j.geoderma.2008.05.008>
- Gültekin YN, Doğan A (2023) Makine öğrenimi yöntemleriyle bazaltlarda tek eksenli sıkışma dayanımının değerlendirilmesi ve performanslarının karşılaştırılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(2):1059-1074. <https://doi.org/10.29130/dubited.1173624>
- Hans C (2011) Elastic net regression modeling with the orthant normal prior. *Journal of the American Statistical Association*, 106(496):1383-1394. <https://doi.org/10.1198/jasa.2011.tm09241>
- He RR, Chen Y, Huang Q, Kang Y (2019) LASSO as a tool for downscaling summer rainfall over the Yangtze River Valley. *Hydrological Sciences Journal*, 64(1):92-104. <https://doi.org/10.1080/02626667.2019.1570210>
- Hong SH, Hendrickx JMH, Borchers B (2011) Down-scaling of SEBAL derived evapotranspiration maps from MODIS (250 m) to Landsat (30 m) scales. *International Journal of Remote Sensing*, 32(21):6457-6477. <https://doi.org/10.1080/01431161.2010.512929>
- Huang S, Xi F, Chen Y, Gao M, Pan X, Ren C (2021) Land use optimization and simulation of low-carbon-oriented – a case study of Jinhua, China. *Land*, 10(1020):1-18. <https://doi.org/10.3390/land10101020>
- IPCC (2003) IPCC Good Practice Guidance for LULUCF, Chapter 4: Supplementary Methods and Good Practice Guidance Arising from the Kyoto Protocol.
- IPCC (2006) 2006 IPCC Guidelines for National Greenhouse Gas Inventories, Chapter 2: Generic Methodologies Applicable to Multiple Land-Use Categories.
- Jungkunst HF, Göpel J, Horvath T, Ott S, Brunn M (2022) Global soil organic carbon-climate interactions: why scales matter? *WIREs Climate Change*, 13(e780):1-17. <https://doi.org/10.1016/j.catena.2025.109435>
- Karamanlı (2024) Karbon depolama kapasitesine dayalı arazi tahsis optimizasyonu. Doktora Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.
- Kılıç M, Gunal H, Budak M (2022) Toprak organik karbon içeriğinin tahmin ve haritalanmasında makine öğrenmesi tekniklerinin kullanımı. 1st International Conference on Engineering, Natural and Social Sciences, Konya, pp:211-217.
- Kılıç S (2013) Doğrusal regresyon analizi. *Journal of Mood Disorders*, 3(2):90-92.
- Kopecký M, Macek M, Wild J (2021) Topographic wetness index calculation guidelines based on measured soil moisture and plant species composition. *Science of the Total Environment*, 757:1-10. <https://doi.org/10.1016/j.scitotenv.2020.143785>
- Lal R (2004) Soil carbon sequestration impacts on global climate change and food security. *Science*, 304(5677):1623-1627. <https://doi.org/10.1126/science.1097396>
- Lamichhane S, Kumar L, Wilson B (2019) Digital soil mapping algorithms and covariates for soil organic carbon mapping and their implications: a review. *Geoderma*, 352:395-413. <https://doi.org/10.1016/j.geoderma.2019.05.031>
- Liaw A, Wiener M (2002) Classification and regression by random. *Forest. R News*, 2(3):18-22.

- Liu X, Li X, Shi X, Huang K, Liu Y (2012) A multi-type ant colony optimization (MACO) method for optimal land use allocation in large areas. *International Journal of Geographical Information Science*, 26(7):1325-1343. <https://doi.org/10.1080/13658816.2011.635594>
- Mirici (2017) Küresel iklim değişikliği çerçevesinde Doğu Akdeniz bölgesi ekosistem hizmetlerinin karbon temelli modellenmesi. Çukurova Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, Adana.
- McDonald GC (2009) Ridge regression. *WIREs Computational Istatistic*, 1(1):93-100. <https://doi.org/10.1002/wics.14>
- Muñoz-Rojas MM, Jordán A, Zavala LM, González-Peñaloza FA, De la Rosa D, Mejias RP, Anaya-Romeo M (2013) Modelling soil organic carbon stocks in global change scenarios: a CarboSOIL application. *Biogeosciences*, 10:8253-8268. <https://doi.org/10.5194/bg-10-8253-2013>
- NASA (2025) Prediction of Worldwide Energy Resources (POWER)/Data Access Viewer (DAV), Relative Humidity at 2 meters (30 m resolution).
- Nourani V, Razzaghzadeh Z, Baghanam AH, Molajou, A (2019) ANN-based statistical downscaling of climatic parameters using decision tree predictor screening method. *Theoretical and Applied Climatology*, 137:1729-1746. <https://doi.org/10.1007/s00704-018-2686-z>
- Orhan H, Vergili M (2022) Genomik veri setlerinin LASSO ve elastik net regresyon yöntemleri ile analizi. *Süleyman Demirel Üniversitesi Sağlık Bilimleri Dergisi*, 13(3):485-496. <https://doi.org/10.22312/sdusbed.1201417>
- O'Rourke SM, Angers DA, Holden NM, Mcbratney AB (2015) Soil organic carbon across scales. *Global Change Biology*, pp3561-3574. <http://doi.org/10.1111/gcb.12959>
- Pahlavan HA, Zahraie B, Nasserı M, Varnousfaderani AM (2017) Improvement of multiple linear regression method for statistical downscaling of monthly precipitation. *International Journal of Environmental Science Technology*, 15:1897-1912. <https://doi.org/10.1007/s13762-017-1511-z>
- Pallant J (2024) SPSS Kullanma Kılavuzu: IBM SPSS ile Adım Adım Veri Analizi. Anı Yayıncılık, 5. Baskı, Ankara.
- Reddy BBK, Maragatham S, Santhi R, Balachandar D, Vijayalakshmi D, Vasu D, Gopalakrishnan M (2004) Predictive soil mapping using random forest models: applications in pH and soil organic matter assessment. *Plant Science Today*, 11(4):1-12. <https://doi.org/10.14719/pst.3865>
- Roudier P, Malone BP, Hedley CB, Minasny B, McBratney AB (2017) Comparison of regression methods for spatial downscaling of soil organic carbon stocks maps. *Computers and Electronics in Agriculture*, 142:91-100. <https://doi.org/10.1016/j.compag.2017.08.021>
- Tatlıdil H (1992) Uygulamalı Çok Değişkenli İstatistiksel Analiz. Engin Yayınları, ISBN:9759487608, Ankara.
- TCKV (2025) T.C. Kahramanmaraş Valiliği Resmî Web Sayfası, Ekinözü.
- Tripathi S, Srinivas VV, Nanjundiah RS (2006) Downscaling of precipitation for climate change scenarios: a support vector machine approach. *Journal of Hydrology*, 330(3-4):621-640. <https://doi.org/10.1016/j.jhydrol.2006.04.030>
- Vandal T, Kodra E, Ganguly AR (2019) Intercomparison of machine learning methods for statistical downscaling: the case of daily and extreme precipitation. *Theoretical and Applied Climatology*, 137:557-570. <https://doi.org/10.1007/s00704-018-2613-3>
- Vikipedi (2025) Vikipedi Özgür Ansiklopedi, Ekinözü.
- Yavuz Ö (2023) Evaluations and suggestions on wind erosion and windbreaks in the process of climate change in Central Anatolia. *Journal of Environmental and Natural Studies*, 5(1):28-48. <https://doi.org/10.53472/jenas>
- Woolson RF, Bean JA, Rojas PB (1986) Sample size for case-control studies using Cochran's statistic. *Biometrics*, 42(4):927-932. <https://doi.org/10.2307/2530706>
- Wu X, Wang S, Fu B, Liu Y, Zhu Y (2018) Land use optimization based on ecosystem service assessment: a case study in the Yanhe watershed. *Land Use Policy*, 72:303-312. <https://doi.org/10.1016/j.landusepol.2018.01.003>
- Xu Y, Smith SE, Grunwald S, Abd-Elrahman A, Wani SP (2017) Incorporation of satellite remote sensing pan-sharpened imagery into digital soil prediction and mapping models to characterize soil property variability in small agricultural fields. *ISPRS Journal of Photogrammetry and Remote Sensing*, 123:1-19. <https://doi.org/10.1016/j.isprsjprs.2016.11.001>
- Zhan X, Xue J, Chen S, Wang N, Shi Z, Huang Y, Zhuo Z (2022) Digital mapping of soil organic carbon with machine learning in dryland of Northeast and North plain China. *Remote Sensing*, 14(10):1-18. <https://doi.org/10.3390/rs14102504>
- Zhu C, Wei Y, Zhu F, Lu W, Fang Z, Li Z, Pan J (2022) Digital mapping of soil organic carbon based on machine learning and regression kriging. *Sensors*, 22(22):1-18. <https://doi.org/10.3390/s22228997>