







# Turkish Journal of REMOTE SENSING

Türkiye Uzaktan Algılama Dergisi



Vol/Cilt:5  
Issue/Sayı:2  
December/Aralık, 2023

e-ISSN: 2687-4997



## Dergi Hakkında

Türkiye Uzaktan Algılama Dergisi (TUZAL) bilim ve teknolojiadaki gelişmelere paralel olarak Uzaktan Algılama alanındaki yeniliklerle ilgili yapılan çalışmaları yayınlayan ve Uluslararası İndeks ve Veri tabanlarında taranan bir dergidir.

## Amaç & Kapsam

TUZAL Dergisi,

- Uzaktan Algılama alanında ulusal ve uluslararası gelişmeleri Harita, jeoloji, Çevre, Elektrik ve Elektronik, Bilgisayar vb. mühendislik alanı ile ilgilenen bilim insanlarının bilgisine sunmak,
- Konu ile doğrudan veya dolaylı etkinliklerde bulunan bilim insanları, araştırmacılar, mühendisler ve diğer uygulayıcılar arasındaki bilgi ve deneyim paylaşımını güçlendirecek ve hızlandıracak, kolay erişilebilen, geniş katılımlı bir tartışma ortamı sağlamak ve bunları yayma olanağı yaratmak,
- Türkiye'nin teknolojik ve ekonomik kalkınmasında rol oynayabilecek Uzaktan Algılama teknolojisine ilişkin sorunların daha etkin bir şekilde çözüme kavuşturulması açısından büyük önem taşıyan kurumlar arası işbirliğinin başlatılmasına ve geliştirilmesine katkıda bulunmak,
- Türkçe'nin Uzaktan Algılama alanında bilim dili olarak geliştirilmesini ve yabancı sözcüklerden arındırılmasını özendirme amaçlarına sahiptir.

Dergisinin kapsamı;

Temel Uzaktan Algılama Uygulamaları,

RADAR/SAR/LIDAR,

Hiperspektral uzaktan algılama,

Görüntü sınıflandırma ve analiz yöntemleri,

Radyometrik düzeltme için atmosferik modellemenin geliştirilmesi,

Uygu verilerinden elde edilmiş parametrelerin modellenmesi

Küresel modelleme, izleme ve sürdürülebilir kalkınma için küresel veri tabanı ve değişim göstergelerinin belirlenmesi,

Laboratuvar ve yerinde test yöntemleri kullanarak veri ve bilginin kontrolü,

Uzaktan algılama ve CBS yöntemlerinin entegrasyonu,

CBS Uygulamaları,

İnsansız Hava Araçları (İHA) ve Yersel Lazer Tarama ile gözlem uygulamaları,

Havasal ve Uzaysal Uzaktan Algılama

Afet ve risk etkilerinin azaltılması için bilgi desteği: erken uyarı sistemleri, etki değerlendirmesi, izleme, esneklik ve risk azaltma çalışmaları,

Çevre kirliliği: değerlendirme ve etki çalışmaları,

Jeoloji, Jeomorfoloji ve Pedolojide Yeryüzü Bilimi Uygulamalarının ile uzaktan algılanmış girdilerin entegrasyonu,

Sürdürülebilir tarımsal üretim ve tarımın korunması için tarım ürünlerinin büyümesinin çok boyutlu izlenmesi,

İklim değişikliği çalışmaları,

Arazi kullanımı/örtüsünün küresel ve bölgesel dinamikleri, biyo-çeşitlilik, bozulma,

Çölleşme ve kuraklık çalışmaları,

Topraklar, bitki örtüsü ve iç, kıyı ve okyanus sularında karbon akıları,

Su kalitesi çalışmaları vb.

## Yayınlanma Sıklığı

Yılda 2 sayı(Haziran-Aralık)

## ISSN


2687-4997

## WEB

<https://dergipark.org.tr/tr/pub/tuzal>

## İletişim

[osmanorhan@mersin.edu.tr](mailto:osmanorhan@mersin.edu.tr) / [tuzaldergisi@gmail.com](mailto:tuzaldergisi@gmail.com) / [osmanorhan44@gmail.com](mailto:osmanorhan44@gmail.com)



## **About Journal**

Turkish Journal of Remote Sensing publishes studies related to innovation in the field of Remote Sensing parallel to the developments in science and technology and indexed in the International Index and database.

## **Aim & Scope**

The Journal,

- ✚ To present to the knowledge of National and international developments in the field of Remote Sensing to scientists related with Geomatics, Geology, Environment, Electric and Electronic, Computer etc. engineering fields.
- ✚ To provide an easily accessible, broadly attended discussion environment that will strengthen and accelerate the sharing of knowledge and experience between scientists, researchers, engineers and other practitioners who engage in direct or indirect activities with the subject, and create an opportunity to disseminate them,
- ✚ Turkey's technological and economic development in the problems related to remote sensing technology that can more effectively play a role of great importance in terms of inter-agency cooperation to be initiated and resolved to contribute to the development,
- ✚ It has the aim of encouraging the development of Turkish as a scientific language in the field of Remote Sensing and to be free from foreign words.

Scope of The Journal;

- ✓ Basic remote sensing applications,
- ✓ RADAR/SAR/LIDAR,
- ✓ Hyperspectral remote sensing,
- ✓ Image classification and analysis methods,
- ✓ Development of atmospheric modelling for radiometric correction,
- ✓ Determine global database and alteration indicator for global modelling, monitoring and sustainable development,
- ✓ Data and information control using laboratory and in-situ tests,
- ✓ Integration of remote sensing and GIS methods,
- ✓ CBS Uygulamaları,
- ✓ İnsansız Hava Araçları (İHA) ve Yersel Lazer Tarama ile gözlem uygulamaları,
- ✓ Havasal ve Uzaysal Uzaktan Algılama
- ✓ Information utility for reducing disaster and risk effects: Early warning systems, impact evaluation, monitoring, flexibly and risk reducing studies,
- ✓ Environment pollution: Evaluation and effect studies,
- ✓ Integration of Earth science applications in Geology, Geomorphology and Pedology with remote sensing data
- ✓ Multidimensional monitoring of growth of agricultural goods for sustainable agricultural production and protection of agriculture
- ✓ Climate change studies,
- ✓ Land use/ Dynamics of global and regional land, biodiversity, deterioration,
- ✓ Carbon amount in Earth, plant cover and in shore, ocean waters,
- ✓ Water quality studies etc.

## **Publication frequency**

Biannual (June-December)

## **ISSN**


2687-4997

## **WEB**

<https://dergipark.org.tr/tr/pub/tuzal>

## **Contact**

osmanorhan@mersin.edu.tr / tuzaldergisi@gmail.com/ osmanorhan44@gmail.com



## EDİTÖR / EDITOR

**Assoc. Prof. Dr. Osman ORHAN**

Mersin University, Institute of Science / Remote Sensing and Geographic Information Systems  
Mersin, TR

## EDİTÖR YARDIMCILARI / ASSOCIATE EDITORS

**Assist. Prof. Dr. Ahmet Tarık TORUN**

Ankara Hacı Bayram Veli University, Academy of Land Registry and Cadastre  
Ankara, TR

**Assist. Prof. Dr. Resul ÇÖMERT**

Eskişehir Technical University, Earth and Space Sciences Institute  
Eskişehir, TR

## EDİTÖR KURULU / EDITORIAL BOARD

- Prof. Dr. Djamil Al-Halbouni, University of Leipzig, DE
- Prof. Dr. Dursun Zafer ŞEKER, İstanbul Technical University, TR
- Prof. Dr. Enes YİĞİT, Bursa Uludağ University, TR
- Prof. Dr. Ferruh YILMAZTÜRK, Aksaray University, TR
- Prof. Dr. Hacı Murat YILMAZ, Aksaray University, TR
- Prof. Dr. Murat UYSAL, Afyon Kocatepe University, TR
- Prof. Dr. Murat YAKAR, Mersin University, TR
- Prof. Dr. Nebiye MUSAOĞLU, İstanbul Technical University, TR
- Prof. Dr. Ömer MUTLUOĞLU, Konya Technical University, TR
- Prof. Dr. Semih EKERCİN, Necmettin Erbakan University, TR
- Prof. Dr. Taşkın KAVZOĞLU, Gebze Technical University, TR
- Prof. Dr. Uğur AVDAN, Eskişehir Technical University, TR
- Assoc. Prof. Dr. Akif DURDU, Konya Technical University, TR
- Assoc. Prof. Dr. Ali İhsan ŞEKERTEKİN, Iğdır University, TR
- Assoc. Prof. Dr. Benyong WEI, China Earthquake Administration & Key Laboratory of Seismic and Volcanic Hazards, CN
- Assoc. Prof. Dr. Khalil VALIZADEH KAMRAN, University of Tabriz, IR
- Assoc. Prof. Dr. Mehmet Ali DERELİ, Giresun University, TR
- Assoc. Prof. Dr. Mustafa YALÇIN, Afyon Kocatepe University, TR
- Assoc. Prof. Dr. Saygın ABDİKAN, Hacettepe University, TR
- Assoc. Prof. Dr. Sefa YALVAÇ, Gümüşhane University, TR
- Assoc. Prof. Dr. Senem TEKİN, Adıyaman University, TR
- Assoc. Prof. Dr. Süleyman Sefa BİLGİLİOĞLU, Aksaray University, TR
- Assist. Prof. Dr. Lütfiye KARASAKA, Konya Technical University, TR
- Assist. Prof. Dr. Mustafa ÜSTÜNER, Artvin Çoruh University, TR
- Assist. Prof. Dr. Nizar POLAT, Harran University, TR
- Dr. Emre HAVAZLI, NASA, USA
- Dr. Fabiana CALO, Irea Cnr, IT
- Dr. Kaan KALKAN, TÜBİTAK, TR
- Dr. Müge Ünal ÇİLEK, Çukurova University, TR
- Dr. Xiaoli Li, China Earthquake Networks Centre, CN

## DANIŞMA KURULU / ADVISORY BOARD

- Prof. Dr. SZABÓ SZILÁRD, Debrecen University, HU
- Dr. Yaohui LIU, Shandong Jianzhu University, CN
- Prof. Dr. Semih EKERCİN, Necmettin Erbakan University, TR
- Prof. Dr. Ferruh YILDIZ, Konya Technical University, TR
- Prof. Dr. Caner ÖZDEMİR, Mersin University, TR

## TUZAL Dergisi Dil Editörleri / TUZAL Journal Language Editors

**Assist. Prof. Dr. Pınar KARAKUŞ**

Osmaniye Korkut Ata University, Geomatics Engineering /Osmaniye, TR

**Res. Ast. Merve Kolikpınar**

Ardahan University, Department of Turkish Language and Literature / Ardahan, TR

## Mizanpaj

**Assist. Prof. Dr. Hasan Bilgehan MAKİNECİ**

Konya Technical University, Geomatics Engineering /Konya, TR

**Mohammad Maleki**

Kharazmi University / Tehran, IR

# İçindekiler


## Contents

### Araştırma Makaleleri;

### Research Articles;

#### S. No


- 
- 59- *Uzaktan Algılama Teknikleriyle Elde Edilmiş Yükseklik Noktalarının Farklı Yapay Sinir Ağları Yöntemleriyle Tahmini*  
(*Estimation of Elevation Points Obtained by Remote Sensing Techniques by Different Artificial Neural Network Methods*)  
**Vahdettin DEMİR, Ramazan DOĞU**
- 67- *Çok Yüksek Çözünürlüklü Uydu Görüntülerinden Bina Çıkarımında Derin Öğrenme ve Çoklu-Çözünürlüklü Bölütleme Kullanılarak Nesne-Tabanlı Entegrasyon*  
(*Object-Based Integration Using Deep Learning and Multi-Resolution Segmentation in Building Extraction from Very High Resolution Satellite Imagery*)  
**Şaziye Özge ATİK**
- 78- *Sentinel-2A Verileriyle Trabzon İli 2019-2020 Yılları Arasında Ortaya Çıkan Sınıflandırma Farklarının Çeşitli Algoritmalarla Değerlendirilmesi*  
(*Evaluation of Classification Differences Occurring Between 2019-2020 in Trabzon Province with Sentinel-2A Data Using Different Algorithms*)  
**Hasan Bilgehan MAKİNECİ, Esmâ Nur AKOSMAN**
- 89- *Investigation of Position Accuracy in UAVs*  
(*İHA'lardan Elde Edilen Konum Doğruluğunun İncelenmesi*)  
**Ömer YILDIRIM, Cevat İNAL, Sercan BÜLBÜL, Burhaneddin BİLGİN**
- 97- *Kesikköprü Baraj Gölü Havzası Su Kaynaklarına Ait Hassasiyet Haritası*  
(*Sensitivity Map of Kesikköprü Dam Lake Basin Water Resources*)  
**Olcay GÜLÇİÇEK UYSAL, Kağan CEBE**



## Türkiye Uzaktan Algılama Dergisi

<https://dergipark.org.tr/tr/pub/tuzal>

e-ISSN 2687-4997



# Uzaktan Algılama Teknikleriyle Elde Edilmiş Yükseklik Noktalarının Farklı Yapay Sinir Ağları Yöntemleriyle Tahmini

Vahdettin Demir\*<sup>1</sup>, Ramazan Doğu<sup>1</sup>

<sup>1</sup> KTO Karatay Üniversitesi, Doğa Bilimleri ve Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Konya/Türkiye

### Anahtar Kelimeler:

Uzaktan Algılama  
Yükseklik  
Tahmin  
Yapay Sinir Ağları  
Ağrı Dağı

### ÖZ

Bu çalışmanın amacı uzaktan algılama ve yapay sinir ağları yöntemleri kullanarak farklı büyüklüklerdeki alanlar için yükseklik tahmini gerçekleştirmektir. Bu amaçla çok katmanlı yapay sinir ağları (ÇKYSA), radyal tabanlı yapay sinir ağları (RTYSA) ve geliştirilmiş yapay sinir ağları (GRYSA) yöntemleri kullanılmıştır. Çalışmada yükseklik verileri Google-earth pro yazılımı kullanılarak elde edilmiştir. Çalışmada alanı olarak kentsel sınırlar dışında tahmini zor olabilecek dağlık bir bölge olan Ağrı Dağı ve yamaçları seçilmiştir. Çalışmada modeller eğitim ve test setlerine %80 ve %20 oranlarında ayrılmış ve üç farklı kriterine göre bulgular karşılaştırılmıştır. Bunlar karekök ortalama karesel hata, ortalama mutlak hata ve determinasyon katsayısı  $R^2$ 'dir. Çalışma sonuçları incelendiğinde en başarılı tahminlerin iki girişli (X ve Y) GRYSA kullanılarak elde edildiği ve yükseklik noktalarının tahmininde alternatif bir yöntem olarak kullanılabilineceği ortaya konmuştur.

## Estimation of Elevation Points Obtained by Remote Sensing Techniques by Different Artificial Neural Network Methods

### Keywords:

Remote sensing  
Height  
Estimation  
Artificial neural networks  
Mount Ararat

### ABSTRACT

The aim of this study is to perform height estimation for areas of different sizes using remote sensing and artificial neural networks methods. For this purpose, multilayer artificial neural networks (MLANN), radial-based artificial neural networks (RBANN) and generalized artificial neural networks (GRANN) methods were used. Height data in the study were obtained using Google-earth pro software. In the study, Mount Ararat and its slopes, which is a mountainous region that can be difficult to estimate outside the urban borders, were chosen as the area. In the study, the models were divided into training and test sets at 80% and 20% rates, and the findings were compared according to three different criteria. These are root mean square error, mean absolute error, and coefficient of determination  $R^2$ . When the results of the study were examined, it was revealed that the most successful estimations were obtained by using GRYSA with two inputs (X and Y) and it could be used as an alternative method in estimating the height points.

### Makale Bilgileri/Article Info

Geliş / Received: 30/05/2023  
Kabul / Accepted: 05/10/2023  
Yayınlanma / Published: 30/12/2023

### Alıntı/Citation:

Demir V., Doğu, R. (2023). Uzaktan Algılama Teknikleriyle Elde Edilmiş Yükseklik Noktalarının Farklı Yapay Sinir Ağları Yöntemleriyle Tahmini. Türkiye Uzaktan Algılama Dergisi, 5 (2) , 59-66.

## 1. GİRİŞ

Arazi noktalarından üretilmiş sayısal modeller su kaynaklarının yönetimi, kentsel ve kırsal planlama, ulaştırma planlaması, tarım, ormancılık, havza yönetimi, afet risk değerlendirmesi vb. birçok alanda kullanılmaktadır (Çubukçu et al., 2021; Demir & Çubukçu, 2021). Sayısal olarak oluşturulan bu modeller özellikle mühendislik çalışmalarının temel proje altlığını oluşturmaktadır. Bu modeller aracılığıyla yer altı ve yüzey hakkında bilgiler işlenebilir, analiz edilebilir ve görsel olarak sunulabilir. Ancak, arazideki tüm noktaların yüksekliklerini ölçmek zor ve yüksek maliyetlidir. Bu sebepten ötürü arazideki ara noktaların tahmin edilmesi için arazi noktalarının çeşitli teknikler kullanılarak yoğunlaştırması veya eksik verilerin tahmini, yüksek maliyetli işlemlerin hızlı ve ücretsiz olarak yapılmasını sağlamaktadır (Demir & Keskin, 2020).

Son yıllarda literatürde yer alan önemli çalışmalar incelendiğinde Demir ve Keskin (2020), Samsun Mert Nehri Havzası'nda yükseklik tahmini gerçekleştirmişlerdir. Çalışmalarında halihazır haritalarda yer alan poligon noktalarından elde ettiği enlem ve boylam bilgilerini model giriş setinde kullanmışlardır. Modellemelerinde farklı yapay sinir ağı yöntemlerini karşılaştırmışlardır ve en yüksek R<sup>2</sup> değeri (0.948) hem enlem hem de boylam bilgilerinin kullanıldığı giriş setinde ve ÇKYSA yönteminde elde etmişlerdir. Demir ve Çubukçu (2021), benzer çalışma alanında yükseklik noktalarını M5 model ağacı (M5-ağacı) ve çok değişkenli uyarlamalı regresyon eğrileri (MARS) sezgisel regresyon yöntemleri kullanarak tahmin etmişlerdir. Sonuçları doğrusal regresyon yöntemleri ile karşılaştırmışlardır. Çalışma sonucunda M5-tree yönteminin yükseklik modellemesinde başarılı ve alternatif bir yöntem olduğu belirtmişlerdir. Yüzey modelleme ile ilgili literatürde ayrıca bulanık mantık, deterministik ve jeo-istatistiksel yöntemler, matematiksel-teorik yüzeyler üzerinde; polinom, klasik ve esnek hesaplama yöntemlerine dayalı yöntemlerinin kullanımına yönelik çalışmalar da bulunmaktadır (Behzadi & Jalilzadeh, 2020; Çakır, 2013, 2015; Çubukçu et al., 2021; Gümüş & Şen, 2017; Konakoglu et al., 2016; Yenipınar et al., 2021).

Bu çalışmada, dağlık bir bölgede uzaktan algılama ile elde edilen yükseklik noktalarının üç farklı yapay sinir ağları tekniği ile tahmini araştırılmıştır. Çalışmada modeller enlem ve boylam bilgileri kullanılarak eğitilmiş (verilerin %80'i) ve test (verilerin %20'si) edilmiştir. Sonuçlar karşılaştırma kriterlerine göre yorumlanmıştır.

## 2. YÖNTEM

Çalışmada yapay sinir ağları (YSA) yöntemlerinden Çok Katmanlı Yapay Sinir Ağları (ÇKYSA), Genelleştirilmiş Yapay Sinir Ağları (GRYSA), Radyal Tabanlı Yapay Sinir Ağları (RTYSA)

yöntemleri kullanılmıştır. Bu yöntemlerin seçilme nedeni literatürde oldukça geniş çerçevede multi disiplinler çalışmalarda kullanılan ve literatürde iyi bilinen yöntemler olmasının yanı sıra diğer kapalı kutu modellere göre iç yapısının daha fazla biliniyor olması ve modelleme zamanının oldukça hızlı olmasıdır (Çubukçu et al., 2022; Kisi & Demir, 2016).

### 2.1. Çok Katmanlı Yapay Sinir Ağları

ÇKYSA, tek katmanlı YSA'nın doğrusal olmayan problemlerde başarısız olması üzerine geliştirilmiştir (Arı & Berberler, 2017). ÇKYSA'da bilgi girişinin yapıldığı girdi katmanı, bir veya daha fazla gizli (ara) katman ve bir çıktı katmanı bulunmaktadır (Çıtakoğlu & Özeren, 2021; Uray et al., 2019). Tahminlerde girdi değerlerinin her bir "wi" ağırlıklarla çarpılır (Zeybekoglu, 2018). Daha sonra elde edilen bilgiye eşik değeri "b" eklenir. Daha sonra sonuç değer için aktivasyon fonksiyonu uygulanır ve çıktı değeri elde edilir (Yılmaz, 2017). ÇKYSA'da ağırlıkları ayarlamak için kullanılan, Levenberg-Marquardt algoritması kullanılmıştır (Marquardt, 1963). Birçok çalışmada LM fonksiyonunun daha başarılı sonuçlar verdiği görülmüştür (Citakoglu, 2015). ÇKYSA da toplama fonksiyonu Denklem 1'deki gibidir (Çubukçu et al., 2022).

$$NET_{it} = \sum_{k=1}^D A_{kl} C_{tk} + \theta_l \quad (1)$$

$\theta_l$  taraflılık sabiti (bias),  $A_{kl}$  Giriş ve Ara tabakaları arasındaki ağırlıklar kümesi, D girdi vektörünün boyutu,  $C_{tk}$  t örneği için giriş tabakasının çıktı kümesidir. Uygulamada ara tabaka hücre sayısı 1-20 arasında, iterasyon değeri ise 100 olarak seçilmiştir. Bu çalışmada D\_Min\_Max normalizasyonu kullanılmıştır. YSA modelinin uygulanması için tüm veriler 0,2 ile 0,8 arasında normalize edilmiştir (Citakoglu, 2017; Çubukçu et al., 2019).

### 2.2. Radyal Tabanlı Yapay Sinir Ağları

RTYSA'da ara katman hücre sayısı ayarlanabilmektedir ve aktivasyon fonksiyonu olarak Radyal Tabanlı Fonksiyonlar kullanılmaktadır. RTYSA çıktısı, giriş vektörü ile ara katmandaki merkezler arasındaki uzaklığın aktivasyon fonksiyonundan geçirilerek bir çıktı elde edilmesi ve bu çıktının ara katman ile çıkış katmanı arasındaki ağırlıkla çarpılması ve bu çarpımların toplanması ile oluşur (Çetinkaya, 2011). RTYSA da toplama fonksiyonu Denklem 2'deki gibidir.

$$o_j^s(t) = \sum_{i=1}^k w_{ji} \Psi_{ji}(\|x^s - v_i\|) \quad (2)$$

Burada  $x_s$ : s. gözleme ait giriş vektörü,  $w_{ji}$  : i. giriş ile j. radyal tabanlı fonksiyon yapay sinir hücresi arasındaki ağırlık,  $v_i$  : Radyal tabanlı ağdaki i. yapay sinir hücresi merkez vektörü,  $\Psi_i$  : Gizli katmandaki i. aktivasyon fonksiyonu. Gizli katmanda genel olarak aktivasyon fonksiyonu olarak Gaussian fonksiyonu kullanılmaktadır (Kılıç, 2015). Bu çalışmada da Gaussian fonksiyonu kullanılmıştır.

### 2.3. Genelleştirilmiş Regresyon Yapay Sinir Ağı

GRYSA giriş katmanı, örüntü katmanı toplama katmanı ve çıkış katmanı olmak üzere dört katmandan oluşan ileri beslemeli bir YSA modelidir (Oral et al., 2018). Geri beslemeli YSA'lardan farklı olarak GRYSA, iteratif eğitim prosedürü gerektirmemektedir (Specht, 1991). Bağımsız x değişkenine göre bağımlı y değişkeninin regresyonu (Alp & Cıgızoğlu, 2004):


$$y(x) = \frac{\sum_{k=1}^N y_k K(x, x_k)}{\sum_{k=1}^N K(x, x_k)} \quad (3)$$

Burada,  $y(x)$ , x girişinin tahmin değeridir,  $y_k$ , nöron k desen katmanı için aktivasyon ağırlığıdır,  $K(x, x_k)$ , Radyal temel fonksiyon çekirdeğidir (Gaussian kernel).

### 2.4. Uygulama Alanı

Çalışma alanı olarak Iğdır-Ağrı ilinde bulunan Ağrı Dağı seçilmiştir. Bu alanın seçilmesindeki temel amaç dağlık bir alanda araştırmanın gerçekleştirilmesidir. Bu amaçla Türkiye'nin en

yüksek rakıma sahip dağı Ağrı Dağı seçilmiştir (URL-1, 2023). Çalışma alanı Şekil 1'de yer almaktadır.



Şekil 1. Çalışma alanı (Demir & Doğu, 2022)

### 2.5. Veri

Çalışmada tahmin edilen veriler Google Earth Pro kullanılarak elde edilmiştir. Google Earth Pro'da yol ekle seçeneği kullanılarak rastgele noktalar oluşturulmuş ve bu noktalar \*.kmz formatında kaydedilmiştir. Daha sonra bu veriler GPS veri formatına dönüştürülmüştür. Daha sonra bu veriler nokta formatına dönüştürülerek ArcGIS yazılımı ile Excel formatına aktarılmıştır. Excelde her bir nokta enlem boylam yükseklik bilgileriyle kaydedilmiştir. Verilerin elde edilmesiyle ilgili ayrıntılı bilgi için daha önce yazarlar tarafından hazırlanmış bildiri metni incelenebilir (Demir ve Doğu, 2022). Elde edilen veriler ücretsiz bir şekilde temin edilmiş olup, platform üzerindeki tüm alanlar için benzer şekilde temin edilebilmektedir. Uygulama için veri sayısı 3500 olarak sınırlandırılmıştır. Bu verilerin %80'i 2800 adeti eğitim, %20 si 700 adeti ise test aşamasında kullanılmıştır. Aşağıda verilere ait tanımlayıcı istatistiksel bilgiler yer almaktadır.

Tablo 1. Verilere ait istatistiksel bilgiler

Alan (km <sup>2</sup> )	Veri Seti	Değişken (m)	Veri Sayısı	Maksimum Değeri (m)	Minimum Değeri (m)	Ortalama (m)	Standart Sapma	Çarpıklık Katsayısı
1x1	Eğitim	X	2800	44.30	44.29	44.30	0.01	0.05
		Y	2800	39.72	39.71	39.71	0.01	0.23
		H	2800	4777.29	4434.71	4638.73	93.21	-0.11
	Test	X	700	44.30	44.29	44.30	0.01	-0.03
		Y	700	39.72	39.71	39.71	0.01	0.22
		H	700	4777.37	4442.25	4636.28	94.83	-0.09
10x10	Eğitim	X	2800	44.35	44.25	44.29	0.03	0.07
		Y	2800	39.76	39.68	39.71	0.02	0.40
		H	2800	5095.94	2292.61	3769.09	561.94	0.22
	Test	X	700	44.35	44.25	44.30	0.03	0.02
		Y	700	39.76	39.68	39.71	0.02	0.44
		H	700	5091.19	2360.99	3726.94	536.67	0.34
100x100	Eğitim	X	2800	44.79	43.79	44.28	0.30	0.08
		Y	2800	40.11	39.33	39.68	0.22	0.19
		H	2800	4320.79	792.00	1521.43	609.53	0.79
	Test	X	700	44.79	43.79	44.28	0.29	0.10
		Y	700	40.10	39.35	39.66	0.22	0.37
		H	700	4129.71	798.49	1561.11	599.53	0.62



Tablo 1 incelendiğinde, verilerin ortalama 1500 ile 4600 metre aralığında test edildiği enlem ve boylam bilgilerinin standart sapmasının oldukça düşük olmasına rağmen yükseklik verilerinde 600 metrelere varan standart sapmaların olduğu görülmektedir.

## 2.6. Model Performansının Belirlenmesi

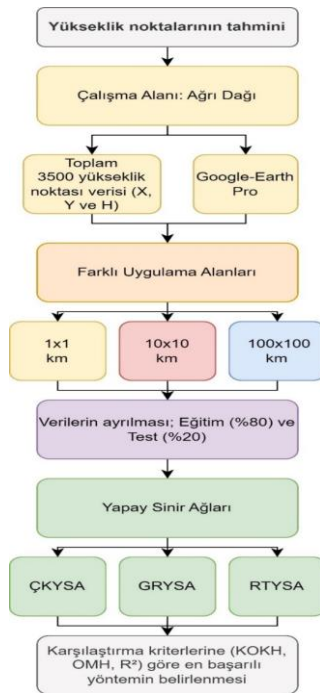
Yapay sinir ağları yöntemleri (ÇKYSA, GRYSA, RTYSA), aşağıda eşitlikleri verilen ve literatürde sıklıkla tercih edilen kriterlere göre karşılaştırılmıştır (Gholami et al., 2018). Bu kriterler sırasıyla, Karekök ortalama karesel hata (KOKH), ortalama mutlak hata (OMH) ve determinasyon katsayısı ( $R^2$ )'dir.

$$KOKH = \frac{1}{n} \sum_{i=1}^n \sqrt{(H_t - H_g)^2} \quad (4)$$

$$OMH = \frac{1}{n} \sum_{i=1}^n |H_t - H_g| \quad (5)$$

$$R^2 = \frac{\sum_{i=1}^n (H_{i,g} - \bar{H}_{i,g})^2 \cdot (H_{i,t} - \bar{H}_{i,t})^2}{\sum_{i=1}^n (H_{i,g} - \bar{H}_{i,g})^2 \cdot \sum_{i=1}^n (H_{i,tahmin} - \bar{H}_{i,t})^2} \quad (6)$$

Denklemlerde H yükseklik değerlerini ifade etmekte olup, gözlenen verileri  $H_g$  ile, tahmin edilen verileri ise  $H_t$  ile temsil etmektedir. n ise veri sayısını göstermektedir. Çalışmaya ait iş akış şeması Şekil 2'de yer almaktadır.



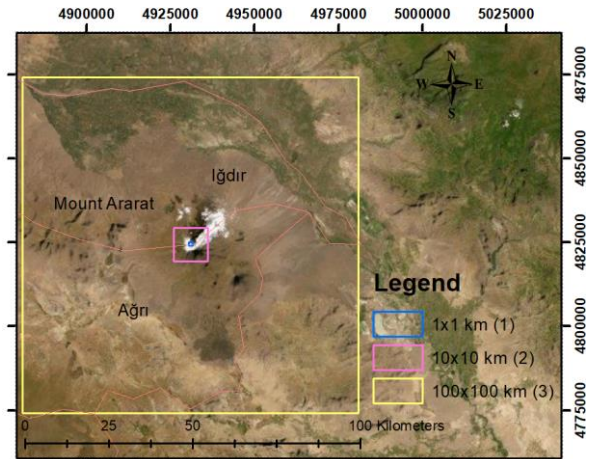
Şekil 2. Uygulama iş akış şeması

## 3. BULGULAR

Çalışmada öncelikle çalışılacak alanlar belirlenmiştir. Bu alanların özelliği tahmini zor dağlık alanlar olmasıdır. Bu amaçla Ağrı ve Iğdır illerimizin bir kısmı içeren Ağrı Dağı'nın olduğu bölge çalışma alanı olarak seçilmiştir. Bu bölgeye ait veriler önce halihazır haritalardan temin edilmesi yönünde girişimde bulunulsa da bölgelerde hali hazır haritanın bulunmaması (genellikle il merkezlerine ait haritalar mevcuttu) nedeniyle uzaktan algılama teknikleriyle elde edilmesi planlanmış ve bu amaçla ücretsiz bir yazılım olan Google Earth Pro kullanılmıştır.

Verilerin temin edilmesinde; ortak sayıda nokta kullanılması, belli bir çerçeve içinde sadece noktaların temin edilmesi, noktaların rastgele elde edilmesi ve farklı büyüklüklerdeki alanlara ait noktaların elde edilmesi hususlarına göre veriler temin edilmiştir.

Çalışmada her bir uygulama alanı için 3500 adet nokta, kare çerçevelerin içinde, rastgele tarama ile, üç farklı büyüklükte alan için elde edilmiştir. Çalışmada araştırılan alanlar; 1x1 km, 10x10 km ve 100x100 km lik kare alanlardır. Şekil 3'te çalışma bölgeleri yer almaktadır.



Şekil 3. Uygulama alanları (Demir & Doğu, 2022)

Uygulama alanlarına göre eğitim aşaması sonuçları Tablo 2-4'te yer almaktadır.

Tablo 2. Eğitim aşaması sonuçları (1x1 km<sup>2</sup>)

Yöntem	Alan (km <sup>2</sup> )	Giriş	Eğitim		
			KOKH	OMH	R <sup>2</sup>
ÇKYSA	1x1	X	81.2138	69.9981	0.2503
		X ve Y	4.8613	3.7806	0.9973
		Y	385.6574	322.4022	0.5343
GRYSA	1x1	X	81.3625	70.3894	0.2479
		X ve Y	1.1825	0.8835	0.9998
		Y	41.0211	32.5568	0.8087
RTYSA	1x1	X	81.3652	70.1751	0.2475
		X ve Y	11.6322	8.7874	0.9846
		Y	81.9686	71.1656	0.2363

**Tablo 3.** Eğitim aşaması sonuçları (10x10 km<sup>2</sup>)

Yöntem	Alan (km <sup>2</sup> )	Giriş	Eğitim		
			KOKH	OMH	R <sup>2</sup>
ÇKYSA	10x10	X	432.5403	333.5953	0.4010
		X ve Y	136.6000	103.8936	0.9403
		Y	387.4730	323.6128	0.5194
GRYSA	10x10	X	431.8452	332.0826	0.4036
		X ve Y	16.5694	12.6611	0.9991
		Y	385.5618	319.7247	0.5246
RTYSA	10x10	X	432.7200	335.1516	0.4005
		X ve Y	92.0927	66.2320	0.9728
		Y	431.6249	332.5581	0.4036

**Tablo 4.** Eğitim aşaması sonuçları (100x100 km<sup>2</sup>)

Yöntem	Alan (km <sup>2</sup> )	Giriş	Eğitim		
			KOKH	OMH	R <sup>2</sup>
ÇKYSA	100x100	X	535.4105	419.0543	0.2040
		X ve Y	137.9634	98.1584	0.9471
		Y	455.0025	329.5134	0.4251
GRYSA	100x100	X	538.3883	420.1133	0.1953
		X ve Y	51.4223	31.0769	0.9928
		Y	455.5143	330.5647	0.4239
RTYSA	100x100	X	436.4895	338.7661	0.4034
		X ve Y	88.0827	64.3180	0.9757
		Y	428.0517	332.6177	0.4263

Tablo 2-4 incelendiğinde en başarılı sonuçların X ve Y giriş setlerinin kullanıldığı GRYSA yönteminde elde edilmiştir. Tüm alanlar içinde en az hata en küçük alan olan 1x1 km<sup>2</sup> alanda elde edilmiştir (KOKH: 1.1825, OMH: 0.8835, R<sup>2</sup>: 0.9998). Alan arttıkça hata değerlerinde de artış görülmektedir. Test aşamasına ait sonuçlar ise Tablo 5-7’de yer almaktadır.

**Tablo 5.** Test aşaması sonuçları (1x1 km<sup>2</sup>)

Yöntem	Alan (km <sup>2</sup> )	Giriş	Test		
			KOKH	OMH	R <sup>2</sup>
ÇKYSA	1x1	X	82.1477	70.4297	0.2144
		X ve Y	5.0486	3.8924	0.9970
		Y	390.6765	323.5696	0.4888
GRYSA	1x1	X	82.3394	71.0533	0.2095
		X ve Y	1.6782	1.2125	0.9997
		Y	41.9047	33.6302	0.7951
RTYSA	1x1	X	475.4698	344.9141	0.3479
		X ve Y	338.5988	252.0137	0.6361
		Y	774.4441	663.0053	0.3026

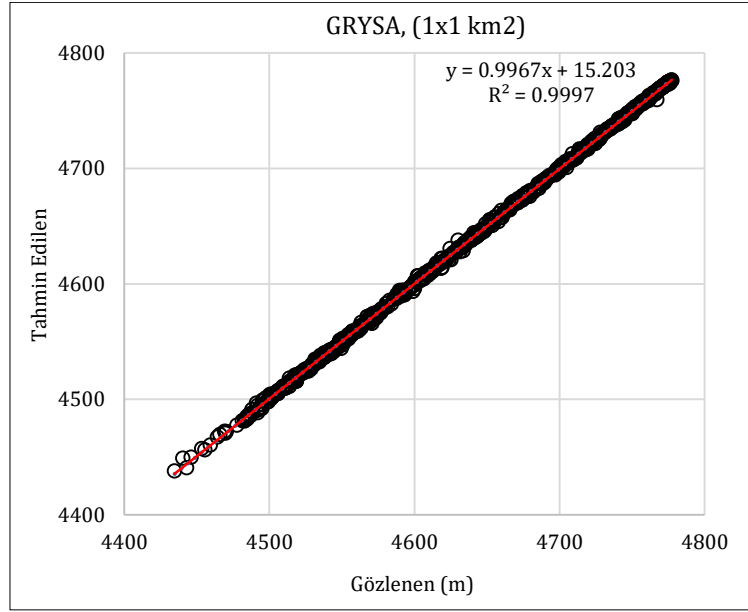
**Tablo 6.** Test aşaması sonuçları (10x10 km<sup>2</sup>)

Yöntem	Alan (km <sup>2</sup> )	Giriş	Test		
			KOKH	OMH	R <sup>2</sup>
ÇKYSA	10x10	X	425.6656	332.4097	0.4027
		X ve Y	137.1840	104.7444	0.9380
		Y	386.4835	322.3571	0.5108
GRYSA	10x10	X	425.5698	331.2443	0.4034
		X ve Y	21.6405	15.9821	0.9985
		Y	384.7959	319.4195	0.5149
RTYSA	10x10	X	432.2819	331.0703	0.3715
		X ve Y	93.4694	66.6324	0.9706
		Y	432.4882	330.0282	0.3713

**Tablo 7.** Test aşaması sonuçları (100x100 km<sup>2</sup>)

Yöntem	Alan (km <sup>2</sup> )	Giriş	Test		
			KOKH	OMH	R <sup>2</sup>
ÇKYSA	100x100	X	569.8355	456.6850	0.2012
		X ve Y	134.0586	96.9186	0.9563
		Y	467.5114	334.8437	0.4635
GRYSA	100x100	X	568.4621	454.6343	0.2069
		X ve Y	65.8283	39.7324	0.9897
		Y	467.5473	335.2457	0.4641
RTYSA	100x100	X	447.0150	340.0846	0.3360
		X ve Y	92.3521	66.2543	0.9713
		Y	435.3389	330.4650	0.3676

Test aşamasında da eğitimde olduğu gibi en başarılı sonuçlar GRYSA yönteminde gözlemlenmiştir. Bu yöntemi RTYSA izlemiş ve daha az başarılı yöntem ise ÇKYSA yöntemidir. Modelin genel performansı eğitim ve test aşamasına göre değerlendirildiğinde GRYSA oldukça başarılı bir modeldir. Aşağıda Şekil 4’te en iyi yönetime ait saçılma grafikleri yer almaktadır.



**Şekil 4.** Saçılma grafiği

Şekil incelendiğinde model sonuçları ile gözlenen değerler hemen hemen tüm veri büyüklüklerinde 45 derecelik  $x=y$  doğrusu üzerindedir. Ayrıca determinasyon katsayısının 1'e oldukça yakın olması modelin oldukça başarılı olduğunu göstermektedir.

#### 4. SONUÇLAR

Bu çalışmada Google-Earth Pro yazılımı ve uzaktan algılama teknikleriyle üç farklı büyüklükteki alan için yükseklik noktaları elde edilmiştir. Bu alanlar Ağrı Dağı çevresinde yer almakta olup 1x1 km, 10x10 km ve 100x100 km<sup>2</sup> boyutlarında kare alanlardır. Bu alanlara ait toplam 3500'er nokta eğitim ve test veri setlerine ayrılarak üç farklı yapay sinir ağı yöntemine göre tahmin edilmiştir. Çalışmada ÇKYSA, RTYSA ve GRYSA yöntemleri kullanılmıştır. Modellerin karşılaştırılmasında KOKH, OMH ve determinasyon katsayısı kullanılmıştır. Sonuçlar incelendiğinde:

- Y konum bilgileriyle gerçekleştirilen modellemeler sadece X konum bilgileriyle gerçekleştirilen modellerden daha başarılıdır.
- En başarılı sonuçlar her 2 girişli (X ve Y) modellerde elde edilmiştir.
- GRYSA yöntemi, RTYSA ve ÇKYSA yöntemlerine göre daha başarılıdır.
- Alan büyüdükçe hata değerlerinin arttığı görülmüştür.

Elde edilen sonuçlar özellikle şehir sınırları dışındaki alanlar için mühendislik projelerinde kullanılarak projelere hız kazandırabilmektedir.

Bu çalışmanın limitleri; üç farklı büyüklükteki alan için, üç farklı yöntem ve üç farklı karşılaştırma kriteri kullanılarak yükseklik noktalarının tahmin edilmesi üzerine kurgulanmıştır. Fakat gelecekteki çalışmalarda, aynı bölge için elde edilen farklı uzaktan algılama platformlarının performans karşılaştırması, farklı alanlar için farklı makine

öğrenmesi yöntemlerinin ve optimizasyon tekniklerinin, eğitim ve test oranlarının değiştirilerek karşılaştırılması planlanmaktadır.

#### Bilgilendirme/Teşekkür

Bu çalışma, TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı (BİDEB) tarafından yürütülen 2209-A Üniversite Öğrencileri Araştırma Projelerini Destekleme Programı 2021-2 kapsamında 1919B012107905 numaralı başvuru ile desteklenmektedir.

#### Araştırmacıların katkı oranı beyan özeti

V. Demir: Araştırma, Uygulama, Makale yazımı, Yorumlama, Revizyon.  
R. Doğu: Veri temini, Verilere ait istatistikler, Uygulama.

#### Çıkar çatışması beyanı

Makale ile ilgili olarak, herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

#### Araştırma ve yayın etiği beyanı

Yapılan çalışmada yazarlar, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul izni gerektirmediğini beyan etmektedir.

#### KAYNAKÇA

- Alp, M., & Cıgızoğlu, K. (2004). Farklı Yapay Sinir Ağı Metodları ile Yağış-Akış İlişkisinin Modellenmesi. *İtü Mühendislik Dergisi*, 3(1), 80-88.
- Arı, A., & Berberler, E. (2017). Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı. *ACTA*

INFOLOGICA, 1(2), 55–73.  
<http://dergipark.gov.tr/download/article-file/398974>

<https://doi.org/10.26833/ijeg.1125412>


- Behzadi, S., & Jalilzadeh, A. (2020). Introducing a Novel Digital Elevation Model Using Artificial Neural Network Algorithm. *Civil Engineering Dimension*, 22(2), 47–51.  
<https://doi.org/10.9744/ced.22.2.47-51>
- Çakır, L. (2013). Sayısal Yükseklik Modellerinde Polinomlar ve Yapay Sinir Ağları Yöntemlerinin Karşılaştırılması. *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu (TUFUAB'2013)*, 23-25 Mayıs 2013, Trabzon, Türkiye., 1–4.
- Çakır, L. (2015). Sayısal Yükseklik Modellerinde Klasik Ve Esnek Hesaplama Yöntemlerinin Karşılaştırılması. *TMMOB Harita ve Kadastro Mühendisleri Odası, 15. Türkiye Harita Bilimsel ve Teknik Kurultayı, 25--28 Mart 2015, Ankara, Türkiye.*, 1-6.,
- Çetinkaya, C. (2011). *Retina Görüntülerinde Radyal Tabanlı Fonksiyon Sinir Ağları İle Damar Tipik Noktalarının Tespit Edilmesi*. Yüksek Lisans Tezi, Ege Üniversitesi Uluslararası Bilgisayar Anabilim Dalı, İzmir.
- Citakoglu, H. (2015). Comparison of artificial intelligence techniques via empirical equations for prediction of solar radiation. *Computers and Electronics in Agriculture*, 118, 28–37.  
<https://doi.org/10.1016/j.compag.2015.08.020>
- Citakoglu, H. (2017). Comparison of artificial intelligence techniques for prediction of soil temperatures in Turkey. *Theoretical and Applied Climatology*, 130(1–2), 545–556.  
<https://doi.org/10.1007/s00704-016-1914-7>
- Çitakoğlu, H., & Özeren, Y. (2021). Sakarya Havzası Su Kalitesi Parametrelerinin Yapay Sinir Ağları ile Modellenmesi. *European Journal of Science and Technology*, 24, 10–17.  
<https://doi.org/10.31590/ejosat.898046>
- Çubukçu, E. A., Demir, V., & Sevimli, M. F. (2021). Digital Elevation Modeling Using Generalized - Radial Based - Multi Layered Artificial Neural Networks. *Turkish Journal of Engineering*, 6(3), 199–205.  
<https://doi.org/10.31127/tuje.889570>
- Çubukçu, E. A., Demir, V., & Sevimli, M. F. (2022). Modeling of Annual Maximum Flows with Geographic Data Components and Artificial Neural Networks. *International Journal of Engineering and Geosciences*, 8(2), 200–211.  
<https://doi.org/10.26833/ijeg.1125412>
- Çubukçu, E. A., Sancioğlu, S., Demir, V., & Sevimli, M. F. (2019). Sea Water Level Estimation Using Six Different Artificial Neural. *International Civil Engineering and Architecture Conference*, 716–725.
- Demir, V., & Çubukçu, E. A. (2021). Digital Elevation Modeling with Heuristic Regression Techniques Abstract. *European Journal of Science and Technology*, 24, 484–488.  
<https://doi.org/10.31590/ejosat.916012>
- Demir, V., & Doğu, R. (2022). Creating digital elevation model with Google Earth Pro. *4th Advanced Engineering Days(AED) -21-22 September 2022*, 21(5), 78–80.  
<https://doi.org/10.35414/akufemubid.936431>
- Demir, V., & Keskin, A. Ü. (2020). Height Modeling with Artificial Neural Networks ( Samsun-Mert River Basin). *Gazi Journal of Engineering Sciences*, 6(1), 54–61.  
<https://doi.org/https://dx.doi.org/10.30855/gmbd.2020.01.05>
- Gholami, V., Booi, M. J., Nikzad Tehrani, E., & Hadian, M. A. (2018). Spatial soil erosion estimation using an artificial neural network (ANN) and field plot data. *CATENA*, 163, 210–218.  
<https://doi.org/10.1016/j.catena.2017.12.027>
- Gümüş, K., & Şen, A. (2017). Sayısal Yüksekli Modellerinin Doğruluğunu Etkileyen Faktörlerin Varyan Analizi İle İstatiksel Olarak İncelenmesi. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 6(1), 46–58.  
<https://doi.org/10.28948/ngumuh.297729>
- Kisi, O., & Demir, V. (2016). Evapotranspiration Estimation using Six Different Multi-layer Perceptron Algorithms. *Irrigation & Drainage Systems Engineering*, 5(2), 1-6..  
<https://doi.org/10.4172/2168-9768.1000164>
- Kılıç, G. (2015). *Yapay Sinir Ağları İle Yemekhane Günlük Talep Tahmini*. Yüksek Lisans Tezi, Pamukkale Üniversitesi, Bilgisayar Mühendisliği Anabilim dalı, Denizli.
- Konakoglu, B., Cakir, L., & Gökalp, E. (2016). 2D coordinate transformation using artificial neural networks. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(2W1), 183–186. <https://doi.org/10.5194/isprs-archives-XLII-2-W1-183-2016>
- Marquardt, D. (1963). An algorithm for least squares

- estimation of non-linear parameters. *J.Soc.Ind. Appl.Math.*, 431–441.
- Oral, M., Kartal, S., & Özyıldırım, B. M. (2018). A cluster based approach to reduce pattern layer size for generalized regression neural network. *Pamukkale University Journal of Engineering Sciences*, 24(5), 857–863. <https://doi.org/10.5505/pajes.2017.76401>
- Specht, D. F. (1991). A general regression neural network. *IEEE Transactions on Neural Networks*, 2(6), 568–576. <https://doi.org/10.1109/72.97934>
- Uray, E., Demir, V., Keskin, A. Ü., & Tan, Ö. (2019). Use of Artificial Neural Networks in Stability Control of Cantilever Retaining Walls. *International Civil Engineering and Architecture Conference, 2001*, 469–478.
- URL-1 (2023). Türkiye'nin En Yüksek Dağları Sıralaması. <https://www.techworm.com/turkiyenin-en-yuksekk-daglari-siralaması/> [Erişim Tarihi: 10.05.2023]
- Yenipınar, E., Kayhan, M. M., Esra Aslı, Ç., Demir, V., & Sevimli, M. F. (2021). Türkiye'nin Uzun Dönem Yağış Miktarının IDW ve Kriging Yöntemleri ile Tahmin Edilmesi. *Türkiye Uzaktan Algılama Dergisi*, 3(2), 47–52.
- Yılmaz, A. (2017). *Yapay Zeka*. KODLAB Yayınevi, İstanbul.
- Zeybekoglu, U. (2018). Forecasting of Annual Mean Rainfall Using Artificial Neural Network and Wavelet Components : Case of Study Sinop. 1. *International Technological Sciences and Design Symposium*, 1700–1709.



© Author(s) 2023.


This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>



## Türkiye Uzaktan Algılama Dergisi

<https://dergipark.org.tr/tr/pub/tuzal>

e-ISSN 2687-4997



# Çok Yüksek Çözünürlüklü Uydu Görüntülerinden Bina Çıkarımında Derin Öğrenme ve Çoklu-Çözünürlüklü Bölütleme Kullanılarak Nesne-Tabanlı Entegrasyon

Şaziye Özge Atik\*<sup>1</sup>

<sup>1</sup>Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kocaeli, Türkiye

### Anahtar Kelimeler:

Derin Öğrenme  
Nesne-tabanlı Görüntü Analizi  
Çoklu-çözünürlüklü Bölütleme  
Entegrasyon

### ÖZ

Son yıllarda, kentsel alanlarda yapılan analizler ve değişimlerin tespitinin hızlı ve güvenilir şekilde gerçekleştirilmesi konusundaki çalışmalarda artış olmuştur. Bu doğrultuda, binaların sınıflandırılması bilgisayarlı görünümün ön plana çıkan güncel konularından biridir. Birçok alanda olduğu gibi bu konuda da derin öğrenme mimarilerinin kullanımı trend uygulamalar arasındadır. Bina ayak izinin belirlenmesi amacıyla evrimsel sinir ağları (ESA) kullanılarak semantik segmentasyon uygulamaları yaygınlaşmıştır. Ancak derin öğrenme ile segmentasyon işlemleri sonrası elde edilen tahmin görüntülerinde karşılaşılan problemlerin başında tuz-biber etkisiyle oluşmuş gürültüler gelmektedir. Bu çalışmada güncel ESA mimarilerinden olan U-Net ve SegNet algoritmalarının kullanımının, Nesne-Tabanlı Görüntü Analizinin (NTGA), Çoklu-Çözünürlüklü Bölütleme (ÇÇB) algoritmasıyla entegrasyonu kullanılmıştır. Deneyler çok yüksek çözünürlüklü uydu görüntülerinden (Gaofen-2, Worldview-2 ve Ikonos) oluşan açık paylaşımlı Wuhan Üniversitesi Bina Çıkarımı Veri seti (WHUBED) üzerinde gerçekleştirilmiştir. ESA+ÇÇB modeli genel doğruluk, F1 skor, Dice skoru ve Intersection over Union (IoU) metriklerinde, sadece ESA kullanımıyla elde edilen tahmin sonuçlarına göre iyileştirmeler sağlamıştır. Bina sınıflandırılması ile elde edilen haritalar karşılaştırılmalı görseller olarak son kısımda sunulmuştur.

## Object-Based Integration Using Deep Learning and Multi-Resolution Segmentation in Building Extraction from Very High Resolution Satellite Imagery

### Keywords:

Deep Learning  
Object-based Image Analysis  
Multi-resolution Segmentation  
Integration

### ABSTRACT

In recent years, there has been an increase in studies on the analysis of urban areas and the detection of changes in a fast and reliable way. In this respect, the classification of buildings is one of the prominent current issues of computer vision. As in many areas, the use of deep learning architectures is among the trending applications. Semantic segmentation applications have become widespread by using convolutional neural networks (CNN) to determine the building footprint. However, at the beginning of the problems encountered in the prediction images obtained after segmentation processes with deep learning, the noise formed by the effect of salt and pepper comes. In this study, the integration of the use of U-Net and SegNet algorithms, which are among the state-of-the-art CNN architectures, with the Object-Based Image Analysis (OBIA) and Multi-Resolution Segmentation (MRS) algorithm is used. Experiments were performed on the open shared Wuhan University Building Inference Dataset (WHUBED) consisting of very high-resolution satellite images (Gaofen-2, Worldview-2 and Ikonos). The model in the study, provides improvements in overall accuracy, F1 score, Dice score and Intersection over Union (IoU) metrics over the prediction results obtained using CNN alone. Building footprint maps obtained by building extraction are presented in the last section as comparative images.

### Makale Bilgileri/Article Info

Geliş /Received: 04/08/2023  
Kabul/Accepted: 25/09/2023  
Yayınlanma/Published: 30/12/2023

### Alıntı/Citation:

Atik, Ş.Ö. (2023). Çok Yüksek Çözünürlüklü Uydu Görüntülerinden Bina Çıkarımında Derin Öğrenme ve Çoklu-Çözünürlüklü Bölütleme Kullanılarak Nesne-Tabanlı Entegrasyon. Türkiye Uzaktan Algılama Dergisi, 5 (2), 67-77.

## 1. GİRİŞ

Uzaktan algılama verilerinin ulaşılabilirliği ve yaygın kullanım alanları gelişen teknolojiyle beraber her geçen gün artmaktadır. Yeryüzünde olan doğal kaynaklı ve insan yapımı birçok alan sürekli olarak değişip, dönüşmekte ve bu değişimler uydu görüntüleriyle periyodik olarak izlenmektedir. Yer gözlem uyduları yardımıyla, yer yüzeyindeki arazi kullanım ve arazi örtüsü (AKAÖ) sınıfları derin öğrenme yaklaşımlarıyla otomatik olarak sınıflandırılmaktadır (Xu vd., 2021; Ali ve Johnsonn, 2022; Balarabe ve Jordonav, 2022). Dünyanın %0,1'inden azı kentleşmiş alanlardan oluşmasına rağmen, dünya nüfusunun %50'den fazlası bu alanlarda yaşamaktadır (Lee ve Baik, 2011). Arazi örtüsü ve kullanımı sınıflarının en büyük değişimi yerleşim sınıfında olduğundan, binaların hızlı ve etkili şekilde otomatik olarak sınıflandırılması oldukça önemli bir konudur. Bu nedenle, semantik segmentasyon olarak bilinen uygulamalar bina çıkarımında son yılların öne çıkan araştırma konularından biri olmuştur. Ancak derin öğrenme yaklaşımlarıyla piksel tabanlı semantik segmentasyon uygulamalarının tuz-biber etkisi gibi bazı gürültüleri mevcuttur. Nesne-tabanlı görüntü analizinin sağladığı imkanlar farklı şekillerde kullanılarak evrimsel sinir ağlarıyla (ESA) sınıflandırılmış görüntüleri iyileştirmede bir teknik olarak kullanılmaktadır (Ghorbanzadeh vd., 2021; Dewali vd., 2023; Tang vd. 2020; Li vd., 2022; Merchant, 2021).

Son on yılda, derin öğrenme yaklaşımı, uydu görüntülerini kullanarak segmentasyon oluşturmak için sağlam bir yöntem olarak etkili olmuştur. Pan vd. (2020) karmaşık bir kentsel köydeki bireysel binaları karakterize etmek için bir yaklaşım önermiştir. Çalışmada, 0,5 m mekansal çözünürlüğe ve bina sınır vektör dosyalarına sahip sekiz bantlı Worldview uydu görüntüleri kullanılmıştır. Arıkan ve Yıldız (2023) Göktürk-1 uydu görüntüleri ile bina çıkarımında U-net modelini kullanarak semantik segmentasyon yapmışlardır. Kaiser vd. (2017), binaları ve yolları çıkarmak için VGG-16 mimarisine dayalı bir derin öğrenme ağı önermiştir. Bu çalışmada, otomatik harita üretimi için, yüksek çözünürlüklü hava görüntülerinin kontrollü sınıflandırma yoluyla semantik segmentasyonu amaçlanmaktadır. Yi vd. (2019), çok yüksek çözünürlüklü (VHR) görüntülerin semantik segmentasyonu için U-Net ve ResNet mimarilerine dayalı DeepResUnet yöntemini önermişlerdir. DeepResUnet, özellikle düzensiz şekilli ve küçük boyutlu binaları yüksek doğruluk ve bütünlükle tespit edebilmektedir. Ji vd. (2019) binaları hava ve uydu görüntülerinden çıkarmak için ölçekli güçlü bir derin öğrenme mimarisi önermişlerdir. Qin vd. (2019) kentsel alanlardaki binaların özellikle çatılarını doğru bir şekilde haritalamak için uçtan uca evrimsel bir ağ tasarlamışlardır. Abdollahi vd. (2022) yüksek çözünürlüklü hava görüntülerine

semantik segmentasyon uygulamak için iki popüler ESA mimarisini, SegNet ve U-Net'i birleştirerek yeni bir model oluşturmuşlardır. Liu vd. (2021), bina ayak izi oluşturmak için iki temel modül içeren bir metodoloji önermişlerdir. Liu vd. (2021), doğal afetlerdeki değişim analizinde VHR havadan uzaktan algılama görüntüleri semantik segmentasyonu için Nesne-Tabanlı Görüntü Analizi (NTGA) ve derin öğrenmeyi birleştirmeyi önermişlerdir. Marcu ve Leordeanu (2016) tarafından yayınlanan çalışmada, bina ve yol çıkarımı için çift akışlı derin sinir ağı modeli geliştirilmiştir. Atik ve İpbüker gerçekleştirdiği çalışmada ESA mimarilerine girdi veri olarak 3 bant: Kırmızı (R), Yeşil (G), Mavi (B) yerine; yakın kızılötesi (NIR), ve/veya spektral indislerin de eklendiği veri setlerini kullanarak arazi kullanım ve arazi örtüsü sınıflandırması gerçekleştirmişlerdir. Söz konusu çalışmada önerilen ESA+ÇÇB (2021) yaklaşımı bu çalışmada farklı özellikte verilere uygulanmış (RGB) ve hedefi bina çıkarımı olarak özelleştirilmiştir.

Bu çalışma, bina çıkarımı sürecinin doğruluğunu ve otomasyonunu iyileştirmek için çoklu çözünürlüklü bölütleme (ÇÇB) uygulamasını birleştiren ESA tabanlı modeller ile birleştiren bina segmentasyonu amaçlanmaktadır. ESA+ÇÇB modeli bu çalışmada ESA tabanlı bina sınıflandırması ve ÇÇB ile sınıflandırma performansının iyileştirilmesi olmak üzere iki adımdan oluşmaktadır. Bu çalışmada,

- Üç farklı uydunun görüntülerinden oluşan açık paylaşımlı Wuhan University Building Extraction Dataset (WHUBED) veri seti kullanılarak U-net ve SegNet derin öğrenme mimarileriyle bina sınıfı için semantik segmentasyon yapılması hedeflenmiştir. Yaygın kullanımı olan ESA mimarilerinin kullanımıyla elde edilen bina sınıfı tahminlerinin içerdiği gürültüler, ÇÇB algoritmasının entegrasyonu ile önemli ölçüde azaltılmıştır.

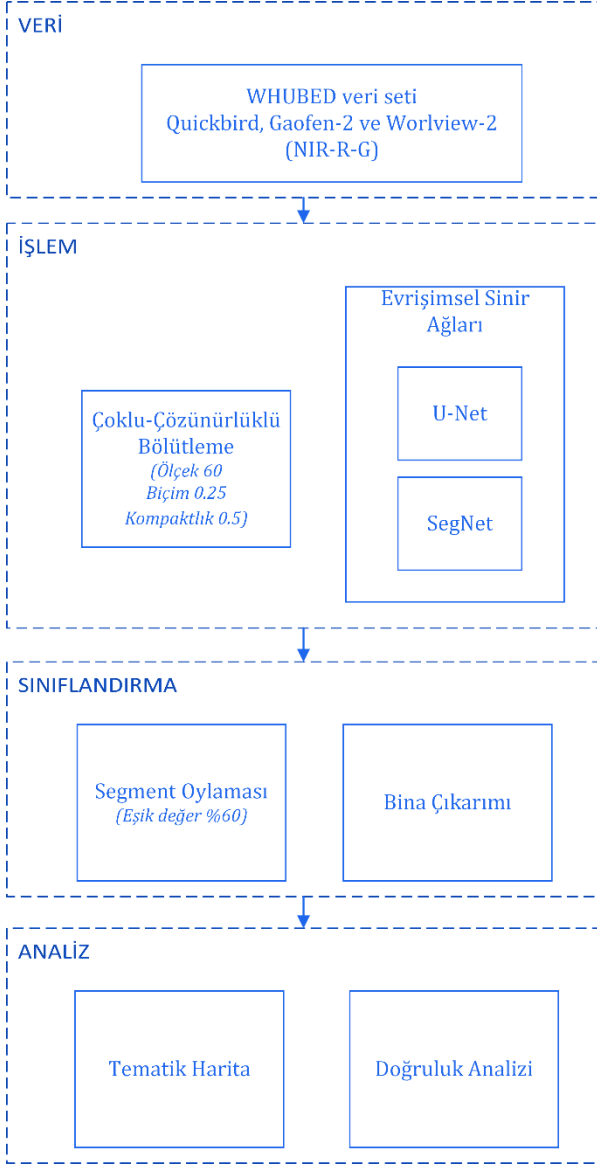
- ESA ve ÇÇB yöntemlerinin entegrasyonu, sadece ESA mimarilerinin kullanımıyla elde edilen sınıflandırmayla karşılaştırıldığında genel doğruluk, F1 skor, Dice skoru ve Intersection Over Union (IoU) metriklerinde iyileştirmeler sağlamıştır.

- WHUBED veri setinin kullanıldığı literatürdeki diğer çalışmalarla karşılaştırma yapıldığında, bu çalışmada ortaya konan yaklaşım ile daha yüksek F1-skorları elde edilmiştir.

## 2. VERİ VE YÖNTEM

Çalışmada izlenen akış diyagramı Şekil 1'de gösterilmiştir. Kullanılan veri ilk aşamada eğitim, validasyon ve test olarak ayrılmıştır. İşlem aşamasında, veri seti üzerinde U-Net ve SegNet ESA ağları kullanılarak derin öğrenme ile bina sınıfı tahmin görüntüleri oluşturulmuştur. Aynı zamanda test görüntülerine ÇÇB algoritması uygulanmış ve görüntülerde algoritmaya göre oluşturulan

nesnelerin bölütleri elde edilmiştir. Sınıflandırma kısmında, bölütler ve tahmin görüntüleri bir arada kullanılarak entegre bir işlem gerçekleştirilmiştir. Burada çoğunluk oylaması ile bölütler rafine edilerek bina sınıflarını içeren sonuç görüntüleri oluşturulmuştur. Analiz kısmında bu alanda yaygın kullanılan metrikler ile doğruluk analizi gerçekleştirilmiş ve analize dair sayısal değerler tablolarda gösterilmiştir.



Şekil 1. Çalışmanın iş akışı.

## 2.1. Veri


Çalışmada, uydu görüntülerinden binaların çıkarılması için Wuhan Üniversitesi Bina Çıkarımı Veri seti (Wuhan University Building Extraction Dataset -WHUBED) kullanılmıştır (Bi vd., 2019). Veri seti, 31 tanesi pan-keskinleştirilmiş olmak üzere, toplam 57 görüntü içermektedir. Veri setindeki uydu görüntüleri, 0,6, 0,8 ve 0,5 m mekânsal çözünürlüğe sahip QuickBird, Gaofen-2 ve WorldView2 uydularına ait görüntülerden oluşmaktadır. Veri setinde referans veri olarak, bina ve bina olmayan

sınıflar etiketli halde açık kaynak olarak paylaşılmıştır (Şekil 2). Veri setinin görüntüleri NIR, RGB bantlarından oluşmaktadır. NIR bant kullanımının, bina sınıfını, bina olmayan bölgeden ayırmaya yardımcı olduğu bilinmektedir. Bu bağlamda oluşturulan veri seti örneklerinin kullanıldığı çalışmalar mevcuttur (Thenkabail vd., 2005, Attri vd., 2015, Atik vd., 2022). Bu çalışmada ESA mimarilerinde veri olarak NIR-R-G bant kombinasyonu kullanılmıştır.



Şekil 2. Veri setine ait örnek görüntü ve referans görüntüsü.

Eğitim aşamasında 54 görüntü (%93) kullanılmış olup, doğrulama için 2 görüntü (3.5) ve test aşamasında 2 görüntü (%3.5) kullanılmıştır. WHUBED veri setine ait görüntüler ESA mimarilerinde kullanılmak üzere alt görüntü oluşturma (görüntü kırpma işlemi) ile 32 x 32 görüntü boyutlarına getirilmiştir. Veri setine ait görüntülere rastgele alt görüntü (görüntü parçacığı) oluşturma uygulanarak veri artırımı yapılmıştır. Veri artırımının şematik çizimi Şekil 3'te temsil edilmiştir.



Şekil 3. Veri artırımı ile alt görüntü üretimi gösterimi.

## 2.2. ESA Mimarileri


Kontrollü sınıflandırma uygulamalarında son dönemlerde popüler olarak tercih edilen ESA mimarileri, evrişim aşamasında Kernel filtreleri yardımıyla girdi verisini kullanarak özellik haritaları üretir. Orijinal görüntüler yerine bu özellik haritalarını ESA ağlarında işlemek daha kolay ve hızlıdır. Bu aşamada üretilen linear çıktıların yerine



gerçek hayattaki örneklerde lineer olmayan örneklere daha çok rastlanır. Bu nedenle bir aktivasyon fonksiyonu yardımıyla tensörlerin ürettiği lineer değerler lineer olmayan değerlere dönüştürülür. Sigmoid ve tanh aktivasyon katmanları basit ama etkili olduklarından ötürü Rectified Linear Unit (ReLU) olarak en çok tercih edilen türleri arasındadır. Havuzlama katmanında özellikleri koruyarak, olası mekansal, dokusal veya diğer türdeki bozulmaların önüne geçmek için piksellerin maksimum değerleri işleme alınmaktadır. Havuzlamanın bir başka faydası da parametre sayısını azaltarak aşırı uyumun önlenmesidir. Hassas-ayarlı ise, kullanılan algoritma için mümkün olan en iyi hiperparametrelerin bulunmaya çalışıldığı aşamadır. ESA mimarisinin son katmanı olan Softmax aşamasında piksellerin segmentasyon sonucunda tahmin sınıflarının ataması yapılır. Pikseller için en yüksek olasılığa sahip sınıf hangisiyse, atama o sınıfa gerçekleştirilir. ESA mimarisinde Softmax Fonksiyonundan sonra, Çapraz Entropi Fonksiyonu kullanılarak modelin güvenilirliği test edilir ve Kayıp Fonksiyon izlenerek modelin yüksek performans göstermesi hedeflenir.

### 2.3. U-Net Mimarisi

U-Net derin öğrenme mimarisi (Ronneberger vd, 2015) 23 evrişim katmanına sahiptir. U-Net mimarisi çok kanallı özellik haritalarına sahiptir. Mimaride her özellik haritasının ardından bir ReLU katmanı,  $2 \times 2$  çekirdek boyutunda maks-havuzlama katmanı ve iki adet  $3 \times 3$  evrişim katmanı vardır. U-Net mimarisinin diğer ESA mimarileri arasındaki önemi, örnekleme aşamasında birçok özellik kanalı bulundurması ve bu sayede ağıın bilgilerini daha yüksek çözünürlüklü katmanlara yaymasını sağlamasıdır. Mimaride, ağıın sahip olduğu geniş yol, darboğaza simetiktir ve bu sayede mimarinin yapısı U şeklini alır. U-Net mimarisi, ilk olarak biyomedikal görüntülerin segmentasyon uygulamalarında iyi performans sağlamasıyla ortaya çıkmıştır. Çalışmada kullanılan U-Net mimarisi çizimi Şekil 4'te gösterilmektedir. Az veri boyutunda gerçekleştirilen eğitimlerde dahi iyi performans göstermesi özelliğiyle sık tercih edilen bir ESA mimarisidir.



Şekil 4. U-Net mimarisinin şeması (Ronneberger vd., 2015).


U-Net mimarisi, segmentasyon haritasındaki hücrelerin her birinin kolayca tanımlanması için görüntünün her pikseli için bir kayıp fonksiyonu kullanır. Aynı zamanda her piksele softmax katmanı ve ardından bir kayıp fonksiyonu uygulanır. Bu sayede, her pikselin sınıflardan birine atanmasını gerektiren bir sınıflandırma işlemi uygulanır. Ancak bu işlemler piksel bazında olduğundan, sonuç ürünlerde her piksel bir sınıfa atanmış olacaktır. Bu çalışmanın kullanılan yaklaşımı sayesinde piksel arasındaki komşuluk ve ilgililik piksel gruplarının bir arada kullanılarak sınıflandırılmasını içerir. Bu sayede ESA mimarilerinin ürettiği sonuç çıktılarındaki gürültüler iyileştirilmiş olur.

Yüksek doğrulukta sonuç veren basit U-Net mimarisinin medikal çalışmalarda (Koç ve Akgün, 2021) kullanımının yanı sıra, esnek ve eklenebilir yapısı sayesinde bir çok farklı uygulamada da tercih edildiği bilinmektedir. U-Net mimarisinde sınırlı sayıda örnekleme ile de iyi sonuçlar üretmesinin yanı sıra veri artırımı ile rastgele şekilde örnekleme alt-görüntülerinin çoğaltılarak oluşturulması yardımıyla aşırı uyumu azaltabileceğinden doğruluğu artırdığı görülmüştür (Kurnaz ve Ceylan, 2020). Bu çalışmada da rastgele alt görüntü oluşturma yöntemi ile veri artırımı gerçekleştirilmiş ve bu işlemler her iki ESA mimarisinde de uygulanmıştır.

### 2.4. SegNet Mimarisi

SegNet (Badrinarayanan vd., 2017), girdi görüntüsüyle aynı boyutta tahmin çıktısı veren tamamen evrişimli bir sinir ağı mimarisidir. Piksel bazında sınıflandırma için kullanılan bu ağda, evrişim katmanlarını, kodlayıcı-kod çözücü (encoder-decoder) katmanlarını, evrişim ve yığın toplu normalleştirme, havuzlama katmanı ve ReLU aktivasyon aşamalarını içerir. Mimaride altörnekleme ve üstörnekleme aşamaları simetrik yapıdadır (Şekil 5). ESA ağının son kısmında, softmax katmanında semantik segmentasyon sonucu üretilir.

Ağda kodlayıcılar ve kod çözücü ağı, özellik haritalarını oluşturmak ve toplu olarak normalleştirmek için bir filtre bankası oluşturur. Bu aşamadan sonra, ReLU katmanı bir aktivasyon işlemini gerçekleştirir. Mimaride daha sonra  $2 \times 2$  çekirdek boyutunda maks-havuzlama katmanı yer alır. Son kod çözücü kısmında, görüntüdeki her piksel için çok sınıflı bir sınıflandırıcı olan softmax katmanı ile semantik segmentasyon işlemi tamamlanır.



Şekil 5. SegNet mimarisi. Görüntü Badrinarayanan vd. nin çalışmasından uyarlanmıştır (2017).

## 2.5. Nesne-Tabanlı Görüntü Analizi

NTGA piksel tabanlı görüntü analizine alternatif olarak ortaya çıkmıştır. Görüntü işlemenin bu çeşidinde, pikseller yerine nesnelere (bölütler) üzerinde işlem yapılır. NTGA çoğunlukla yüksek ve çok yüksek çözünürlüklü görüntülerin sınıflandırılmasında tercih edilmektedir. Çünkü, kullanılan görüntülerdeki mekânsal çözünürlük arttıkça sınıflandırmada karşılaşılan tuz-biber etkisi kaynaklı gürültüler de önemli bir sorun haline gelmektedir. Görüntü segmentasyonu, NTGA'nın kritik ve önemli bir aşamasıdır. NTGA'da elde edilecek kalite, büyük oranda görüntü bölütleme aşamasındaki kaliteye bağlıdır (Hossain ve Chen, 2019). Birçok farklı açık-kaynak yazılımı (Spring ve Monteferdi-Orfeo Toolbox) imkanıyla NTGA işlemleri gerçekleştirilebilirken; eCognition, ENVI, ERDAS Imagine gibi ticari yazılımlarla da bu işlemler sürdürülebilmektedir. NTGA'nın literatürde yaygın kullanımlı çeşitleri arasında ÇÇB algoritması (Torunlar vd., 2021, Ghorbanzadeh vd., 2022, de Pinho vd. 2012) ve Yalın Doğrusal Yinelemeli Kümeleme (SLIC-Simple Linear Iterative Clustering) uygulamalarına (Manaf vd., 2018; Kawamura, 2021) sık rastlanmaktadır. Bu çalışmada, en yaygın ve etkili NTGA yöntemlerinden biri olan ÇÇB algoritması kullanılmıştır.

### 2.5.1. Çoklu-Çözünürlüklü Bölütleme

Baatz vd. (2000) piksel tabanlı görüntü işleme algoritmasına alternatif bir algoritma önermişlerdir. ÇÇB algoritması olarak bilinen bu algoritma literatürde yaygın olarak kullanımını sürdürmektedir (Hossain ve Chen, 2019). ÇÇB tekniği görüntünün sahip olduğu spektral özelliklere göre gruplandırma yapmaktadır. Bölütleme yani nesne tabanlı segmentasyon, görüntüleri birbiriyle ilgili olan piksellerden oluşan parçalara ayırma yöntemidir. Bir görüntüyü nesnelere ayırmak, bu ayırmadan öznelikler çıkarmak ve sonrasında öznelikleri sınıflandırarak görüntüyü anlamlandırmak bu yaklaşımın temelini oluşturur (Wang, 2008). Bu sayede, piksel tabanlı algoritmalara alternatif olarak görüntünün anlamlı nesnelere bölünüp; doku ve bağlamsal ayrıntılar gibi daha tanımlayıcı yeni nitelikler elde edilebilir (Tian ve Chen, 2007). Daha ileri sınıflandırmanın amaçlandığı nesne tabanlı görüntü analizinde bölütleme önemli bir aşamadır (Ghorbanzadeh vd, 2021). Bu bölütleme esnasında, görüntüdeki nesnelere belirlenirken, şekil ve renk parametrelerinin ağırlık değerlerinin toplamı 1 olacak şekilde uygun değerler seçilir. Aynı şekilde, kompaktlık ve düzgünlük değerleri toplamı 1'e eşit olacak şekilde en uygun haliyle belirlenir. Algoritmanın birleştirme maliyet fonksiyonunun, spektral ve şekil heterojenliği arasındaki bağlantısı Eşitlik 1'de (Wang, 2008) gösterilmiştir.


$$f = w \times h_{renk} + (1 - w) \times h_{biçim} \quad (1)$$

Eşitlikte 0-1 değer aralığında olan  $w$  değeri, spektral heterojenlik ağırlığına;  $h_{biçim}$  ve  $h_{renk}$  ise şekil ve renk parametrelerine karşılık gelir.

Bölütleme aşamasından sonra, görüntü artık birbiriyle ilgili piksellerin bir arada olduğu gruplara ayrılmıştır. Bu bölütlerin ESA+ÇÇB entegrasyonundaki görevi, daha önceden ESA mimarisi kullanılarak görüntüde tahmin değerlerine ait aynı grubun (segment) içinde kalan pikseller için yeniden oylama gerçekleştirmektir. Bu sayede bu grubun içinde kalan başka sınıflara ait olduğu tahmin edilmiş gürültüler de ağırlık oylamasında belirlenen eşik değerin uygun şekilde seçilmesiyle azaltılır. Bu işlem Şekil 6'da gösterilmiştir.

### 2.6. Çoğunluk Oylaması

ESA+ÇÇB yaklaşımında, ESA mimarilerinin tahmin sonucu belirlenen sınıf kategorisi, ÇÇB yardımıyla rafine edilir. Çoğunluk oylaması (majority voting) ÇÇB algoritması tarafından bölümlere ayrılan her nesne (bölütte), pikseller yardımıyla gerçekleştirilir.



**Şekil 6.** Segmentasyon aşamasında çoğunluk oylamasının şematik açıklaması (Atik ve İpbüker, 2021'den uyarlanmıştır)

İlk aşama olarak, çalışmada kullanılan uydu görüntüleri, ÇÇB algoritması ile nesnelere ayrılır. ÇÇB algoritması sonucu elde edilen bir bölüt,  $n$  sayıda piksel içerir. ESA kullanılarak semantik segmentasyon ile sınıf etiketlemesinden (tahmin) sonra bir sınıf kategorisi elde edilir. ÇÇB yardımıyla üretilen bir nesne, kendi içinde sınıf kategorisinde çoğunluğu sağlayamazsa, o nesnedeki tüm piksellerin sınıfları, ESA tahmini haliyle aynı kalacaktır. Eğer oylamada çoğunluk sağlanırsa, daha önce ESA ile farklı sınıfa atanmış pikseller de çoğunluğun sınıfına atanır (Şekil 6). Yani bu durumda, nesnedeki her piksel, modelin uygulanması sonucunda içerdiği nesnenin yeni kategori değerini alır. Bu nedenle, ESA+ÇÇB modeli her nesne için yeniden bir kategori (sınıf) hesaplamasını temsil eder. Böylece, ESA tabanlı

sınıflandırma, ÇÇB algoritması kullanılarak çoğunluk oylamasıyla rafine edilmiş olur.

$$Kesinlik = \frac{GP}{GP + YP} \quad (2)$$

$$Duyarluluk = \frac{GP}{GP + YN} \quad (3)$$

$$F1 \text{ skor} = 2 \frac{Kesinlik \times Duyarluluk}{Kesinlik + Duyarluluk} \quad (4)$$

$$IoU = \frac{GP}{GP + YP + YN} \quad (5)$$

$$Dice = \frac{2 \times GP}{2 \times GP + YP + YN} \quad (6)$$

$$Genel \text{ Doğruluk} = \sum_{i=1}^k \frac{N_{ii}}{N} \quad (7)$$

Çalışmada, bina çıkarımının doğruluk analizi için kullanılan performans ölçütleri Eşitlik 2-7'de gösterilmiştir. Eşitliklerde, tahmin edilen etiket ile referans etiketinin aynı olduğu piksel sayısı gerçek pozitif (GP) değerine karşılık gelmektedir. Yanlış-pozitif (YP) değeri ise, referans etiketi negatifken tahmin edilen etiketin pozitif olduğu piksel sayısına karşılık gelir. Tahmin edilen etiket negatif iken, referans etiketinin pozitif olduğu piksel sayısı yanlış-negatif (YN) ile ifade edilir. IoU, başka bir deyişle Jaccard indeksi, iki bölgenin üst üste örtüşmesini ölçen ve 0-1 aralığında değerler alan bir metriktir. Dice katsayısı, iki görüntünün benzerliğini ölçmeye yarayan semantik segmentasyon uygulamalarında sıkça tercih edilen bir istatistiktir.

## 2.7. Uygulama

Bu çalışmada uydu görüntülerinin ESA tabanlı piksel sınıflandırma sonuçlarının çok-çözünürlüklü bölütleme ile elde edilen nesnelere kullanılarak iyileştirilmesi amaçlanmaktadır. ESA modeli olarak U-Net ve SegNet mimarileri kullanılmıştır. ESA mimarisinde kullanılan girdi görüntüler 512 × 512 piksel boyutundadır. Eğitim parametreleri momentum 0.9, küme boyutu 128 ve öğrenme hızı 0.001 olarak belirlenmiştir. Eğitim sırasında ince ayar ve optimizasyonlar (erken, durdurma vb.) için validasyon doğrulukları ve kayıp fonksiyonları dikkate alınmıştır.

NTGA kısmında, görüntüler nesnelere ayrılırken kullanılan ÇÇB algoritmasında test görüntüleri için, ölçek parametresi 60 ve 0.25 biçim ve 0.5 kompaktlık parametreleri seçilerek işlemler gerçekleştirilmiştir.

Aynı zamanda sınıflandırılan görüntüler üzerinde 5x5 çekirdek boyutunda medyan filtre uygulanarak yumuşatma işlemi (smoothing) uygulanmıştır.

Tüm deneyler, GPU destekli RTX 3070 ekran kartı, 32 GB RAM ve i7-11800H 2.3 GHz işlemciye sahip bir bilgisayar kullanılarak gerçekleştirilmiştir. ESA uygulamaları MATLAB ortamında geliştirilmiştir. ÇÇB algoritması eCognition yazılımı kullanılarak uygulanmıştır.

## 3. BULGULAR

Uygulanan yaklaşımın, WHUBED veri seti üzerinde derin öğrenme tabanlı görüntü sınıflandırması ve ESA+ÇÇB modelini kullanarak yapılan deneylerde elde edilen sonuçlar Tablo 1-3'te gösterilmiştir. U-Net algoritması ile sadece ESA kullanıldığı durumda %87.13 Genel Doğruluk (GD), %78.87 F1-skor ve %65.01 IoU elde edilmiştir. ESA sonuçlarına ÇÇB ile elde edilen görüntü bölütleri rafine işlemi için uygulandığında ise genel doğrulukta %2.83, F1-skor'da %3.07 ve IoU'da %4.84 artış olduğu görülmektedir. SegNet modelinde ise U-Net'e göre daha az miktarda artış görülmüştür. GD'de %0.7 ve IoU'da %1.34 artış görülürken, F1-skor'da %1.42 düşüş gerçekleşmiştir.


Elde edilen sonuçlara göre U-Net mimarisinin kullanılan deneylerde, U-Net+ÇÇB modelinin ölçütlerin tamamında sadece U-Net kullanımından daha başarılı olmuştur. SegNet mimarisinin kullanıldığı deneylerde de sadece bir test görüntüsündeki F1 skorda artış sağlayamamıştır. Bu deneylerde diğer tüm ölçütlerde yine SegNet+ÇÇB modeli en yüksek doğrulukları elde etmiş, sadece SegNet kullanılan tahmin değerlerindeki gürültüleri azaltmada etkin rol oynamıştır. Algoritmaların test verisi üzerindeki ortalama sonuçları Tablo 1'de sunulmuştur. Ayrıca her bir test görüntüsüne ait sınıflandırma haritaları Şekil 7-8'de gösterilmiştir.

**Tablo 1.** Algoritmaların test verisi üzerindeki sonuçları. Değerler % olarak verilmiştir.

ESA	Model	G.D	F1-skor	IoU	Dice
U-Net	ESA	85.06	84.17	65.35	66.47
	ESA+ÇÇB	88.98	89.32	72.19	73.93
SegNet	ESA	86.79	84.68	68.53	70.87
	ESA+ÇÇB	88.01	83.93	70.85	73.46

Sınıf bazlı sonuçlar incelendiğinde, U-Net algoritmasının kullanıldığı ESA+ÇÇB yaklaşımının hem bina hem de bina olmayan sınıfın metriklerini önemli ölçüde iyileştirdiği görülmüştür. Özellikle IoU metriğinde bina sınıfı için %8.88 performans artışı gözlemlenmiştir. Yine bina sınıfında ESA+ÇÇB modeli ile GD metriğinde %1.68 ve F1-skor metriğinde %3.56 artış sağlanmıştır. Bina olmayan sınıfının ESA modeli ile GD, F1-skor ve IoU değerleri sırasıyla %90,21, %84.03 ve %80.88 iken, ESA+ÇÇB modeli ile GD %95.48, F1-skor %90.78 ve IoU değeri %85.70'tir. U-Net modeline ait piksel tabanlı semantik segmentasyonda tahmin görüntülerinde yoğun

şekile tuz-biber etkisi bulunmaktadır. ÇÇB ile elde edilen görüntü nesnelere sayesinde bu gürültüler önemli oranda giderilmektedir. Böylece, özellikle referans veri ve tahmin verisi arasında sınıfların kesişim oranını ölçen IoU metriğinde yüksek oranda iyileşme sağlandığı gözlenmiştir. U-Net modelini içeren ESA ve ESA+ÇÇB'ye ait metrik sonuçları Tablo 2'de sunulmuştur. Tahmin görüntüleri ise Şekil 7'da sunulmuştur.




Şekil 7. U-Net ile ESA ve ESA+ÇÇB yaklaşımlarının test sonuçları ve referans görüntüsü.

Tablo 2. U-Net algoritmasının test görüntüleri üzerinde sınıf bazlı sonuçları. Değerler % olarak verilmiştir.

Model	Sınıf	Genel Doğruluk	F1-score	IoU
ESA	Bina olmayan	90.21	84.03	80.88
	Bina	64.66	84.31	49.80
ESA+ÇÇB	Bina olmayan	95.48	90.78	85.70
	Bina	66.34	87.87	58.68

U-Net modeline benzer şekilde, SegNet kullanılan ESA+ÇÇB yaklaşımı sayesinde semantik segmentasyonun doğruluğu GD ve IoU metriklerinin değerlerinde iyileştirilmektedir. Sadece bir test görüntüsünde F-1 skor metriğinde, az oranda bir düşüş görülmektedir. Bunun en önemli sebeplerinden birisi de ESA tarafından tam olarak tespit edilemeyen bina yapısının ESA+ÇÇB tarafından tamamen bina dışı sınıfa atanmasıdır.

Çünkü ESA modeli ile yüksek oranda tahmin edilemeyen bir piksel grubunun ESA+ÇÇB tarafından tahmin edilemediği görülmektedir. Dolayısıyla, ESA+ÇÇB modelinin performansının, kullanılan ESA modelinin tahmin kalitesine direkt bağlı olduğu da gözlenmiştir. SegNet ve ÇÇB beraber kullanıldığında bina sınıfının GD değeri %1.12 ve IoU değeri %3.17 oranlarında geliştirilmiştir. Bina olmayan sınıfta ESA+ÇÇB ile GD %90.68, F1-skor %86.46 ve IoU %83.65 olarak elde edilmiştir. SegNet modelini içeren ESA ve ESA+ÇÇB'ye ait metrik sonuçları Tablo 3'te sunulmuştur. Tahmin görüntüleri ise Şekil 8'dedir.




Şekil 8. SegNet ile ESA ve ESA+ÇÇB yaklaşımlarının test sonuçları ve referans görüntüsü.

Tablo 3. SegNet algoritmasının test görüntüleri üzerinde sınıf bazlı sonuçları. Değerler % olarak verilmiştir.

Model	Sınıf	Genel Doğruluk	F1-score	IoU
ESA	Bina olmayan	89.41	86.64	82.17
	Bina	68.94	82.72	54.88
ESA+ÇÇB	Bina olmayan	90.68	86.46	83.65
	Bina	70.06	81.41	58.05

ESA+ÇÇB yaklaşımının tuz-biber etkisini gidermenin yanı sıra bina kenarlarını belirginleştirmede de başarılı katkılar sağladığı görülmektedir. Ancak, ESA tarafından tahmin edilemeyen bir sınıf ESA+ÇÇB modeli tarafından da tahmin edilememektedir. ESA+ÇÇB yaklaşımı ESA modellerinin tahmin sonuçlarının ÇÇB ile üretilen

görüntü nesnelere sayesinde iyileştirilmesini amaçlamaktadır. Derin öğrenme mimarisinin tahmin görüntüsünde olmayan bir sınıfı ortaya çıkarması geliştirilen yöntemin amacının dışında kalmaktadır. Dice benzerliğinin görüntü bazlı gösterimi Şekil 9’da sunulmuştur.



**Şekil 9.** Referans görüntüler ile tahmin görüntüleri arasında hesaplanan Dice benzerliğinin gösterimi. Beyaz doğru tahminleri, mor yanlış negatif ve yeşil yanlış pozitif ifade etmektedir.

**Tablo 4.** WHUBED veri setinin kullanıldığı diğer çalışmalarla karşılaştırma.

Model	F1-skor (%)
MFBI (Bi et al., 2019)	77.31
Bi et al. (2019)	78.70
DeepLabV3+Xception (Atik ve Ipbuker, 2021)	82.64
DeepLabV3+ResNet18 (Atik ve Ipbuker, 2022)	84.96
U-Net + ÇÇB*	89.32
SegNet + ÇÇB*	83.93

\*Bu çalışma Tablo 4’te WHUBED veri seti kullanılan diğer çalışmaların sonuçlarıyla karşılaştırma yapılmıştır. Buna göre, bu çalışmada U-Net+ÇÇB yaklaşımı ile elde edilen F1-skor karşılaştırılan diğer çalışmalara göre iyileştirilmiştir.

#### 4. SONUÇLAR

Bu çalışmada VHR uydu görüntüleri üzerinden bina çıkarımında ESA modellerinin segmentasyon performansını iyileştirmek amacıyla ESA+ÇÇB modelinin kullanımına yönelik deneyler sunulmuştur. Deneylerde derin öğrenme mimarisi olarak U-Net ve SegNet modelleri kullanılmıştır. Her iki ESA modelinin ayrı ayrı kullanıldığı bina çıkarımı için, bir nesne tabanlı görüntü analizi yaklaşımı olan Çoklu-Çözünürlüklü Bölütleme (ÇÇB) algoritmasının modele entegrasyonu ile genel doğruluk, F1-skor ve IoU metriklerinde iyileştirmeler sağlanmıştır. Çalışmada ortaya konan yaklaşım ESA ve ÇÇB yaklaşımının entegrasyonunu belirtmek üzere ESA+ÇÇB olarak adlandırılmıştır. U-Net veya SegNet’in yanı sıra farklı derin öğrenme mimarilerinde de ESA+ÇÇB modelinin uygulanması mümkündür. Çalışmada farklı mekansal çözünürlüğe sahip uydu görüntülerini içeren WHUBED veri seti kullanılmıştır. Derin öğrenme uygulamalarında genelde, eğitim verisine çok benzer test verilerinde başarı sağlanırken, test verisi eğitimden farklılaştıkça performansta azalmalar gözlenir. Ancak bu çalışmada kullanılan veri seti birbirinden farklı 3 sensöre sahip ve farklı mekansal çözünürlükteki uydu görüntülerinden oluşmaktadır. Bu durumda, çalışmanın derin öğrenmenin dezavantajlarından olan bir konuda da çözüme katkı sağlayan yönde sonuçlar ortaya konduğu düşünülmektedir.

ESA+ÇÇB yaklaşımı IoU, Dice katsayısı ve F1-skor ölçütlerinde tek başına ESA kullanımının elde ettiği değerleri iyileştirmiştir. Bunun önemli bir nedeni, ESA tahmin sonucundaki tuz-biber görüntülerinin ESA+ÇÇB modeli ile önemli ölçüde giderilmesinden kaynaklanır. Ancak SegNet mimarisinin kullanıldığı yaklaşımda F1-skorda az da olsa düşüşün nedeni, bazı binaların alanlarını SegNet mimarisi U-Net kadar bütün çıkaramadığından; ESA+ÇÇB modelinin filtreleme etkisi ile küçük bina alanlarının daha da küçülmesinden kaynaklanmaktadır. Ancak bu dezavantaj U-Net’in kullanıldığı ESA+ÇÇB modelinin uygulanmasında geçerli değildir. Bu çalışmada ESA+ÇÇB modeli ile, F1-Skor da dahil olmak üzere tüm metriklerde iyileştirme sağlanmıştır.

Derin öğrenme algoritmalarının kullanımının birçok alanda olduğu gibi sahip olduğu avantaj ve dezavantajların kullanım alanı ve kapsamına göre ele alınması önem arz etmektedir. Örneğin bina sınıflandırması uygulamalarında, derin öğrenme mimarilerinin tercihi otomatik sınıflandırma yaklaşımına imkân tanırken aynı zamanda işlem yükü (özellikle kullanılan teknolojik cihazların GPU kapasitesindeki kısıtlar) dezavantajları arasında sayılabilir. Sunduğu hızlı çözüm elde etme imkanı rağmen, ESA mimarilerinin piksel bazlı tahminlerindeki tuz biber etkisiyle oluşan görüntüler de yine dezavantajlardan biri olarak sayılabilir. Ancak bu çalışmada ESA ve NTGA algoritmalarından olan ÇÇB algoritmasının entegrasyonu sayesinde,

sınıflandırmada karşımıza çıkan gürültü miktarlarını azaltma imkânı ortaya konmuştur. Bu sayede bina çıkarımında elde edilen bina sınıfının daha bütün ve sınırları daha düzgün şekilde elde edilme imkânı oluşmuştur. Bina sınır problemleri, pafta üzerindeki sınır koordinatlar gibi daha birçok meselenin uygulamalarında ESA+ÇÇB modeli ile hem derin öğrenme sınıflandırmasının avantajlarından yararlanılırken hem de elde edilen nesne-tabanlı yaklaşımın sınıflandırmada pikseller yerine görüntüdeki nesnelere ile daha bütünsel ürün şeklinde üretilmesi söz konusudur. Gelecek çalışmalarda çoklu-sınıf içeren arazi örtüsü haritalarının hızla ve güvenilir güncellenmesinde ESA+ÇÇB modeli kullanılabilir. AKAÖ veri tabanlarının (CORINE, AfriCover vb.) otomatik oluşturulmasında çok bantlı veri setleri ile ESA+ÇÇB modelinin kullanım alanları daha çok genişletilebilir.

#### Araştırmacıların katkı oranı beyan özeti

Yazar çalışmaya %100 oranında katkı sağlamıştır.

#### Çıkar çatışması beyanı

Makale ile ilgili olarak, herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

#### Araştırma ve yayın etiği beyanı

Yapılan çalışmada yazar, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul izni gerektirmediğini beyan etmektedir.

#### KAYNAKÇA

- Abdollahi, A., Pradhan, B., & Alamri, A. M. (2022). An ensemble architecture of deep convolutional Segnet and U-net networks for building semantic segmentation from high-resolution aerial images. *Geocarto International*, 37(12), 3355-3370.
- Ali, K., & Johnson, B. A. (2022). Land-Use and Land-Cover Classification in Semi-Arid Areas from Medium-Resolution Remote-Sensing Imagery: A Deep Learning Approach. *Sensors*, 22(22), 8750.
- Arıkan, D. & Yıldız, F. (2023). Göktürk-1 Uydu Görüntülerinden U-Net Modeli Kullanılarak Binaların Segmentasyonu . *Türkiye Uzaktan Algılama Dergisi*, 5 (1) , 50-58 . DOI: 10.51489/tuzal.1300939
- Atik, S. O., & Ipbuker, C. (2021). Integrating convolutional neural network and multiresolution segmentation for land cover and land use mapping using satellite imagery. *Applied Sciences*, 11(12), 5551.
- Atik, S. O., Atik, M. E., & Ipbuker, C. (2022). Comparative research on different backbone

architectures of DeepLabV3+ for building segmentation. *Journal of Applied Remote Sensing*, 16(2), 024510-024510.

- Atik, S. O., & Ipbuker, C. (2022). Building Extraction in VHR Remote Sensing Imagery Through Deep Learning. *Fresenius Environ. Bull*, 31, 8468-8473.
- Attri, P., Chaudhry, S., & Sharma, S. (2015). Remote sensing & GIS based approaches for LULC change detection—A review. *Int. J. Curr. Eng. Technol*, 5, 3126-3137.4e
- Baatz, M. (2000). Multi resolution segmentation: an optimum approach for high quality multi scale image segmentation. In *Beiträge zum AGIT-Symposium*. Salzburg, Heidelberg, 2000 (pp. 12-23).
- Badrinarayanan V., Kendall A. and Cipolla R., (2017) SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 12, pp. 2481-2495, 1 Dec., doi: 10.1109/TPAMI.2016.2644615.
- Balarabe, A. T., & Jordanov, I. (2021). LULC image classification with convolutional neural network. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS* (pp. 5985-5988). IEEE.
- Baştuğ Koç, A., Akgün, D. (2021). U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 407-414.
- Bi, Q., Qin, K., Zhang, H., Zhang, Y., Li, Z., & Xu, K. (2019). A multi-scale filtering building index for building extraction in very high-resolution satellite imagery. *Remote Sensing*, 11(5), 482.
- de Pinho, C. M. D., Fonseca, L. M. G., Korting, T. S., De Almeida, C. M., & Kux, H. J. H. (2012). Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis. *International Journal of Remote Sensing*, 33(19), 5973-5995.
- Dewali, S. K., Jain, K., Varshney, D., Dhamija, S., & Pundir, E. (2023). Combining OBIA, CNN, and UAV Photogrammetry for Automated Avalanche Deposit Detection and Characterization. *Advances in Space Research*. 72(8), 3109-3132.
- Ghorbanzadeh, O., Gholamnia, K., & Ghamisi, P. (2022). The application of ResU-net and OBIA for landslide detection from multi-temporal sentinel-2 images. *Big Earth Data*, 1-26.

- Ghorbanzadeh, O., Tiede, D., Wendt, L., Sudmanns, M., & Lang, S. (2021). Transferable instance segmentation of dwellings in a refugee camp-integrating CNN and OBIA. *European Journal of Remote Sensing*, 54(sup1), 127-140.
- Hossain, M. D., & Chen, D. (2019). Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150, 115-134.
- Ji, S., Wei, S., & Lu, M. (2019). A scale robust convolutional neural network for automatic building extraction from aerial and satellite imagery. *International journal of remote sensing*, 40(9), 3308-3322.
- Kaiser, P., Wegner, J. D., Lucchi, A., Jaggi, M., Hofmann, T., & Schindler, K. (2017). Learning aerial image segmentation from online maps. *IEEE Transactions on Geoscience and Remote Sensing*, 55(11), 6054-6068.
- Kawamura, K., Asai, H., Yasuda, T., Soisouvanh, P., & Phongchanmixay, S. (2021). Discriminating crops/weeds in an upland rice field from UAV images with the SLIC-RF algorithm. *Plant Production Science*, 24(2), 198-215.
- Kurnaz, E., & Ceylan, R. (2020, October). Pancreas segmentation in abdominal CT images with U-Net model. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Li, H., Tian, Y., Zhang, C., Zhang, S., & Atkinson, P. M. (2022). Temporal sequence Object-based CNN (TS-OCNN) for crop classification from fine resolution remote sensing image time-series. *The Crop Journal*, 10(5), 1507-1516.
- Liu, T., Yang, L., & Lunga, D. (2021). Change detection using deep learning approach with object-based image analysis. *Remote Sensing of Environment*, 256, 112308.
- Manaf, S. A., Mustapha, N., Sulaiman, M. N., Husin, N. A., Shafri, H. Z. M., & Razali, M. N. (2018). Hybridization of SLIC and Extra Tree for Object Based Image Analysis in Extracting Shoreline from Medium Resolution Satellite Images. *International Journal of Intelligent Engineering & Systems*, 11(1).
- Marcu, A., & Leordeanu, M. (2016). Dual local-global contextual pathways for recognition in aerial imagery. *arXiv preprint arXiv:1605.05462*.
- Merchant, M. A. (2021). Classification of open water features using OBIA and deep learning. In *2021 IEEE international geoscience and remote sensing symposium IGARSS* (pp. 104-107). IEEE.
- Pan, Z., Xu, J., Guo, Y., Hu, Y., & Wang, G. (2020). Deep learning segmentation and classification for urban village using a worldview satellite image based on U-Net. *Remote Sensing*, 12(10), 1574.
- Qin, Y., Wu, Y., Li, B., Gao, S., Liu, M., & Zhan, Y. (2019). Semantic segmentation of building roof in dense urban environment with deep convolutional neural network: A case study using GF2 VHR imagery in China. *Sensors*, 19(5), 1164.
- Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science, vol 9351. Springer, Cham. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Lee, S. H., & Baik, J. J. (2011). Evaluation of the vegetated urban canopy model (VUCM) and its impacts on urban boundary layer simulation. *Asia-Pacific Journal of Atmospheric Sciences*, 47, 151-165.
- Tang, Z., Li, M., & Wang, X. (2020). Mapping tea plantations from VHR images using OBIA and convolutional neural networks. *Remote Sensing*, 12(18), 2935.
- Thenkabail, P. S., Schull, M., & Turrall, H. (2005). Ganges and Indus river basin land use/land cover (LULC) and irrigated area mapping using continuous streams of MODIS data. *Remote Sensing of Environment*, 95(3), 317-341.
- Tian, J., & Chen, D. M. (2007). Optimization in multi-scale segmentation of high-resolution satellite images for artificial feature recognition. *International Journal of Remote Sensing*, 28(20), 4625-4644.
- Torunlar, H., Tuğaç, M. G. & Duyan, K. (2021). Nesne Tabanlı Sınıflandırma Yönteminde Sentinel-2A Uydu Görüntüleri Kullanılarak Tarımsal Ürün Desenlerinin Belirlenmesi; Konya - Karapınar Örneği . *Türkiye Uzaktan Algılama Dergisi*, 3 (2) , 36-46 . DOI: 10.51489/tuzal.932912
- Wang, M. (2008). A multiresolution remotely sensed image segmentation method combining rainfalling watershed algorithm and fast region merging. *Int. Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37, 1213-1217.

Xu, Z., Su, C., & Zhang, X. (2021). A semantic segmentation method with category boundary for Land Use and Land Cover (LULC) mapping of Very-High Resolution (VHR) remote sensing image. *International Journal of Remote Sensing*, 42(8), 3146-3165.


Yi, Y., Zhang, Z., Zhang, W., Zhang, C., Li, W., & Zhao, T. (2019). Semantic segmentation of urban buildings from VHR remote sensing imagery using a deep convolutional neural network. *Remote sensing*, 11(15), 1774.



© Author(s) 2023.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>






## Türkiye Uzaktan Algılama Dergisi

<https://dergipark.org.tr/tr/pub/tuzal>

e-ISSN 2687-4997



# Sentinel-2A Verileriyle Trabzon İli 2019-2020 Yılları Arasında Ortaya Çıkan Sınıflandırma Farklarının Çeşitli Algoritmalarla Değerlendirilmesi

Hasan Bilgehan Makineci\*<sup>1</sup>, Esmâ Nur Akosman<sup>1</sup>

<sup>1</sup>Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, Konya, Türkiye

### Anahtar Kelimeler:

Sentinel-2a  
NDVI  
Sınıflandırma Yöntemleri  
Rastgele Orman

### ÖZ

Çevre durum raporları yayınlandıkları yıllar itibarıyla ilgili şehrin ve çevresinin durumunu ortaya koyan önemli dokümanlardır. Trabzon İli ve çevresini kapsayan 2021 çevre durum raporundan yola çıkarak 1/100000 ölçekli çevre düzenleme planı (ÇDP) sınıflandırmasında yeşil alanların azalmakta olduğu fark edilmiştir. Bu çalışmada Trabzon İli yeşil alanların değişiminin 2019-2020 yılları arasında farklı kontrollü-kontROLSÜZ sınıflandırma yöntemleri ve makine öğrenmesi algoritmalarından rastgele orman (RO) algoritmasıyla incelenmesi sağlanmıştır. Değişimin izlenmesinde Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), kontrollü, kontROLSÜZ ve RO algoritmasıyla sınıflandırma işlemleri gerçekleştirilmiştir. Çalışma alanının Sentinel-2A uydu veri setleriyle, 2019 yılı Mayıs ile 2020 yılı Mayıs ayları arasındaki, 10 m mekânsal çözünürlükteki bant kompozitleri kullanılarak ve NDVI işlemi gerçekleştirilerek sınıflandırma sonuçları değerlendirilmiştir. Sonuç olarak gerçekleştirilen kontrollü sınıflandırma işlemi sonucunda 2019 yılı için genel doğruluk oranı %100.0 iken 2020 yılı için genel doğruluk oranı %81.31 olarak elde edilmiştir. Uydu görüntülerinde makine öğrenmesi algoritmalarından RO algoritmasıyla sınıflandırma işlemi de gerçekleştirilmiştir ve genel doğruluk oranı %97.6 olarak elde edilmiştir.

## Evaluation of Classification Differences Occurring Between 2019-2020 in Trabzon Province with Sentinel-2A Data Using Different Algorithms

### Keywords:

Sentinel-2a  
NDVI  
Classification Methods  
Random Forest

### ABSTRACT

Environmental status reports are important documents that reveal the situation of the relevant city and its surroundings as of the years they were published. Based on the 2021 environmental status report covering Trabzon Province and its surroundings, it has been noticed that green areas are decreasing in the 1/100000 scale environmental arrangement plan (EAP) classification. This study examined the change in the green regions in Trabzon Province with different controlled-uncontrolled classification methods and random forest (RF) algorithm, one of the machine learning algorithms, between 2019 and 2020. In monitoring the change, classification processes were carried out with Normalized Difference Vegetation Index (NDVI), controlled, uncontrolled, and RO algorithm. Classification results were evaluated using the Sentinel-2A satellite data sets of the study area between May 2019 and May 2020, using band composites with 10 m spatial resolution and performing NDVI processing. As a result, as a result of the controlled classification process, the general accuracy rate for 2019 was 100.0%, while the general accuracy rate for 2020 was 81.31%. Classification of satellite images was also carried out with the RO algorithm, one of the machine learning algorithms, and the overall accuracy rate was obtained as 97.6%.

### Makale Bilgileri/Article Info

Geliş /Received: 31/10/2023  
Kabul/Accepted: 29/11/2023  
Yayınlanma/Published: 30/12/2023

### Alıntı/Citation:

Makineci, H.B., Akosman, E.N. (2023). Sentinel-2A Verileriyle Trabzon İli 2019-2020 Yılları Arasında Ortaya Çıkan Sınıflandırma Farklarının Çeşitli Algoritmalarla Değerlendirilmesi. Türkiye Uzaktan Algılama Dergisi ,5 (2) , 78-88.

## 1. GİRİŞ

Türkiye'nin doğal bitki örtüsü, insanların yaşamsal faaliyetlerini gerçekleştirebilmesi ve barınma ihtiyacını karşılaması amacıyla zamanla deformasyona uğramıştır. Bu deformasyonlar doğal bitki örtüsünü olumsuz yönde etkilemektedir (Dönmez ve Aydınözü, 2013). Doğal bitki örtüsünün tahrip edilmesinde en büyük nedenlerden birisi kentleşmedir. Hava kirliliği, su kirliliği ve toprak erozyonu kentleşmenin çevre üzerindeki olumsuz sonuçlarından bazıları iken, yeşil alanların yok olması toprak erozyonunun en belirgin göstergesidir (Aksoy ve Ergun, 2009).

Arazi örtüsü kullanımı bölgelerin fiziksel, sosyolojik ve idari yapısına göre değişim göstermektedir. Bu kapsamda doğal bitki örtüsünün tahrip edilmemesi için karar vericilerin bu konuyla ilgili stratejik planlar oluşturmaları gerekmektedir. 20. Yüzyılın sonlarından itibaren gelişen uzaktan algılama teknikleri ve Coğrafi Bilgi Sistemleri (CBS), birçok noktada daha verimli, daha hızlı, daha hassas kararlar verebilmeyi sağlamaktadır (Dereli, 2019). Arazi kullanım haritaları, birçok bilimsel ve çevresel uzaktan algılama uygulamaları için önemli bilgiler temin etmektedir. Teknolojinin ilerlemesi ve uyduların çoğalmasıyla birlikte uydu görüntüleri bu haritaların hızlı ve güvenilir bir şekilde yapılmasına yardımcı olmaktadır (Belward, 2014). Bu anlamda arazi kullanım haritalarının hızlı ve güvenilir olarak üretilmesinde görüntü sınıflandırma işlemi en yaygın kullanılan uzaktan algılama tekniklerinden biridir (Akar ve Görmüş, 2019).

Bitki örtüsü değişimlerinin yıllara göre izlenebilmesi için çeşitli görüntü sınıflandırma yöntemleri mevcuttur (Karakuş, 2017). Görüntü sınıflandırması piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma olmak üzere iki kısma ayrılmaktadır (Jensen, 2006; Platt ve Rapoza, 2008; Weih ve Riggan, 2010; Myint ve ark., 2011; Whiteside vd., 2011). En Çok Benzerlik (EÇB) yöntemi en çok kullanılan sınıflandırma algoritmalarından biridir (Akar ve Güngör, 2013). Her banttaki her sınıf için görüntü verisi EÇB algoritması tarafından normal dağılımda kabul edilir. Bir EÇB prosedüründe, belirli bir piksel birkaç kategoriden birine girebilir. Sonuç olarak, her pikselin olasılığı belirlenir ve daha sonra en yüksek olasılığa sahip sınıfa atanır (Akar ve Güngör, 2013). Fakat nesne tabanlı tekniklerde pikseller, daha doğru sonuçlar üretmek için uzamsal özelliklerine göre gruplandırılır. Nesnelerin spektral özelliklerinin yanı sıra şekli ve dokusu gibi temel özelliklerine göre sınıflandırma obje tabanlı sınıflandırma yöntemlerine uygundur (Dronova vd., 2011) Şekil, yoğunluk ve ölçek gibi kriterlerden üretilen bilgi gruplarını gösteren objelere göre görüntüyü parçalara ayıran obje tabanlı sınıflandırma yöntemlerinde elde edilen parçalar ayrı ayrı sınıflara tanımlanır. Böylece objeler farklı üyelik değerleri ile birden fazla sınıfa tanımlanabilmektedir (Matinfar, 2007).

Piksel ve nesne tabanlı yöntemlere alternatif olarak, uydu fotoğraflarından daha doğru ve güvenilir bilgiler elde etmek için günümüzde birkaç öğrenme tabanlı algoritma geliştirilmektedir. En popüler öğrenme tabanlı algoritmalar K-En Yakın Komşuluk, Destek Vektör Makinesi (DVM), Karar Ağacı (KA), Rastgele Orman (RO) ve Yapay Sinir Ağlarıdır (YSA). Bu algoritmalara makine öğrenme teknikleri denir. Makine öğrenimi teknikleri, istatistiksel tekniklerin aksine verilerin dağılımı hakkında herhangi bir varsayımda bulunmadıkları için parametrik değildir. Tahmin edici ve ilgili cevaplar arasındaki ilişkiler, veriye dayalı makine öğrenimi teknikleri kullanılarak öğrenilir. Makine öğrenimi tekniklerinin amacı, girdi verilerinden ve yeterince büyük parametrelerden çıkarılan karar kurallarını kullanarak veri için en iyi modeli belirlemektir (Breiman, 2001).

RO, ağaç tipi sınıflandırıcılar topluluğu olarak tanımlanabilir. RO, torbalama yöntemine rastgelelik özelliğinin eklenmesiyle geliştirilen bir versiyondur (Breiman, 2001). Her düğümde rastgele seçilen en iyi değişkeni kullanarak her düğümü birleştirmek yerine, RO tüm değişkenler arasında en iyi dalı kullanarak her düğümü dallandırır. Her bir veri kümesini oluşturmak için orijinal veri kümesinden yer değiştirme ve ağaçlar oluşturmak için rastgele özellik seçimi kullanılır. Gelişmiş alanlarda hiçbir ağaç budanmamaktadır (Archer 2008; Breiman 2001). Bu taktik nedeniyle RO'nun hassasiyeti rakipsizdir. Hızlı ve fazla takılmaya karşı dirençli olan RO ile gerektiği kadar ağaç kullanılabilir (Breiman ve Cutler 2005). Sınıflandırmada birincil düğümden kaç ek düğümün izole edilebileceğine karar veren faktör sayısı ve ağacın kullanıcı tarafından ne kadar büyütüleceğini belirleyen ağaç sayısı seçilir. Rastgele ormanların birçok gerçek dünya sorunu için iyi performans gösterdiği kanıtlanmıştır (Breiman 2001, Comert ve vd. 2019, Sevgen 2019).

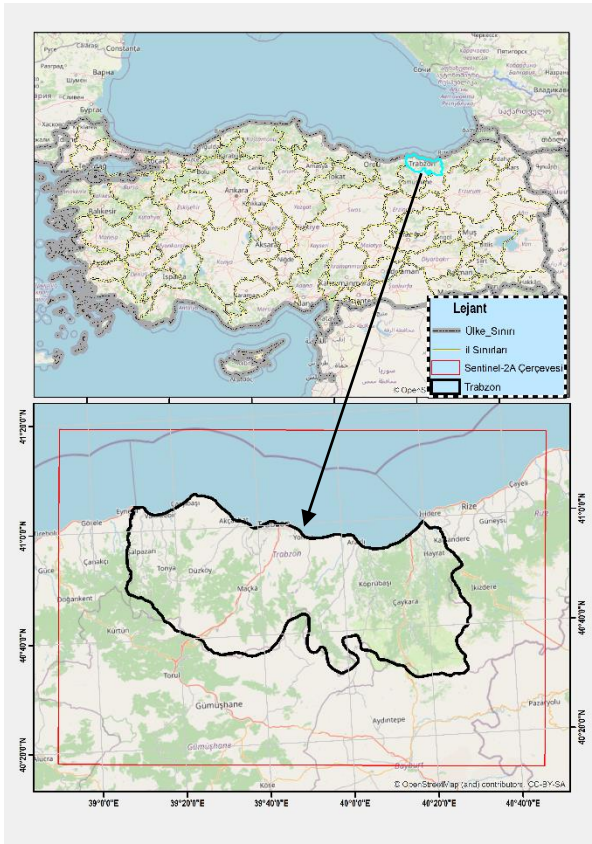
Bu çalışmada Copernicus programı kapsamında geliştirilen Sentinel uydu sistemlerinden optik algılayıcıya sahip Sentinel-2A uydusunun 2019 ve 2020 yılları mayıs ayına ait Sentinel-2 MSI (Multispectral Instrument), Level-2a uydu görüntüleri kullanılmıştır. Bu çalışmada 2019-2020 yılları arasında yayınlanan ÇDP'ye göre Trabzon İli yeşil alan değişimlerinin makine öğrenmesi algoritmalarından biri olan RO algoritmasıyla ve kontrollü kontrolsüz farklı sınıflandırma yöntemleriyle yüksek doğrulukla belirlenmesi amaçlanmıştır. Görüntülerin sınıflandırılmasında öncelikle 10m çözünürlüğe sahip bantlarla Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI) analizi gerçekleştirilmiştir. Mekânsal çözünürlüğü 10m olan bant kompozitleri kullanılarak kontrollü sınıflandırma yöntemlerinden biri olan ve yaygın olarak kullanılan EÇB yöntemiyle kontrollü sınıflandırma işlemi gerçekleştirilmiştir. Aynı zamanda çalışmada görüntülerin sınıflandırılması işleminde makine öğrenmesi algoritmalarından biri olan RO algoritması kullanılmıştır. Trabzon İli çevre

durum raporlarında görülen yeşil alanlarla alakalı sorunların araştırılmış olması da çalışmanın önemini ortaya koymaktadır.

## 2. YÖNTEM

### 2.1. Çalışma Alanı

Bu çalışmada belirlenen araştırma alanı Trabzon İli olarak belirlenmiştir. Trabzon, 41° 0' 9.7092" kuzey enlemi ve 39° 43' 0.3468" doğu boylamında bulunmaktadır. Trabzon'un genel yamaç eğimleri %12'nin üzerindedir. Başlıca tarım ürünleri fındık, çay, patates, mısır, tütün, buğday ve fasulyedir. Fındıktan sonra armut, kiraz ve turuncgiller oldukça fazla yetişir. Çalışma bölgesinin haritadaki yeri Şekil 1.'de belirtilmiştir.



Şekil 1. Çalışma alanı

### 2.2. Uzaktan Algılama Verileri

Çalışma alanının yeşil alan değişiminin belirlenmesine yönelik yapılan görüntü sınıflandırması için Sentinel-2A uydu görüntüleri ve bu görüntülerden elde edilen NDVI analizi, kontrolsüz, kontrollü sınıflandırma ve RO algoritmasıyla sınıflandırma materyal olarak kullanılmıştır.

Avrupa Uzay Ajansı (ESA), orta mekânsal çözünürlüklü çok bantlı bir algılayıcı olan Sentinel-2 uydusunu kullanıcılara sunmuştur. Sentinel-2 uydusu, yüksek mekânsal çözünürlüğü, yeni spektral bantları, geniş alanlı veri toplama ve beş gün içinde veri alma kapasitesi nedeniyle birçok uygulamada çok işlevseldir (Malenovský vd., 2012).

Sentinel-2 uydu görüntüleri toplamda 13 farklı banttan oluşmasına rağmen, özellikle hem kısa dalga hem de yakın kızılötesi bantların koyu yeşil görünen bitki örtüsünü vurgulamada başarılı olmasından dolayı çoğunlukla bitki gelişiminin izlenmesi gibi tarımsal uygulamalarda sırası ile B2, B3, B4, B8 ve B11 (mavi (B), yeşil (G), kırmızı (R), yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bantları kullanılmaktadır (URL-1) (Tablo 1).

**Tablo 1.** Sentinel-2 uydu görüntüleri, bantlara göre çözünürlükleri ve kullanım alanları (URL-2)

Bant	Açıklama	Mekânsal Çözünürlük (m)
B1	Ultra Mavi	60
B2	Mavi	10
B3	Yeşil	10
B4	Kırmızı	10
B5	(VNIR)*	10
B6	(VNIR)	20
B7	(VNIR)	20
B8	(VNIR)	10
B8A	(VNIR)	20
B9	(SWIR)**	60
B10	(SWIR)	60
B11	(SWIR)	20

\*Görünür ve yakın kızılötesi

\*\*Kısa dalga kızıl ötesi

Her beş günde bir, 10, 20 ve 60 m mekânsal çözünürlüklerle veriler toplanmaktadır. Atmosfer koşullarının veriler üzerinde etkisi olduğundan, elde edilen tüm veriler kullanılmaya uygun değildir. Uydu görüntülerindeki bulutluluk oranları, özellikle tarımsal amaçlar için kullanılabilirliklerini kısıtlamaktadır (Torunlar vd., 2021). Araştırmada, atmosfer altı yansıma değerlerine sahip Sentinel-2A uydu görüntüsü seviyesi 2A verileri kullanılmıştır. NDVI indeksi, birkaç uydu resmi bantı kullanılarak oluşturulmuştur ve görüntü sınıflandırmasının doğruluğunu geliştirmek için ek veri olarak kullanılmıştır.

### 2.3. Çevre Durum Raporu ve Çevre Düzeni Planı

Çalışmada Çevre, Şehircilik ve İklim Değişiklikleri Bakanlığı Mekânsal Planlama Genel Müdürlüğü'nün yayınlamış olduğu Ordu-Trabzon-Rize-Giresun-Gümüşhane-Artvin Planlama Bölgesi 1/100.000 ölçekli Çevre Düzeni Planı'na (ÇDP) Trabzon İline ait plan paftalar sayısallaştırılarak kullanılmıştır. Ayrıca Trabzon Valiliği, Çevre ve Şehircilik İl Müdürlüğü ÇED Hizmetleri ve Çevre İzinleri Şube Müdürlüğü tarafından hazırlanan Çevre Durum Raporu dikkate alınarak kullanılmıştır (URL-3).

## 2.4. NDVI Analizi

NDVI, herhangi bir alanda yer alan bitki örtüsünün yoğunluğunu, sağlıklı veya sağlıklı olmama durumunu analiz ederek ortaya koyan bir indekstir. Uzaktan algılamada bitki örtüsünün durumunun izlenmesinde en çok tercih edilen yöntemlerden biri olan NDVI analizi, uydu görüntülerinin çeşitli bantlarını kullanarak gerçekleştirilmektedir. NDVI değerleri Eşitlik 1'deki standart formül ile hesaplanmaktadır (Carlson, & Ripley, 1997; Karakuş, 2017; Kaya & Polat, 2021).

$$\frac{(NIR-RED)}{(NIR+RED)} \quad (1)$$

NDVI analizi sonucunda elde edilen değerler -1 ile +1 arasında değişmektedir. Sağlıklı ve yoğun bitki örtüsünün fazla olduğu yerlerde indeks değerleri +1'e doğru yaklaşırken, sağlıklı ve zayıf bitki örtüsünün fazla olduğu yerlerde indeks değeri 0'a doğru yaklaşmaktadır. NDVI 0 değerinden düşük durumlarda genelde yeşil bitki varlığından söz edilmemektedir (Carlson, & Ripley, 1997; Kaya & Polat, 2021)

## 2.5. Kontrolsüz Sınıflandırma Yöntemi

Bir kullanıcı bir görüntüde bulunan arazi örtüsünün sayısından emin olmadığında, denetimsiz veya kontrolsüz sınıflandırma olarak da bilinen sınıflandırma, uygulamak için iyi bir tekniktir. Denetimsiz sınıflandırma, yalnızca sınıf numaralarını kullanarak piksellerin sınıflandırılmasını sağlar. Iso kümesi denetimsiz sınıflandırma adı verilen bir coğrafi işlem teknolojisi, müdahale olmadan girdi raster bantlarına dayalı olarak verileri sınıflandırır (Nijhawan, vd., 2017; Lemenkova, 2021).

Denetimsiz piksel tabanlı görüntü sınıflandırma yöntemi, kullanıcıdan bağımsız bir yöntem kullanır. Bu teknik, bir algoritmadaki pikselleri, spektral değerlerinin ne kadar benzer olduğuna bağlı olarak kümeler halinde gruplandırır. Her piksel, spektral değerlerin nasıl gruplandığına bağlı olarak algoritma tarafından sınıflandırılır. Raster sınıflandırması otomatik bir süreç olmasına rağmen, kullanıcıların hangi özelliğin veya nesnenin kategorize edildiğini belirlemek için sınıflandırılmış kümeleri kaydetmesi gerekir (Vlachou, vd., 2016).

## 2.6. En Çok Benzerlik Yöntemi

İstatistiksel temeli olan bir sınıflandırma yaklaşımı EÇB yönteminde ortalama değerler, varyans ve kovaryans değerlerinin tümü dikkate alınır. Bu değerlendirme aşamasında sınıf kontrol kümelerindeki verilerin normal bir dağılıma sahip olması beklenir. Sınıflandırılması gereken pikseller, olasılık yoğunluk fonksiyonları oluşturulduktan sonra sınıflandırma aşamasında üyelik olasılıkları en büyük olan sınıflara atanır. İlgili pikseller, kendileri için türetilen sınıfların olasılık değerlerinin önceden

belirlenmiş eşik değerinin altına düşmesi durumunda belirsiz olarak etiketlenir. (Myung, 2003; Çolkesen, 2009; Günlü, 2012; Topaloğlu vd.; 2016).

## 2.7. Rastgele Orman Algoritması

Denetimli sınıflandırma tekniklerinden biri de RO algoritmasıdır. Hem sınıflandırma hem de regresyon problemleri RO kullanır. Sınıflandırma aşaması boyunca sınıflandırma değerini iyileştirmek için algoritma çok sayıda karar ağacı oluşturur. Karar ormanı, RO algoritması tarafından üretilen bireysel karar ağaçlarından oluşur. Burada karar ağaçları, rastgele seçilen veri kümesinin alt kümelerine bağlanır. En yüksek oyu alan sınıf, RO'daki her ağaç tarafından modelin tahmini olarak seçilir (Breiman, 2001; Breiman ve Cutler 2005).

RO pek çok veri seti için Adaboost ve DVM'den daha kesin sonuçlara sahiptir ve oldukça kısa sürede sonuç verir. Veri biliminde, RO modelinin bu kadar iyi çalışmasının nedeni bir komite olarak faaliyet gösteren çok sayıda nispeten ilişkisiz modelin (ağaç), bireysel kurucu modellerden herhangi birinden daha iyi performans göstermesidir. RO algoritmasında işlem akışı 3 adımdan oluşur:

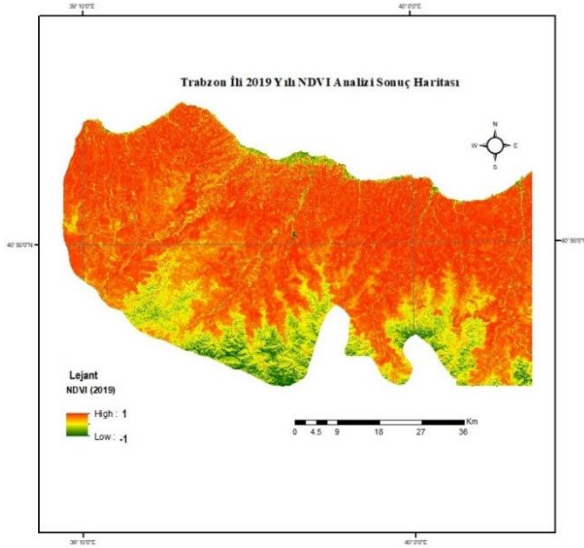
- Adım 1: RO' da, "k" kayıt sayısına sahip veri kümesinden n sayıda rastgele kayıt alınır.
- Adım 2: Her örnek için ayrı ayrı karar ağaçları oluşturulur.
- Adım 3: Her karar ağacı bir çıktı üretir.
- Adım 4: Nihai çıktı, çoğunluk oylamasına veya sınıflandırma ve regresyon ortalamasına göre değerlendirilir (Akar & Güngör, 2013; Akar & Görmüş, 2017; Makineci, 2023).

## 3. BULGULAR

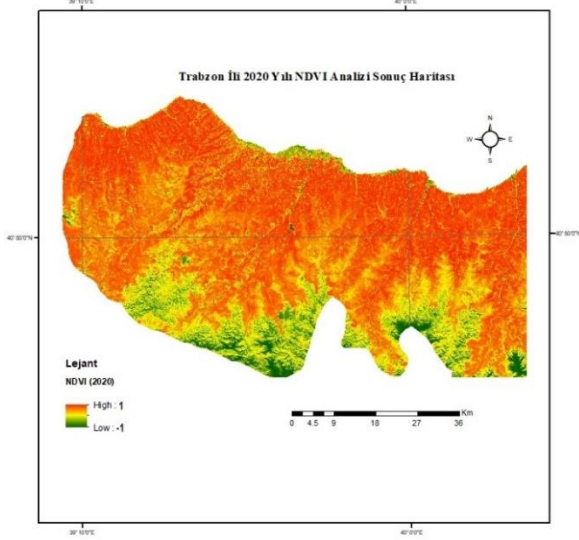
Çalışma alanını kapsayan 2019 ve 2020 yılları mayıs aylarına ait uydu görüntüleri, alanı sınırlarınca kesilerek sınıflandırmada kullanılmıştır. Bu işlemler için; CBS yazılımı olan ArcMap programı kullanılmıştır.

Uydu görüntüleri üzerinden NDVI analizi gerçekleştirilmiştir. Bu aşamada indirilen uydu görüntülerinin WGS84 UTM Zone-37N projeksiyon sistemine dönüşümü sağlandıktan sonra 10m çözünürlüğe sahip olan 4. ve 8. bantlar CBS yazılımına aktarılmıştır.

NDVI işlemi tamamlanan uydu görüntüsünden çalışma bölgesi olan Trabzon İli, İl sınırları kullanılarak kesilmiştir. NDVI analizi işlemi 2019 ve 2020 yılına ait uydu görüntülerinin her ikisine de sırasıyla uygulanmıştır. NDVI analizi sonucu oluşan haritalar Şekil 2 ve Şekil 3'te sunulmaktadır.



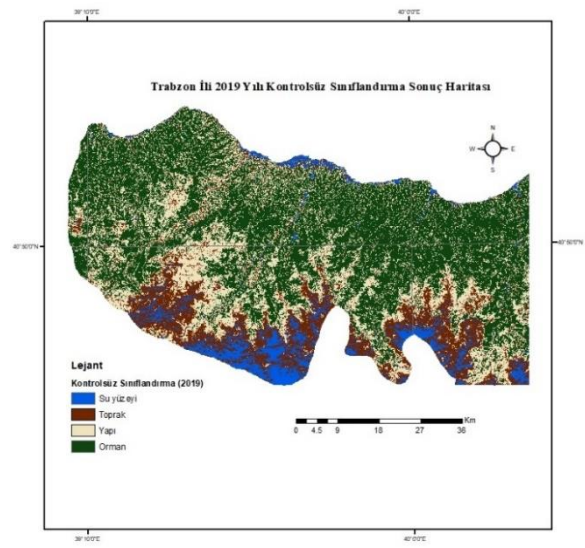
Şekil 2. Trabzon İli 2019 yılı NDVI haritası



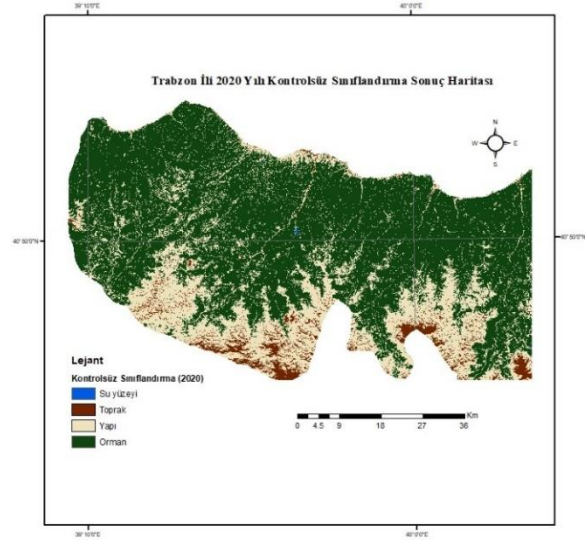
Şekil 3. Trabzon İli 2020 yılı NDVI haritası

NDVI analizi sonucu yıllara göre elde edilmiş olan uydu görüntülerinde CBS yazılımında bulunan kontrolsüz piksel tabanlı sınıflandırma (iso cluster unsupervised classification) aracı kullanılarak kontrolsüz sınıflandırma işlemi gerçekleştirilmiştir. Yıllara göre NDVI değişimine baktığımızda 2019 yılında bitkilerin 2020 yılına oranla daha sağlıklı olduğu tespit edilmiştir.

Yapılan kontrolsüz sınıflandırma işleminde 4 adet sınıf belirlenmiştir. Bunlar; su yüzeyi, toprak, yapı ve orman sınıflarıdır. Kontrolsüz sınıflandırma daha önce de belirtildiği gibi kullanıcının müdahalesinin bulunmadığı ve tamamen yazılım tarafından yapılan bir sınıflandırma yöntemi olduğundan CBS yazılımında gerçekleştirilmiştir. Sonuç haritalar aşağıda verilmiştir (Şekil 4 ve 5).



Şekil 4. Trabzon İli 2019 yılı kontrolsüz sınıflandırma haritası



Şekil 5. Trabzon İli 2020 yılı kontrolsüz sınıflandırma haritası

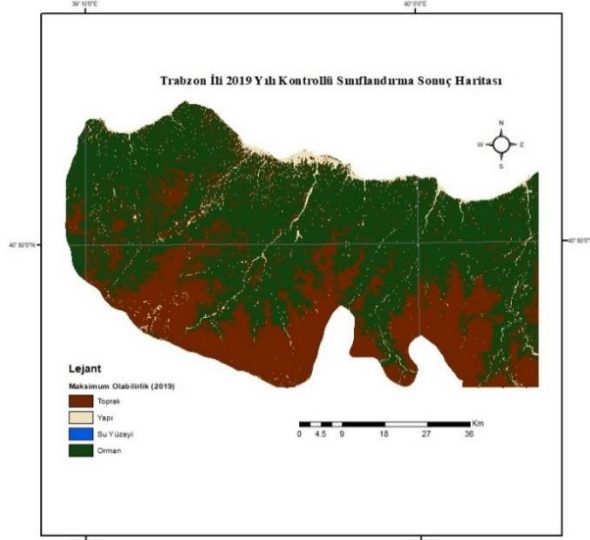
2019 ve 2020 yılları mayıs ayı verileri kullanılarak yapılan kontrolsüz sınıflandırma işlemi sonucunda oluşan haritaların karşılaştırılması sonucunda azımsanamayacak büyüklükte bir fark olduğu görülmüştür.

Çalışmada kontrollü sınıflandırma işlemlerinde 10m. mekânsal çözünürlüğe sahip bantlar kullanılmıştır. Toplamda 11 banttan oluşan uydu görüntüsünün RGB değerleri 4-3-2 şekline yani gerçek renk kompozitine dönüştürülmüştür. Gerçek renk kompozitini gösteren bu sıralama yardımıyla daha önce kontrolsüz sınıflandırmada oluşturulan sınıflar (su yüzeyi, toprak, yapı ve orman) CBS yazılımında, görüntü sınıflandırması gerçekleştirilmiştir.

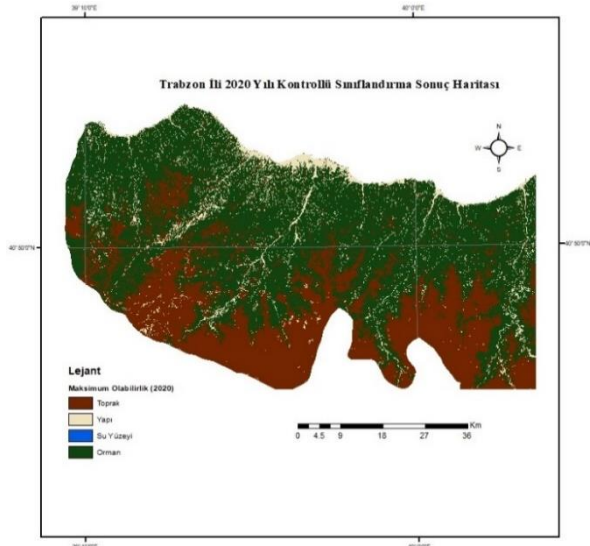
Daha sonra tanıtılan sınıflara ait alanlar sınıf başlıkları altında toplanmış ve sınıflar kayıt altına alınmıştır. Gerçek renk kompozitinin yanı sıra sınıfların tanıtılmasında eş zamanlı olarak bitki indeksini gösterir renk kompoziti, temel harita

(basemap) ve NDVI analizi sonucu oluşan haritadan da yararlanılmıştır.

Kontrollü sınıflandırmanın doğruluk derecesinin yüksek olması için her renk tonunun sınıflandırmaya dahil edilmesine özen gösterilmiştir. Bu sayede program denetimli piksel tabanlı sınıflandırmada, tanıtımı yapılan renkleri kolaylıkla ayırt etmiştir. Sınıfların tanıtılmasının ardından kontrollü sınıflandırma yöntemlerinden biri olan ve sıklıkla kullanılan EÇB yöntemine göre sınıflandırma işlemi gerçekleştirilmiştir. Kontrollü sınıflandırmanın gerçekleştirilmesinin ardından sınıflara uygun renklendirme işlemi yapılmıştır. Sonuç haritaları aşağıda verilmiştir (Şekil 6 ve 7).



**Şekil 6.** Trabzon İli 2019 yılı kontrollü sınıflandırma haritası



**Şekil 7.** Trabzon İli 2020 yılı kontrollü sınıflandırma haritası

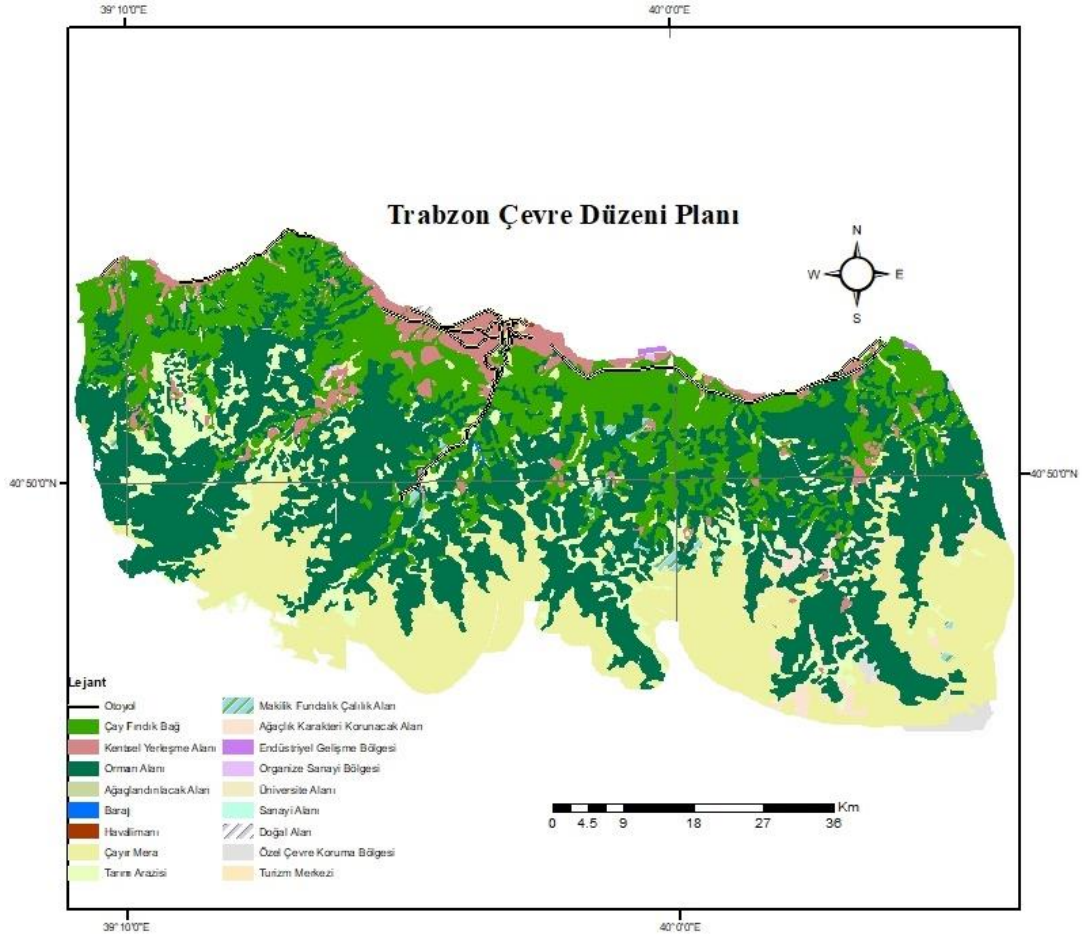
2020 yılı hata matrisinden hesaplanan 0.705761 kappa değeri; sınıflandırma işleminin, tamamen rastgele sınıflandırmada oluşacak hataların %70.6'ından arındırıldığını göstermektedir. 2019 yılı hata matrisinden hesaplanan 1.00 kappa değeri ise; sınıflandırma işleminin, tamamen rastgele sınıflandırmada oluşacak hataların %100'ünden arındırıldığını göstermektedir. Bu durum aşırı öğrenme nedeniyle oluşmaktadır ve istenilmeyen bir durumdur. Bu çalışmada yeşil alanların yapılan kontrollü ve kontrolsüz sınıflandırma işlemleriyle karşılaştırılması amacıyla Çevre, Şehircilik ve İklim Değişiklikleri Bakanlığı Mekânsal Planlama Genel Müdürlüğü'nün yayınlamış olduğu Ordu-Trabzon-Rize-Giresun-Gümüşhane-Artvin Planlama Bölgesi 1/100.000 ölçekli ÇDP'de Trabzon İline ait plan paftaları kullanılmıştır (Şekil 8).

Kontrollü sınıflandırma sonucu oluşan görüntülerin, CBS yazılımında rastgele üretilmiş olan 100 adet test noktası ile doğruluk değerlendirmesi yapılmıştır. Üretilen test ve kontrol noktalarına ilişkin değerlendirmeler gerek yerinde gerekse altlık harita üzerinden gerçekleştirilmiştir. 2019 ve 2020 yılı mayıs ayına ilişkin veri setleri için genel doğruluk ve kappa istatistikleri Tablo 2'de verilmiştir.

**Tablo 2.** Doğruluk analizi sonuçları

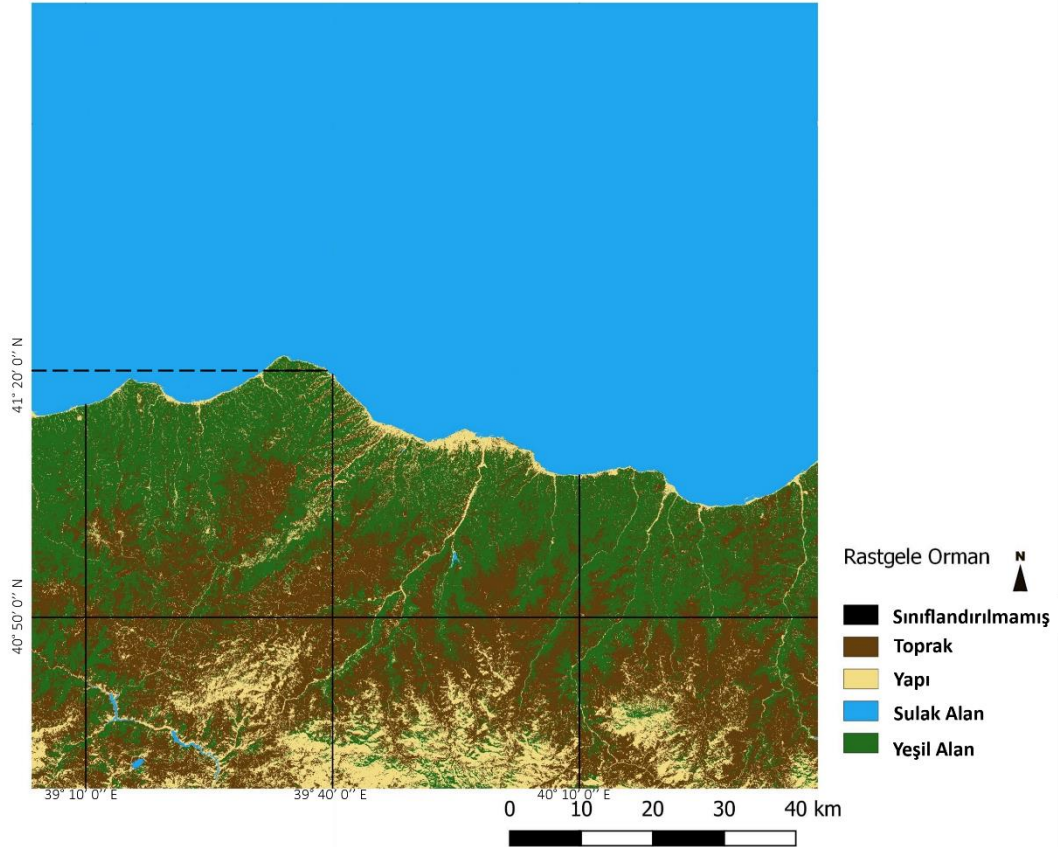
Algoritma	Yıl	Genel Doğruluk	Kappa
EÇB	2019	%100	1.00
EÇB	2020	%81.3	0.71

Burada 2019 yılına ait veri setiyle yapılan kontrollü sınıflandırma sonucu bulunan genel doğruluk değeri aşırı öğrenme (overlearning) sonucu oluşmuştur. Aşırı öğrenme, yinelemeli bir eğitim algoritması çalıştırıldığında, algoritma çok uzun süre çalıştırıldığında veya mevcut veri miktarı çok olduğunda meydana gelebilir. Bu çalışmada öncelikle 2020 yılına ait veri setinde daha sonra 2019 yılına ait veri setinde kontrolsüz sınıflandırma işlemi gerçekleştirilmiştir.



Şekil 8. Trabzon ili ÇDP

### Trabzon İli Rastgele Orman Algoritmasıyla Sınıflandırma



Şekil 9. RO algoritmasıyla sınıflandırma işlemi sonucu oluşan harita

Çalışmada RO algoritmasıyla sınıflandırma işlemi QGIS yazılımında gerçekleştirilmiştir. Daha önce kontrollü sınıflandırmada kullanılan sınıf alanları QGIS yazılımına yüklenmiştir. RO penceresinde giriş bandı seti 1, eğitim örneklerinin sayısı 5000, ağaç sayısı 100 olarak belirlenmiş ve sınıflandırıcıyı değerlendir seçeneği aktif edilmiştir ardından çalıştır komutuyla RO işlemi başlatılmıştır. Elde edilen harita Şekil 9’da sunulmuştur.

Şekil 9 incelendiğinde RO algoritmasıyla yapılan sınıflandırmanın çok yüksek derecede doğruluğa sahip olduğu görülmüştür. Daha önceki adımlarda yapılan sınıflandırma yöntemleri sonucu oluşan sonuç ürünlerle karşılaştırıldığında özellikle su yüzeyi sınıfındaki farklılık dikkat çekmektedir. Diğer sınıflandırma yöntemlerinde su yüzeyini ifade etmeyen bazı bölgeler su yüzeyi olarak sınıflandırılmışken RO yöntemiyle yapılan sınıflandırmada böyle bir şey söz konusu değildir. Bu sınıflandırma yöntemi sonucunda baraj olarak belirtilen yerler ormanlık ve toprak alanlardan, deniz olarak belirtilen yerler yapı alanlarından ayrı olarak sınıflandırılmıştır. RO algoritmasıyla sınıflandırma işlemi sonucu oluşan hata matrisi Tablo 3.’deki gibidir.

**Tablo 3.** RO algoritmasıyla sınıflandırma sonucu oluşan hata matrisi

<b>Toprak</b>			
Doğruluk	Hassasiyet	Korelasyon	Hata Oranı
0.978	0.952	0.943	0.022
Gerçek Pozitifler	Yanlış Pozitifler	Gerçek Negatifler	Yanlış Negatifler
1201	60	3690	49
<b>Su Yüzeyi</b>			
Doğruluk	Hassasiyet	Korelasyon	Hata Oranı
1.00	1.00	1.00	0.00
Gerçek Pozitifler	Yanlış Pozitifler	Gerçek Negatifler	Yanlış Negatifler
1250	0	3750	0
<b>Yapı</b>			
Doğruluk	Hassasiyet	Korelasyon	Hata Oranı
0.986	0.974	0.962	0.014
Gerçek Pozitifler	Yanlış Pozitifler	Gerçek Negatifler	Yanlış Negatifler
1211	33	3717	39
<b>Orman</b>			
Doğruluk	Hassasiyet	Korelasyon	Hata Oranı
0.989	0.979	0.969	0.011
Gerçek Pozitifler	Yanlış Pozitifler	Gerçek Negatifler	Yanlış Negatifler
1219	26	3724	31

#### 4. SONUÇLAR

Bu çalışmada 2019-2020 yılları arasını kapsayan çevre durum raporuna ve bakanlık tarafından yayınlanan ÇDP’ye göre Trabzon İli yeşil

Bu çalışmada RO algoritmasıyla yapılan sınıflandırma sonucunda elde edilmiş olan doğruluk oranı %97.62’dir (Tablo 4). Bu oran oldukça yüksektir. Bu uygulamada toplamda 10000 adet örnek kullanılmıştır ve RO algoritması bu örnek verilerle 0.369 cm hata oranıyla sonuç vermiştir. KOH değerinin 0’a yakın olması istenilmektedir. Bu varsayımla, RO algoritması sonucu elde ettiğimiz bulguların doğruluğunun yüksek olduğu görülmektedir (Tablo 4).

**Tablo 4.** RO algoritması sonucu elde edilen ölçütler

Test verisinden elde edilen doğru tahminler (%)	97.6
Toplam örnek sayısı (adet)	10000
KOH (cm)	0.37

RO algoritması bu aşamaya kadar rastgele gözlemleri seçmiş ve bir karar ağacı oluşturmuştur. RO algoritmasının son aşaması olan nihai çıktı, sınıflandırmada bulunan doğru tahminlerin ortalamasına göre elde edilmiştir. Dağıtım her sınıf için eşit oranda gerçekleştirilmiştir.

alan değişimlerinin makine öğrenmesi algoritmalarından biri olan RO algoritmasıyla ve kontrollü kontrolsüz farklı sınıflandırma yöntemleriyle yüksek doğrulukla belirlenmesi amaçlanmıştır. Uygulamada Trabzon İli’ne ait Mayıs



2019 ve 2020 tarihli Sentinel-2a uydu görüntüleri kullanılmış ve bu uydu görüntüleri dört farklı sınıf belirlenerek CBS yazılımı ile sınıflandırılmıştır. Çalışmada kontrolsüz sınıflandırma da kullanılmak üzere 10m mekânsal çözünürlüğe sahip bant kompozitlerinden NDVI analizi gerçekleştirilmiştir. Kontrollü sınıflandırmada EÇB yöntemi kullanılmış ve sınıflandırma dört farklı sınıf ile gerçekleştirilmiştir. RO algoritmasıyla sınıflandırma ise açık kaynak kodlu QGIS yazılımı ile dört farklı sınıf belirlenerek yapılmıştır.

Kontrolsüz sınıflandırma işlemi sonucu oluşan haritalarda su yüzeyi diğer sınıflara en çok karışan sınıf olmuştur. Bu durum uydu görüntülerinin çözünürlüklerinin çok yüksek olmamasından kaynaklı olduğu düşünülmüştür. Kontrollü sınıflandırma işlemi sonucu oluşan haritalarda ise sınıfların birbirine karışımı oldukça düşük derecededir. Bu durumun sebebi kontrolsüz sınıflandırmada olduğunun aksine kontrollü sınıflandırmada kullanıcı tarafından ürün sınıflarının programa tanıtılmasıdır. Yapılan kontrollü sınıflandırma işleminde 2019 yılı genel doğruluk oranı %100.00, kappa değeri 1.00 iken 2020 yılı için genel doğruluk oranı %81.31, kappa değeri ise 0.71 olarak bulunmuştur. Burada 2019 yılı için elde edilen doğruluk oranı ve kappa değeri aşırı öğrenme (overlearning) sonucu olmakla beraber zararlı bir durumdur.

Çalışmada sınıflandırma sonucu oluşan haritalarla karşılaştırılmak üzere Trabzon iline ait ÇDP kullanılmıştır. Karşılaştırma sonucunda özellikle kentsel yerleşme alanlarında bir büyümenin olduğu görülmüştür. Kontrollü sınıflandırma sonucu üretilen haritalar karşılaştırıldığında da 2019 yılında yeşil alan olarak sınıflandırılan alanların bir kısmının 2020 yılında kentsel yerleşme alanı olarak sınıflandırıldığı tespit edilmiştir. Buradan 2019 ve 2020 yılları arasındaki zaman aralığında yeşil alanlar üzerinde kentsel yerleşimin oluştuğu sonucuna varabiliriz.

RO algoritmasıyla sınıflandırma sonucunda KOH değeri 0.37 cm olarak bulunmuştur ve bu değer 0'a yakın olması sınıflandırmanın iyi bir performans gösterdiği anlamına gelmektedir. Aynı zamanda oluşan sonuç haritada su yüzeyinin diğer sınıflarla hiç karışmadığı görülmüştür.

Üç sınıflandırma yöntemi için tüm sınıflar incelendiğinde; yeşil alan sınıfının tespitinde en yüksek doğruluk değerini veren RO algoritmasıdır. RO algoritmasından sonra en yüksek doğruluk değerine sahip kontrollü sınıflandırma yöntemi ikinci, en düşük doğruluk değerine sahip kontrolsüz sınıflandırma yöntemi ise üçüncü sırada yer almaktadır. Sonuç olarak RO algoritması ile Sentinel-2a görüntülerinden iyi bir yeşil alan sınıflandırma performansının elde edilebileceği gösterilmiş ve 2019-2020 yılları arasında geçen zamanda yeşil alanların azalırken kentsel yerleşme alanlarının arttığı gözlemlenmiştir.

## Teşekkür

Araştırmada kullanılan Sentinel-2 uydu verilerini ücretsiz sağlayan Avrupa Uzay Ajansı (ESA) ve Çevre Düzeni Planını ücretsiz sağlayan Çevre, Şehircilik ve İklim Değişiklikleri Bakanlığı Mekânsal Planlama Genel Müdürlüğü'ne teşekkürlerimizi sunarız.

## Araştırmacıların katkı oranı beyan özeti

E. Akosman: Veri analizi, Araştırma, Modelleme, Makale yazımı;  
H. B. Makineci: Konsept Oluşturma, Veri temini, Makale düzenleme, Makalenin dil bilgisi kontrolü.

## Çıkar çatışması beyanı

Makale ile ilgili olarak, herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

## Araştırma ve yayın etiği beyanı

Yapılan çalışmada yazarlar, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul izni gerektirmediğini beyan etmektedir.

## KAYNAKÇA

- Akar, Ö., & Güngör, O. (2012). Rastgele Orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Jeodezi Ve Jeoinformasyon Dergisi* (106), 139-146. <https://doi.org/10.9733/jgg.241212.1t>
- Akar, Ö., & Tunç Görmüş, E. (2019). Göktürk-2 ve Hyperion EO-1 Uydu Görüntülerinden Rastgele Orman Sınıflandırıcısı ve Destek Vektör Makineleri ile Arazi Kullanım Haritalarının Üretilmesi. *Geomatik*, 4(1), 68-81. <https://doi.org/10.29128/geomatik.476668>
- Aksoy Y., Ergun N., (2009). Kentleşme Ve Yeşil Alan Sorunu Üzerine Bir Araştırma İstanbul Kenti Bakırköy İlçesi Örneği, *Tünav Bilim Dergisi*, Cilt:2, Sayı:4, Sayfa:426-438.
- Antoine L., Christophe S., Thomas C., (2016). Monitoring urban areas with sentinel-2a data: application to the update of the copernicus high resolution layer imperviousness degree, *Remote Sens.* 2016, 8(7), 606.
- Apaydın C., Abdikan S., (2021). Fındık Bahçelerinin Sentinel-2 Verileri Kullanılarak Pikel Tabanlı Sınıflandırma Yöntemleriyle Belirlenmesi. *Geomatik Dergisi* – 2021; 6(2); 107-114.
- Belward A.S. ve Skoien, J.O. (2015). Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. *ISPRS Journal of*

- Photogrammetry and Remote Sensing*, vol. 103, no. May 2015, 115-128, 2014.
- Breiman, L. (2001). Random forests, machine learning, 2001 Kluwer Academic Publishers, 45(1), 5-32.
- Breiman, L. ve Cutler, A. (2005). Random Forest, [http://www.stat.berkeley.edu/~breiman/RandomForests/cc\\_home.htm](http://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm) (15.11.2009).
- Carlson, T. N., & Ripley, D. A. (1997). On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote sensing of Environment*, 62(3), 241-252.
- Çölkesen, İ. ve Yomralıoğlu, T. (2014). Arazi Örtüsü ve Kullanımının Haritalanmasında WorldView-2 Uydu Görüntüsü ve Yardımcı Verilerin Kullanımı, *Harita Dergisi*, Temmuz 2014 (152): 12-24.
- Dereli M. A., (2019). Sentinel-2a uydu görüntüleri ile Giresun İl merkezi için kısa dönem arazi örtüsü değişiminin belirlenmesi, *AKU J. Sci. Eng.* 19 (2019) 025501(361-368).
- Dönmez Y., Aydınöz D., (2013). Bitki Özellikleri Açısından Türkiye. *Coğrafya Dergisi*, 24, 1-17, İstanbul, 2012.
- Fırat A. S., (2014). Doğayı Ve İnsanı Yoksullaştırıcı Kentleşme Pratikleri. *Tesam Akademi Dergisi - Turkish Journal of TESAM Academy* Temmuz - July 2014. 1 (2). 31-64 ISSN: 2148 - 2462.
- Jensen, J. R., Garcia-Quijano, M., Hadley, B., Im, J., Wang, Z., Nel, A. L., Teixeira, E., Davis, B. A., 2006, Remote Sensing Agricultural Crop Type For Sustainable Development In South Africa, *Geocarto International*, 21 (2), 5-18.
- Karagöl S., Bayram B., Erdem F., Bakırman T., (2021). Aktarımlı Öğrenme ile SENTINEL-2 Görüntülerinden Kıyı Çizgisi Bölütlemesi. *Türkiye Uzaktan Algılama Dergisi*, 2021; 3(1); 01-07.
- Karakuş, P., 2017, Çok zamanlı uydu görüntü verileri ile tarımsal ürünlerin belirlenmesi ve verim tahmini, *Doktora Tezi*, Selçuk Üniversitesi.
- Karakuş P., Karabörk H., (2020). Crop Cover Fraction Estimation Based On Digital Images from 2014-2016: A Case Study of Kadirli in Osmaniye Province. *Turkish Journal of Remote Sensing*, 2020; 2(2); 50-57.
- Karasu, S., Hacıoğlu, R. & Altan, A. (2018). Prediction of Bitcoin Prices with Machine Learning Methods using Time Series Data, 26th signal Processing and Communications Applications Conference.
- Kaya, Y., & Polat, N. (2021). Bitki İndeksleri Kullanarak Buğday Bitkisinin Rekolte Tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(1), 99-110.
- Lemenkova, P. (2021). ISO Cluster classifier by ArcGIS for unsupervised classification of the Landsat TM image of Reykjavík. *Bulletin of Natural Sciences Research*, 11(1), 29-37.
- Makineci, H. B. (2023). Spatio-temporal change detection of built-up areas with Sentinel-1 SAR data using random forest classification for Arnavutköy Istanbul. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(2), 626-636.
- Malenovský, Z., Rott, H., Cihlar, J., Schaepman, E. M., García-Santos, G., Fernandes, R. and Berger, M. (2012). Sentinels for science: Potential of Sentinel-1, -2 and -3 missions for scientific observations of ocean, cryosphere, and land, *Remote Sens. Environ.*, no. 120, p. 91-101.
- Matinfar H.R., Sarmadian F., AlaviPanah S.K., Heck R.J., (2007), Comparisons of object-oriented and pixel-based classification of land use/land cover types based on landsat7, etm+ spectral bands (case study: arid region of Iran), *American-Eurasian J. Agric. & Environ. Sci.*, 2 (4), 448-456.
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S. ve Weng, Q. H., 2011, Perpixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery, *Remote Sensing of Environment*, 115 (5), 1145-1161.
- Myung I.J. 2003. Tutorial on maximum likelihood estimation. *Journal of Mathematical Psychology*, 47 90-100.
- Nijhawan, R., Srivastava, I., & Shukla, P. (2017, June). Land cover classification using supervised and unsupervised learning techniques. In *2017 international conference on computational intelligence in data science (ICCIDS)* (pp. 1-6). IEEE.
- Platt, R. V. ve Rapoza, L., (2008). An evaluation of an object-oriented paradigm for land use/land cover classification, *Professional Geographer*, 60 (1), 87-100.
- Tektaş Y., Polat N., (2021). HEC-RAS İle Taşkın Modelleme ve Sentinel-2 Uzaktan Algılama Görüntüsünden Taşkın Hasar Analizi: Diyarbakır İli Çakmak Deresi Çınar Bölgesi

Örneği. *Türkiye Uzaktan Algılama Dergisi*, 2021; 3(1); 28-35.

*Observation and Geoinformation*, 13 (6), 884-893.

Torunlar H., Tuğaç M. G., Duyan K., (2021). Nesne Tabanlı Sınıflandırma Yönteminde Sentinel-2A Uydu Görüntüleri Kullanılarak Tarımsal Ürün Desenlerinin Belirlenmesi; *Konya-Karapınar Örneği. Türkiye Uzaktan Algılama Dergisi*, 2021; 3(2); 36-46.

Yılmaz M., (2018). Tarımsal Yaz Ürünlerin Sentinel-2 Uydu Görüntülerinden Rastgele Orman Algoritması İle Nesne-Tabanlı Sınıflandırılması, *Yüksek Lisans Tezi*, Hacettepe Üniversitesi.

Vlachou, S., Georgaki, M., Pagkratis, C., & Poulos, M. (2016). Unsupervised Clustering Evaluation on Services of Public Library. *WSEAS Transactions on Advances in Engineering Education*, 13, 44-49.

Yiğit A. Y., Uysal M., (2019). Nesne Tabanlı Sınıflandırma Yaklaşımı Kullanılarak Yolların Tespiti. *Türkiye Fotogrametri Dergisi*– 2019; 1(1); 17-24.

Weih, R. C. ve Riggan, N. D., (2010). Object-Based Classification Vs. Pixel-Based Classification: Comparative Importance of Multi-Resolution Imagery, *Geobias*, Geographic Object-Based Image Analysis, 38-4-C7.

URL-1: <https://customscripts.sentinelhub.com/customscripts/sentinel2/composites/> [Erişim tarihi: 22.06.2022]

Whiteside, T. G., Boggs, G. S. ve Maier, S. W., (2011). Comparing object-based and pixel-based classifications for mapping savannas, *International Journal of Applied Earth*


URL-2: <https://blog.esri.com.tr/2019/02/25/sentinel-2-uydu-goruntuleriyle-esri-sentinel-2-explorer-web-uygulamasi-araciligiyla-calismak/> [Erişim tarihi: 24.06.2022].

URL-3: [https://webdosya.csb.gov.tr/db/ced/icerikler/2020\\_trabzon\\_cdr-20210616135008.pdf](https://webdosya.csb.gov.tr/db/ced/icerikler/2020_trabzon_cdr-20210616135008.pdf) [Erişim tarihi: 23.11.2023].



© Author(s) 2023.


This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>



## Türkiye Uzaktan Algılama Dergisi

<https://dergipark.org.tr/tr/pub/tuzal>

e-ISSN 2687-4997



### Investigation of Position Accuracy in UAVs

Ömer Yıldırım<sup>1</sup>, Cevat İnal<sup>2</sup>, Sercan Bülbül<sup>\*2</sup>, Burhaneddin Bilgen<sup>3</sup>

<sup>1</sup> Tokat Gaziosmanpaşa University, Faculty of Engineering and Natural Sciences, Geomatics Engineering Department, Tokat/Türkiye

<sup>2</sup> Konya Technical University, Faculty of Engineering and Natural Sciences, Geomatics Engineering Department, Konya/Türkiye

<sup>3</sup> Ankara Hacı Bayram Veli University, Academy of Land Registry and Cadastre, Ankara, Türkiye

#### Keywords

Accuracy  
DTM  
GCP  
GNSS  
UAV

#### ABSTRACT

Digital Terrain Models (DTMs) are used as primary data in many engineering projects. In addition to classical terrestrial techniques, space and satellite techniques and Unmanned Aerial Vehicles (UAVs) are commonly used in the production of the DTMs. In the production of the DTM with the help of the UAVs, measurements can be made easily where people can access hardly, and large areas can be mapped quickly. However, one of the most fundamental problems in the UAVs is to obtain the most accurate DTM by choosing the homogeneously spread ground control points (GCPs) number. In this study, the effect of flight altitude and the density of GCPs on position accuracy were investigated in production of the DTM. For this purpose, 56 points were established at approximately 40 m intervals and images from 80, 100, 120 m flight altitude were taken in the test area. The rapid static Global Navigation Satellite Systems (GNSS) method was used to obtain the coordinates of the points with high accuracy. Then, the homogeneously spread 5, 10, and 15 points were chosen as GCPs, respectively. The images were evaluated in Pix4d Mapper software with 9 different combinations and DTMs were produced. Outliers of the coordinates obtained from the models were detected by Bland-Altman Plot. To determine the geometric accuracy of the produced models, the coordinates of the test points obtained from the models and the results of rapid static GNSS measurements were compared with the statistical methods and the obtained results were interpreted.

### İHA'lardan Elde Edilen Konum Doğruluğunun İncelenmesi

#### Anahtar Kelimeler:

Doğruluk  
GNSS  
İHA  
SAM  
YKN

#### ÖZ

Sayısal Arazi Modelleri (SAM) birçok mühendislik projesinde temel veri olarak kullanılmaktadır. SAM'ların üretiminde klasik yersel tekniklerin yanı sıra yaygın olarak uzay ve uydu teknikleri ile İnsansız Hava Araçları (İHA'lar) kullanılmaktadır. SAM'ın İHA'lar yardımıyla üretilmesinde insanların ulaşmasının zor olduğu yerlerde kolaylıkla ölçümler yapılabilen ve geniş alanların haritaları kısa sürede üretilmektedir. Ancak İHA'larda en temel sorunlardan biri homojen yayılmış yer kontrol noktaları (YKN) sayısını seçerek en doğru SAM'ı elde etmektir. Bu çalışmada, SAM üretiminde uçuş yüksekliği ve YKN yoğunluğunun konum doğruluğuna etkisi araştırılmıştır. Bu amaçla test alanında yaklaşık 40 m aralıklarla 56 nokta tesis edilmiş ve 80, 100, 120 m uçuş yüksekliğinden görüntüler alınmıştır. Noktaların koordinatlarının yüksek doğrulukla elde edilmesi için hızlı statik Küresel Navigasyon Uydu Sistemleri (GNSS) yöntemi kullanılmıştır. Daha sonra homojen olarak yayılan 5, 10 ve 15 nokta sırasıyla YKN olarak seçilmiştir. Görüntüler Pix4d Mapper programında 9 farklı kombinasyonla değerlendirilerek SAM'lar üretilmiştir. Modellerden elde edilen koordinatlardan uyumsuz ölçüler Bland-Altman yöntemi ile belirlenerek ölçü grubundan çıkartılmıştır. Üretilen modellerin geometrik doğruluğunun belirlenmesi amacıyla modellerden elde edilen test noktalarının koordinatları ve hızlı statik GNSS ölçüm sonuçları istatistiksel yöntemlerle karşılaştırılmış ve elde edilen sonuçlar yorumlanmıştır.

#### Article Info

Received: 02/11/2023  
Accepted: 05/12/2023  
Published: 30/12/2022

#### Citation:

Yıldırım, O., İnal, C., Bülbül S. & Bilgen, B. (2023). Investigation of Position Accuracy in UAVs . Turkish Journal of Remote Sensing, 5 (2) , 89-96.

## 1. INTRODUCTION

Digital Terrain Model (DTM) is required to realize many engineering projects. DTM can be defined as a digital representation of all the artificial and natural details of the physical earth and in a broad sense it contains the position and elevation information of all the details in the field. Global Navigation Satellite Systems (GNSS), Total Station (TS) and Terrestrial Laser Scanning (TLS) techniques are used in the production of the DTM required for many applications in the field of engineering (Liu, 2008; Lague et al., 2013; Martínez-Carricondo et al., 2018; Akgul et al., 2018, Makineci, 2023). Along with the developing technology over the years, the measuring instruments used in the surveying sector have come to a different point and Unmanned Aerial Vehicles (UAV) have been commonly used in the production of the 3D model of the earth.

The UAV was primarily used for military applications. Nowadays, it can be used in geological and meteorological research, natural disaster management, international border patrols, detection of forest fires, determination of deformations, production of a topographic map and modeling of 3D city or land (Ottichilo and Khamala, 2002; Koeva et al., 2018; Otto et al., 2018, Makineci, 2022). The use of such aircraft also brings many advantages in the field of surveying. Thanks to digital cameras installed on the UAVs, measurements can be made easily where people can access hardly. The accuracy of the measurements performed with the help of the obtained images can almost compete with the classical terrestrial techniques.

The UAV is a vehicle that can be moved automatically or semi-automatically depending on a flight plan or is remotely controlled by a pilot on the ground or in another vehicle (Otto et al., 2018; Dalamagkidis, 2015). The UAV systems can be used as an alternative to low-resolution and high-cost constraints arising from the high flight altitude of manned mapping systems (Westoby et al., 2012; Hugenholtz et al., 2013; Tonkin et al., 2014; Smith et al., 2016; Ewertowski et al., 2019).

The UAV platform can be equipped with LiDAR sensors or several of these technologies, thermal or infrared camera systems, video camera, multispectral cameras, depending on their capacity and characteristics. In addition, the UAV GNSS/Inertial Navigation System (INS) may include compass systems and barometric altimeter. Such an integrated system is often called as Unmanned Aerial Vehicle System (UAS) (Nex and Remondino, 2014).

There are several studies on achievable accuracies of UAV imagery. Lucieer et al. (2014) generated landslide displacements map using UAV imagery. They obtained horizontal Root Mean Square (RMS) of 7.0 cm and vertical RMS of 6.2 cm from 1 cm resolution Digital Surface Models (DSMs). Tonkin et al. (2014) compared total station data and the coordinates obtained from UAV based DTMs.

They noted that the total station data and the coordinates obtained from UAV based DTMs were in a good agreement. Mesas-Carrascosa et al. (2015) investigated the effect of flight altitude, flight mode and configuration of GCPs. Ruzgiene et al. (2015) investigated the accuracy of DSMs produced with UAV imagery and the effect of the Ground Control Points (GCPs) number. Uysal et al. (2015) analyzed the accuracy of DSMs produced using UAV and they concluded that DSMs produced with UAV have advantages such as low-cost, minimum field work, time conservation comparing with classical methodologies. Agüera-Vega et al. (2016), investigated the effects of GCP number, different land structures and flight altitudes on accuracies of DSM and orthophoto. In all these studies, GCP coordinates were determined by Real Time Kinematic-GNSS (RTK-GNSS) method and when determination of the accuracy of the UAV, only the RMS of produced models taken into account. Here, the rapid static GNSS technique was used to obtain the coordinates of test points and the GCPs with high accuracy. Then, the effect of flight altitude and the density of GCPs on position accuracy were investigated in the production of DTM. For this purpose, images from 80, 100, 120 m flight altitude were taken in the test area and 5, 10, 15 GCPs were selected and evaluated in Pix4d Mapper software with 9 different combinations and DTMs were produced. The coordinates of the test points were obtained from produced DTMs. Bland-Altman Plot was used to detect outliers of the coordinates obtained from the models. In order to determine the geometric accuracy of the produced models, the coordinates of the test points obtained from the models and the results of rapid static GNSS measurements were compared statistically and the obtained results were interpreted.

## 2. THE RELATIVE POSITIONING WITH GNSS

The GNSS has been a commonly used positioning method since 1990s. The GNSS consists of global systems such as Global Positioning System (GPS), Russian Global Navigation Satellite System (GLONASS), European Navigation Satellite System (Galileo), BeiDou Navigation Satellite System (BeiDou) as well as regional navigation systems such as Quasi Zenith Satellite System (QZSS) and Indian Regional Navigation Satellite System (IRNSS). GNSS that used all weather conditions is a highly precise microwave (L-band) technique (Jin et al., 2014). The GNSS can be used wider applications such as positioning, intelligent transport systems, navigation and timing, terrestrial reference frame, precise orbit determination, monitoring of plate movements, real-time active control networks (RTK-CORS), crustal deformation, location-based services, cadastral measurements, deformation measurements (dam, bridge, viaduct, etc.), hydrographic and photogrammetric measurements.

With the GNSS, point positions can be determined by relative and absolute techniques. The relative techniques are used more commonly than the absolute techniques due to their high accuracy. The relative techniques are kinematic and static

positionings. Static positioning is preferred due to its high accuracy, in applications such as deformation monitoring, tectonic plate movements, monitoring of large engineering structures (Table 1).

**Table 1.** Accuracies of relative techniques (Hoffman-Wellenhof et al., 2008)

Technique	Horizontal accuracy
Kinematic	5 cm + 5 ppm
Static	5 mm + 0.5 ppm

Static positioning is sub divided into three different techniques; rapid static, stop and go and pseudo kinematic. The rapid static solves the ambiguities fast and, in the technique, code and carrier phase observations are usually used. Up to 20

km baselines, millimeter level accuracy can be achieved (Hoffman-Wellenhof et al., 2008). Session durations for static positioning are listed in Table 2. The more session duration enhances the accuracy.

**Table 2.** Session durations for static observations (up to 20 km baselines)

Receiver	Rapid Static	Conventional Static
Dual-frequency	10 min + 1 min/km	20 min + 2 min/km
Single-frequency	20 min + 2 min/km	20 min + 3 min/km

### 3. UNMANNED AERIAL VEHICLES


UAVs are described as pilotless aerial vehicles which can be controlled remotely or automatically move along a flight plan. UAVs were originally produced for military purposes and are now widely used in civil / scientific purposes (Otto et al., 2018). UAVs are produced with both fixed fin and rotary vanes. These different designs have superior and weak sides compared to each other. As fixed-fin-UAVs use a special platform for taking off or they are thrown by hand, rotary vanes -UAVs are just like aircrafts with the ability to move vertically as helicopters (Canis, 2015). A calibrated, digital, and integrated camera can be placed in the UAV and images of the earth can be obtained. The images obtained during UAV flights can be processed by photogrammetric methods at considerably lower costs compared to the cost of receiving from an aircraft with complex and expensive equipment, devices, and facilities (Suziedelyte Visockiene et al., 2016). UAVs can be integrated with various imaging devices with sensors such as thermal, infrared, hyperspectral, radar, chemical and biological, and provide day and night images. The UAVs can send the data to ground control stations in real time and thus important information such as fire, flood, forecast can be obtained instantaneously (Rawat and Lawrence, 2014).

Thanks to real time-GNSS system integrated on the UAVs, routing of the UAVs can be performed automatically. In addition, the images obtained with this system are both coordinated instantaneously and oriented with Inertial Measurement Unit (IMU) systems. Also, the images can be processed instantaneously at the control station, or they can be processed in the office after taking the images (Samad et al., 2013).

Although the UAVs have many advantages, they have also disadvantages such as incapability of use on very large areas, low flight time, limited applications for windy weather, difficulties in landing, take-off and flight stages. The 3D position information obtained from the digital elevation model produced using the UAVs can sometimes produce erroneous results due to the disadvantages of the UAVs. Incorrect position information obtained in this case can be eliminated using appropriate statistical methods.

### 4. APPLICATION

In order to investigate the use of UAVs in producing a digital terrain model, a test area of ~5.5 hectares (ha) was selected in an area belonging to the private sector in province of Konya, Çumra (Figure 1). In the selected test area, 56 points were established at approximately 40 m intervals. In order to investigate the density of GCP and the effect of flight altitude on the accuracy, the flight altitude 80, 100, 120 m and the homogeneously spread GCPs number were chosen as 5, 10, 15 respectively, while the remaining points were considered as the test point (Figure 2).



**Figure 1.** The points in the test area



**Figure 2.** One of GCPs

In the study, The Geo V3 Multicopter produced by Geomatics Inc. Co. was used (Figure 3). Detailed information can be obtained from (<http://www.geomaticsgroup.com/contents/urunler/77/327/481>).



**Figure 3.** Geo V3 Multicopter

The Sony A6000 16 mm – 6000 × 4000 camera was used to take images in RAW format. During the flight with the UAV, one picture was taken in about two seconds on average. For this purpose, the main control card of the UAV was programmed to take regular pictures. The camera shutter was pressed at constant time intervals. Vibration damping equipment has been installed in the connection point between the UAV platform and the camera, so that the camera was not affected by the vibration generated during flight (Table 3-4). More information about the platform can be found at (Yildirim et al., 2016).

**Table 3.** Platform technical specifications (Yildirim et al., 2016)

Specification	Technical Detail
Weight	3.6 kg
Wingspan	103 cm
Payload	4 kg
Height	34 cm with GPS Antenna
Range	4 km
Endurance	30 min
GPS	5 Hz – 72 channels
Speed	7 m/sec
Telemetry Radio	433 MHz
Radio Control	24 GHz
Maximum Speed	110 km - 30 mm /sec
Frame Transponder (FPV)	5.8 GHz

**Table 4.** Sony A6000 digital camera specifications (<https://www.sony.com/electronics/interchangeable-lens-cameras/ilce-6000-body-kit/specifications>)

Specification	Technical Detail
Megapixels	24.7 MP
Size of Sensor	23.5 x 15.6 mm
Dimensions	2.63 x 4.72 x 1.78 inches
Sensor Type	APS-C
Weight	10.05 oz
Media Format	Secure Digital (SD), SD Extended Capacity, SD High Capacity
Maximum ISO	51200
Battery Type	Lithium Ion
Size of LCD	3 inches
Aspect Ratio of LCD	4:3
LCD Dots	921600
Type of Viewfinder	0.39" type electronic viewfinder (colour)
35 mm-Equivalent (Wide)	25 mm
35 mm-Equivalent (Telephoto)	500 mm

Images obtained by the UAVs can be evaluated using different software. In this study, UAV data were evaluated with Pix4D software. Detailed information can be obtained from

(<http://www.geomaticsgroup.com/contents/urunler/77/328/486>).

As a result of the software evaluation; GeoTIFF format, orthomosaic with real coordinate, Google

fields in KML and HTML formats, DSM with real coordinate, point cloud in LAS, LAZ, XYZ and PLY formats, vector data in dxf, shp and kml formats, adjustment result report can be obtained (<http://www.geomaticsgroup.com/contents/uruner/77/328/486>).

**4.1. Evaluation of the measurements**

The point coordinates were determined by rapid static method using Javad TRIUMPH1 GNSS receiver that exists in Konya Technical University Geomatics Engineering Laboratory. Data were collected as 10 minutes for recording intervals of 5 seconds at all the points in the test area. Until the measurement was completed at all points with 4 GNSS receivers, 2 GNSS receivers also collected data simultaneously at the benchmark points at the immediate surroundings of the study area. The collected data were evaluated based on two benchmark points at the immediate surroundings of the study area using LGO v7.0 GNSS software and the Transversal Mercator (TM) projection coordinates and ellipsoidal heights of the points were calculated at International Terrestrial Reference Frame-1996 (ITRF96) in 2005.00 epoch. The RMS of obtained coordinates were between ±0.4 mm and ±1.2 mm, ±0.4 mm and ±1.0 mm, ±1.2 mm and ±2.4 mm, in the direction of x, y and h axes, respectively. These RMS values are more accurate than the RTK-GNSS technique. This would increase the accuracy of the produced models. Then, the Geo V3 Multicopter was flown at 80, 100, and 120 meters altitude. Overlap ratios were taken as 80%, 70% for forward, side, respectively. Data obtained by the UAV was evaluated in Pix4D software and coordinates of the

test points were obtained from DTM produced using 5, 10, 15 GCPs spread homogeneously from the test points whose coordinates were determined by rapid static method.

The coordinates obtained from DTMs and the coordinates calculated by rapid static method were compared. For this purpose, considering the selected flight altitude and the number of GCPs used, the coordinate differences were calculated (Eq. 1);

$$d_{x_i} = x_{si} - x_i, \quad d_{y_i} = y_{si} - y_i, \quad d_{h_i} = h_{si} - h_i, \quad (1)$$

$n_x, n_y, n_h$  are to show the number of coordinate differences, RMS errors were (Eq. 2);

$$m_x = \pm \sqrt{\frac{\sum d_{x_i} d_{x_i}}{n_x}}$$

$$m_y = \pm \sqrt{\frac{\sum d_{y_i} d_{y_i}}{n_y}} \quad (2)$$

$$m_h = \pm \sqrt{\frac{\sum d_{h_i} d_{h_i}}{n_h}}$$


In the equations above,  $x_{si}, y_{si}, h_{si}$  are the coordinates of point i, calculated by rapid static method,  $x_i, y_i, h_i$  are the coordinates obtained with the UAV. Outliers of the coordinates obtained from the models were detected by Bland-Altman Plot (Bland and Altman, 1986;1999; Stöckl et al., 2004; <https://www.medcalc.org/manual/blandaltman.php>). After outlier detections, test statistics were calculated (Table 5). The RMS errors in the directions of y, x and h axes are shown in Figure 4.

**Table 5.** The descriptive statistics (cm)

Number of GCPs	Flight Altitude (m)	Descriptive Statistics											
		y (cm)				x (cm)				h (cm)			
		max	min	mean	RMS	max	min	mean	RMS	max	min	mean	RMS
5	80	9.6	-11.3	-1.0	±4.65*	7.0	-8.9	-0.5	±3.79*	25.6	-19.6	-0.6	±10.10
	100	11.5	-9.2	1.6	±5.53	10.6	-6.4	2.2	±4.70	12.1	-9.9	2.5	±6.19*
	120	8.0	-11.2	-2.5	±5.39	10.0	-15.9	-1.6	±6.30	68.0	-39.1	3.0	±16.77
10	80	10.6	-8.3	0.1	±4.18*	9.1	-8.1	-0.2	±4.41*	15.4	-10.0	1.4	±7.00
	100	9.1	-8.2	-1.1	±4.65	8.6	-9.5	-0.2	±5.26	11.2	-9.3	2.2	±5.65*
	120	10.6	-12.1	-2.1	±5.90	10.1	-11.4	-2.3	±6.28	12.8	-10.8	4.2	±7.73
15	80	9.6	-11.3	-1.0	±4.65*	7.0	-8.9	-0.5	±3.79*	68.2	-36.6	5.7	±24.74
	100	8.2	-12.1	-1.9	±5.23	12.9	-13.7	-1.1	±6.08	12.2	-10.9	2.3	±6.41*
	120	10.1	-10.9	-1.1	±5.33	9.0	-9.8	-0.6	±4.44	13.1	-11.9	2.1	±6.94

\* The least RMS error in different scenarios





**Figure 4.** The RMS of y, x, and h (cm)

When Table 5 is examined, it is seen that there is no significant difference between the coordinate accuracies of the different flight altitudes. The number of GCPs when producing the DTM does not affect the results. This situation is due to the small and disinclined test area. When the RMS errors are examined, it is seen that the accuracies of x and y directions are nearby 5 cm and the height accuracy is nearby 15 cm. The least RMS error at a flight altitude of 80 meters is achieved by using 10 GCPs in the direction of the y axis. For the direction of x axis, the least RMS error of 80 meters flight altitude is achieved by using both 5 and 15 GCPs. The least RMS error in the height component at a flight altitude of 80 meters is obtained by using 10 GCPs. For the flight altitude of 100 meters, minimum RMS errors in the y, x, and h directions are obtained with 10, 5, and 10 GCPs, respectively. At the flight altitude of 120 meters, these values are 5, 15, and 15 GCPs. Figure 4 clearly shows these findings.

**Table 6.** 2D and 3D position accuracies

Number of GCPs	Flight Altitude (m)	Position Accuracy (cm)	
		2D	3D
5	80	±6.00 *	±11.74
	100	±7.26	±9.54 *
	120	±8.30	±18.71
10	80	±6.07 *	±9.26
	100	±7.02	±9.01 *
	120	±8.61	±11.58
15	80	±6.00 *	±25.46
	100	±8.02	±10.26
	120	±6.94	±9.82 *

\* The least RMS error

The RMS errors, obtained from models, are shown in Table 6. It is seen that 2D and 3D position accuracies vary between ± 6.00- ± 8.61 cm and ±

9.01- ± 25.46 cm, respectively. For the 2D position accuracy in the test area, the least RMS are at 80 m, while the 3D position accuracy is generally obtained at a flight altitude of 100 m. While the best horizontal accuracy (2D) at 80 m flight altitude is achieved by using 5 and 15 GCPs, the best 3D accuracy is achieved with 10 GCPs. The best 2D position accuracy at flight altitudes of 100 and 120 meters is achieved with 10 and 15 GCPs, respectively. The GCP numbers, which the best 3D accuracy is achieved, are the same as 2D for 100 and 120 m flight altitudes.

**5. RESULTS**

In recent years, the UAVs have been widely used in the production of DTMs. It is possible to produce a DTM of larger areas with lower costs in a shorter time than classical terrestrial techniques with the UAVs. However, as with every method, the UAVs also have some disadvantages. The need for trained pilots and the high cost of purchasing them are seen as their most significant disadvantages.

The main problem encountered when producing DTM with UAVs is to determine the appropriate conditions for more accurate modeling of the selected area. It is necessary to determine the optimal flight altitude and ideal GCPs number. In this study, different flight altitude and a different number of GCPs were set in a selected region and the accuracy of the produced DTM was investigated. The images taken with the UAV on the flights at 80, 100 and 120 meters were evaluated with 5, 10 and 15 GCPs and 9 DTMs were generated. The coordinates of the test points were determined by the rapid static method as it provided more accurate results than RTK-GNSS technique. The coordinates obtained from the models were compared with the rapid static coordinates using the Bland-Altman plot and the outliers were detected in the direction of the coordinate axes.

In each model, statistical differences in the direction of coordinate axes, 2D and 3D position accuracies were calculated (Table 5-6). When a comparison is made to the number of GCPs, the best result regarding 2D position accuracy was obtained

using 5-15 GCPs, while in 3D position accuracy was obtained using 10 GCPs. When compared to the flight altitude, it was determined that the highest geometric accuracy of the model was 80 m for 2D position accuracy and 100 m for 3D position accuracy. It was found that the accuracy obtained here provides the expected accuracy from the DTMs to be used as a base in maps. It should not be overlooked that these accuracies may vary depending on the structure and size of land, weather conditions and position accuracies of GCPs.

#### Author contributions

O. Yildirim : Designed the research, analyzed the data, Methodology, Validation.

C. Inal : Designed the research, Investigation, Validation, Conceptualization, writing the manuscript–review and editing.

S. Bulbul : Collected the datasets , Analyzed the data, Methodology, Validation, Writing. Writing the manuscript–review and editing.

B. Bilgen : Collected the datasets , Analyzed the data, Methodology, Validation, Writing. Writing the manuscript–review and editing.

#### Conflicts of Interest

The authors declare no conflict of interest.

#### Research and publication ethics statement

In the study, the authors declare that there is no violation of research and publication ethics and that the study does not require ethics committee approval.

#### REFERENCES


- Agüera-Vega F., Carvajal-Ramírez F., Martínez-Carricondo P.J., (2016), Accuracy of digital surface models and orthophotos derived from unmanned aerial vehicle photogrammetry, *J. Surv. Eng.*, 143, 1-10.
- Akgul M., Yurtseven H., Gulci S., Akay A.E., (2018), Evaluation of UAV- and GNSS-Based DEMs for Earthwork Volume. *Arabian Journal for Science and Engineering*, 43, 1893-1909.
- Bland J.M., Altman D.G., (1986) Statistical methods for assessing agreement between two methods of clinical measurement (PDF), *Lancet*, 327, 307–310.
- Bland J.M., Altman D.G., (1999), Measuring agreement in method comparison studies, *Statistical Methods in Medical Research*, 8, 135–160.
- Canis B., (2015), Unmanned aircraft systems (UAS): Commercial outlook for a new industry, CRS Report: Congressional Res. Service, September 9.
- Dalamagkidis K., (2015), Classification of UAVs. In: Handbook of Unmanned Aerial Vehicles, Valavanis K.P., Vachtsevanos G.J. (Eds.), Springer, Dordrecht, 83-91.
- Ewertowski M.W., Tomczyk A.M., Evans D.J.A., Roberts D.H., Ewertowski W., (2019), Operational Framework for Rapid, Very-high Resolution Mapping of Glacial Geomorphology Using Low-cost Unmanned Aerial Vehicles and Structure-from-Motion Approach, *Remote Sensing*, 11, 1-18.
- Makineci, H. B., (2023), Comparative accuracy analysis of DEMs generated from descending and ascending orbit TerraSAR-X data, *Bulletin of Geophysics and Oceanography* Vol. 64, n. 3, pp. 259-278., DOI 10.4430/bgo00427.
- Makineci, H. B. (2022). İstanbul İli Merkez İlçelerindeki NO2 ve CO Emisyonlarının Uzaktan Algılama ve Yersel İstasyon Verileri Kullanılarak İncelenmesi . *Türkiye Uzaktan Algılama Dergisi* , 4 (2) , 62-74 . DOI: 10.51489/tuzal.1160333
- Mesas-Carrascosa F.J., Torres-Sánchez J., Clavero-Rumbao I., García-Ferrer A., Peña J.M., Borra-Serrano I., López-Granados F., (2015), Assessing optimal flight parameters for generating accurate multispectral orthomosaics by UAV to support site-specific crop management, *Remote Sens.*, 7, 12793–12814.
- Hoffman-Wellenhof B., Lichtenegger H., Wasle E., (2008), GNSS - Global Navigation Satellite Systems, Springer, Austria.
- Hughenoltz C.H., Whitehead K., Brown O.W., Barchyn T.E., Moorman B.J., LeClair A., Riddell K., Hamilton T., (2013), Geomorphological mapping with a small unmanned aircraft system (sUAS): Feature detection and accuracy assessment of a photogrammetrically-derived digital terrain model. *Geomorphology*, 194, 16-24.
- Jin S., Cardellach E., Xie F., (2014), GNSS Remote Sensing, Springer, New York.
- Koeva M., Muneza M., Gevaer, C., Gerke M., Nex F., (2018), Using UAVs for map creation and updating. A case study in Rwanda, *Survey Review*, 50, 312-325.

- Lague D., Brodu N., Leroux J., (2013), Accurate 3D comparison of complex topography with terrestrial laser scanner: application to the Rangitikei canyon (N-Z), *ISPRS J. Photogramm. Remote Sens*, 82, 10–26.
- Liu X.Y., (2008), Airborne LiDAR for DEM generation: some critical issues. *Progress in Physical Geography*, 32, 31-49.
- Lucieer A., De Jong S.M., Turner D., (2014), Mapping landslide displacements using Structure from Motion (SfM) and image correlation of multi-temporal UAV photography, *Prog. Phys. Geogr.*, 38, 97–116.
- Uysal M., Toprak A.S., Polat N., (2015), DEM generation with UAV Photogrammetry and accuracy analysis in Sahitler hill, *Measurement*, 73, 539–543.
- Martínez-Carricondo P., Agüera-Vega F., Carvajal-Ramírez F., Mesas-Carrascosa F.-J., García-Ferrer A., Pérez-Porras F.-J., (2018), Assessment of UAV-photogrammetric mapping accuracy based on variation of ground control points, *International Journal of Applied Earth Observation and Geoinformation*, 72, 1-10.
- Nex F., Remondino F., (2014), UAV for 3D mapping applications: a review, *Applied Geomatics*, 6, 1-15.
- Ottichilo W., Khamala E., (2002), Map updating using high resolution satellite imagery – A case of the kingdom of Swaziland, *International Archives of Photogrammetry and Remote Sensing*, 34, 89–92.
- Otto A., Agatz N., Campbell J., Golden B., Pesch E., (2018), Optimization approaches for civil applications of unmanned aerial vehicles (UAVs) or aerial drones: A survey. *Networks*, 72, 411-458.
- Rawat K. S., Lawrence E. E., (2014), A mini-UAV VTOL Platform for Surveying Applications, *International Journal of Robotics and Automation (IJRA)*, 3, 259-267.
- Ruzgiene B., Berteska T., Gecyte S., Jakubauskiene E., Aksamitaukas V.C., (2015), The surface modelling based on UAV Photogrammetry and qualitative estimation, *Measurement*, 73, 619–627.
- Samad A. M., Kamarulzaman N., Hamdani M. A., Mastor T. A., Hashim K. A., (2013), The Potential of Unmanned Aerial Vehicle (UAV) for Civilian and Mapping Application, 2013 *IEEE 3rd International Conference on System Engineering and Technology*, Shah Alam, Malaysia, 19 - 20 Aug. 2013.
- Smith M.W., Carrivick J.L., Quincey D.J., (2016), Structure from motion photogrammetry in physical geography, *Progress in Physical Geography*, 40, 247-275.
- Stöckl D., Rodríguez Cabaleiro D., Van Uytfaenghe K., Thienpont L.M., (2004), Interpreting method comparison studies by use of the Bland-Altman plot: reflecting the importance of sample size by incorporating confidence limits and predefined error limits in the graphic, *Clinical Chemistry*, 50, 2216-2218.
- Suziedelyte Visockiene J., Puziene R., Stanionis A., Tumeliene E., (2016), Unmanned Aerial Vehicles for Photogrammetry: Analysis of Orthophoto Images over the Territory of Lithuania, *International Journal of Aerospace Engineering*, 2016, 1-9.
- Tonkin T.N., Midgley N.G., Graham D.J., Labadz J.C., (2014), The potential of small unmanned aircraft systems and structure-from-motion for topographic surveys: A test of emerging integrated approaches at Cwm Idwal, North Wales, *Geomorphology*, 226, 35-43.
- Westoby M.J., Brasington J., Glasser N. F., Hambrey M. J., Reynolds J.M., (2012), Structure-from-Motion photogrammetry: A low-cost, effective tool for geoscience applications, *Geomorphology*, 179, 300-314.
- Yildirim O., Susam T., Yaprak S., Delen A., Inyurt S., (2016), The Availability of UAV Systems for Agricultural Purposes, *Journal of Agricultural Faculty of Gaziosmanpasa University*, 33, 111-120.



© Author(s) 2023.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>



## Türkiye Uzaktan Algılama Dergisi

https://dergipark.org.tr/tr/pub/tuzal

e-ISSN 2687-4997



### Kesikköprü Baraj Gölü Havzası Su Kaynaklarına Ait Hassasiyet Haritası

Olca Gülçiçek Uysal\*<sup>1</sup>, Kağan Cebe<sup>2</sup>

<sup>1</sup>Mersin Üniversitesi, Mühendislik Fakültesi, Çevre Mühendisliği Bölümü, Mersin, Türkiye

<sup>2</sup>Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Samsun, Türkiye

#### Anahtar Kelimeler:

Hassasiyet Haritası  
CBS  
Havza  
Su Kalitesi  
Bütünleşik Havza Yönetimi

#### ÖZ

Havzalar, içerdikleri yerleşim yerleri, sanayi ve tarım arazileri ile doğal alanların temel ekolojik işlevlerinin beslenmesi gerekli su kaynağını sağlar ve suyla birbirine bağlanan üst, orta ve alt kesimlerden oluşan karmaşık bir ekosistemden oluşur. Bir gölün su kalitesi büyük ölçüde gölün ve gölü besleyen kaynakların havzasındaki arazi kullanımına, endüstri tesisleri ve havzanın yönetim politikalarına bağlıdır. Bu çalışma, entegre havza yönetimi perspektifinden havzalarda su kaynaklarına ait bir hassasiyet indeksi oluşturmak için Coğrafi Bilgi Sistemleri (CBS) tabanlı yeni bir yaklaşım önermektedir. Çalışmada, Kesikköprü Baraj Gölü Havzasına ait doğal ve antropojenik faaliyetler ile ilgili verileri kullanılarak, faaliyetlerin su kaynakları üzerine etkileri analiz edilmiştir. Analiz edilen veriler, bir CBS yazılımı olan ArcGIS 10.8 yazılımı kullanılarak koordinatlarına göre haritalandırılmıştır. Çalışma alanına ait oluşturulan hassasiyet parametreleri ve değerlendirme puanı ile alana özgü hassasiyet ölçeği oluşturulmuştur. Su kaynaklarının kalitesini etkileyen faaliyetlere ait puanların, hassasiyet ölçeğinde değerlendirme sonuçları CBS programına aktarılarak, hassasiyet haritası oluşturulmuştur. Hassasiyet haritası ile, noktasal evsel kirlilik yükü kaynağı olan yerleşim yerlerinin ve fosseptiklerinin bulunduğu alanların *Çok Yüksek Hassasiyet* sahip bölgelerde olduğu tespit edilmiştir. Kesikköprü Baraj Gölü Havzası'ndaki madencilik faaliyetlerinin Hassasiyet Haritası ile değerlendirilmesi yapıldığında ise, bu alanların *Çok Yüksek Hassasiyet* ve *Orta Hassasiyete* sahip bölgelerde olduğu tespit edilmiştir. Bu çalışmada kullanılan metodoloji, su kaynaklarını koruma geliştirme, kentsel-kırsal kalkınma ve göl havzası planlaması gibi çeşitli planlama programlarında yol gösterici olacağı düşünülmektedir.

### Sensitivity Map of Kesikköprü Dam Lake Basin Water Resources

#### Keywords:

Sensitivity Map  
GIS  
Watershed  
Water Quality  
Integrated Basin Management

#### ABSTRACT

Watersheds offer vital water supply for the fundamental ecological roles of settlements, industrial and agricultural lands, and natural areas they comprise. They are made up of a complex ecosystem comprising upper, middle, and lower levels, all linked by water. The quality of a lake's water heavily relies on the land use in its catchment and the sources that supply it, as well as the industrial facilities and management policies found within. This study presents a methodology utilizing Geographic Information System (GIS) for developing a sensitivity index of catchment water resources from an integrated catchment management standpoint. The study analyses the impact of natural and anthropogenic activities on water resources in Kesikköprü Dam Lake Basin by employing data, which is mapped based on their coordinates using ArcGIS 10.8 software, a GIS application. An area-specific sensitivity scale was developed using sensitivity parameters and evaluation scores for the study area. The scores of activities that impact the quality of water resources were evaluated on the sensitivity scale, and the resulting data was transferred to the GIS program to generate a sensitivity map. It is believed that the methodology used in this study will serve as guidance for several planning programs, including the development of water resource protection, urban-rural development, and lake basin planning.

## 1. GİRİŞ

Su kıtlığı ve kirlilik gibi su krizleri, kritik küresel öneme sahip bir konu olarak kabul edilmektedir (Vörösmarty vd., 2010). Bu krizler, gıda ve enerji güvenliğinin sağlanması, ekonomik büyümenin artırılması, halk sağlığının desteklenmesi ve ekonomik ve sosyal sistem dengesinin korunması üzerinde yüksek baskı oluşturmuştur (Xue vd., 2021; Sun vd., 2012). Su kalitesinde değişimlerin esas olarak hidrolojik döngüye dayandığı yaygın olarak kabul edilmektedir (Abbaspour vd., 2015; Yao vd., 2020). Ancak hidrolojik, hidrodinamik ve su kalitesi süreçleri tam olarak anlaşılmamıştır (Xue vd., 2021). Bu nedenle entegre, çok yönlü bir havza yönetimi uygulaması üzerinde daha fazla çalışma yapılmalıdır.

Tüm Dünya’da havzaların su kalitesini olumsuz etkileyen ve kirliliğe yol açan faaliyetler büyük bir endişe kaynağı olmaktadır. Havzalarda kısıtlı ve heterojen bilgilerin bulunması havzaların su kaynaklarının yönetiminde ciddi sıkıntılara yol açmaktadır.

Havza sınırları içinde var olan tüm doğal kaynakların (su, toprak) kullanımı ve korunması, tarım, hayvancılık, sanayi, ticaret ve turizm gibi antropojenik faaliyetlerin kontrollü yürütülmesi, havza ekosisteminin korunması, havzaların etkin yönetimi ile gerçekleşmektedir (Beheim vd., 2012; Garipağaoğlu & Uzun, 2019).

Su kaynaklarının korunmasına karşı alınan önlemlerin artması ile günümüzde havzaların sürdürülebilir ve ülkelerin kalkınmasını destekler biçimde yönetimi önem kazanmıştır. Türkiye’de havza yönetimi-planlaması kapsamındaki çalışmalarda rolü, etkinliği ve işlevsel ağırlığı farklı olan birçok kurum ve kuruluş bulunmaktadır (Öztürk, 2011).

2000 yılında Avrupa Birliği üye ülkeleri tarafından yürürlüğe suyun entegre olarak yönetilmesi anlayışını benimseyen EC/2000/60 Sayılı AB Su Çerçeve Direktifi, nehir havzalarının yönetimine önem vermektedir. Türkiye’de Avrupa Birliği ne (AB) uyum süreci kapsamında, AB Su Çerçeve Direktifinin de uygulayıcısı konumundadır (Karadağ & Barış, 2012).

Türkiye ilk olarak 2009 yılında entegre havza yönetimi konusunda nehir havza yönetimi planlarının oluşturulması için çalışmalara başlamış ve son yıllarda havza yönetimi konularında önemli adımlar atmıştır. Bu amaçlar doğrultusunda havzalarda su miktarları, özellikleri ve kirlilik durumu belirlenmiş, antropojenik faaliyetlerden kaynaklı problemler tespit edilmiş, havzaların kirlilik durumu, kirlenici kaynakların tanımlanması vb. çevresel sorunlar raporlanmıştır. Bütüncül bir bakış açısı ile havzaların korunması ve yönetim planı oluşturulması adına yapılan çalışmalar, su kaynaklarının mevcut ve ilerleyen zamanlardaki durumuna önemli sonuçların ortaya çıkmasına sebep olmuştur.

Bu çalışma ile Kesikköprü Baraj Gölü Havzası’nın su kaynaklarının korunması ve


sürdürülebilir yönetimi üzerine katkı sağlayacağı düşünülen, su kaynaklarının doğal ve antropojenik faaliyetlere karşı kirlilik hassasiyetini gösteren bir harita oluşturulmuştur. Bu amaç ile havzanın mevcut durumundaki doğal (yüzey akış, eğim, erozyon, topografik yapı, bitki örtüsü, jeolojik yapı, toprak özellikleri) ve antropojenik faaliyetleri (arazi kullanım durumu, yerleşim yerleri, fosseptik, tarımsal faaliyetler, maden alanları, hayvancılık) ait veriler toplanarak analiz edilmiş ve veriler koordinatlarına göre bir CBS yazılımı olan ArcGIS 10.8 yazılımı kullanılarak haritalandırılmıştır.

## 2. YÖNTEM

### 2.1. Coğrafi Konum

Çalışma alanı, Ankara, Bala ve Şereflikoçhisar ilçeleri ve Kırşehir, Kaman ilçesi ile Kırıkkale, Çelebi ilçesi sınırları içerisinde bulunmaktadır. Çalışma alanı Kızılırmak Havzası-Orta Kızılırmak Alt Havzası sınırları içerisinde yer almakta olup, havzayı temsil eden Kesikköprü Barajı Gölü’nün orta noktası ED50 UTM Zone 36 536611 D ve 4359527 K koordinatlarında bulunmaktadır.

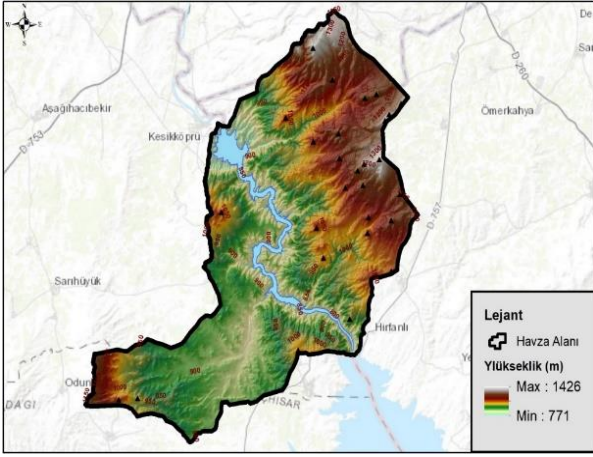
Türkiye 1/25.000 ölçekli pafta bölümlenmesinde barajın havza alanı; J30-b2, J30-b3, J30-b4, J30-c1 J30-c2, J31-a1 ve J31-a4 paftaları içerisinde yer almaktadır. Söz konusu baraj havzasının coğrafi konumunu gösterir harita Şekil 1’de verilmiştir.



**Şekil 1.** Kesikköprü Baraj Gölü Havzası’nın coğrafi konumu

### 2.2. Topografya


Kesikköprü Barajı Havzası’nda yükselti deniz seviyesinden 771 m ile 1426 m arasında değişen aralıklarda görülmektedir. Havzada genel olarak yüksek kotlardaki tepe ve dağ oluşumları incelendiğinde; havzanın kuzeyinde 1300 m kotunda Çardak Tepesi yer alırken, en düşük kottaki tepe olan Kepir Tepe (995 m) ise havzanın güneybatısında yer almaktadır. Havzanın topografik yapısı incelendiğinde genel olarak tepe oluşumlarının, havzanın kuzey ve doğu kesimlerinde görüldüğü tespit edilmiştir (Şekil 2).



Şekil 2. Yükseklik haritası

### 2.3. Yüzeysel Eğimler


Kesikköprü Baraj Havzası 25.242 ha'lık havza alanı incelenmiş ve havza alanında minimum eğim  $0,0^\circ$ , maksimum eğim ise  $45,5^\circ$  olarak tespit edilmiştir. Alanın ortalama eğimi ise  $7,5^\circ$ 'dir. Havzada genel olarak  $0-10^\circ$  de bir eğim gözlenirken, Kesikköprü Barajı çevresi incelendiğinde eğim değerlerinin artarak baskın olarak  $20-30^\circ$  Aralığında seyrettiği görülmektedir (Şekil 3).



Şekil 3. Eğim haritası

### 2.4. Yüzeysel Akış Yönleri

Havza alanının topografik yapısı incelenmiş ve bu inceleme sonucunda topografya eğimi için dört ana ve dört ara yön olmak üzere toplam sekiz adet akış yönü oluşturulmuştur. Oluşturulan bu yönler neticesinde havza alanındaki akışın her yöne doğru olduğu görülmüştür. Havza alanında akış yönleri yüksek kottan düşük kotlara doğru seyretmektedir. Özellikle Kesikköprü Barajı çevresi incelendiğinde havzanın doğusunda kalan ve tepe oluşumlarının yoğun olarak görüldüğü alanlardaki akışların düşük kottaki baraja doğru, batıya yöneldiği görülmektedir (Şekil 4).

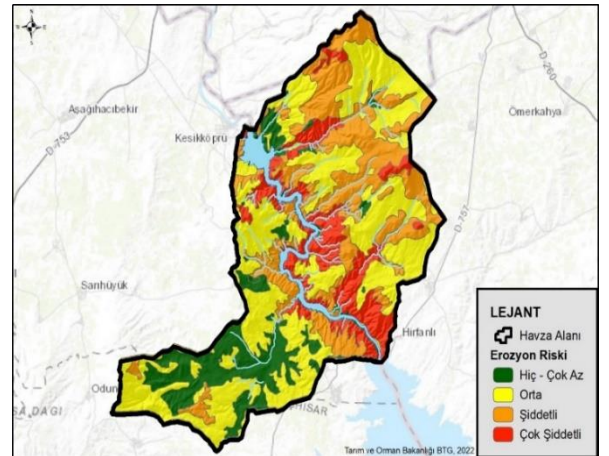


Şekil 4. Yüzeysel akış yönleri

### 2.5. Erozyon Risk Değerlendirmesi

Havza Alanı içerisinde erozyon risk durumunun analiz edilmesi amacıyla, toprak koruma ve arazi kullanımına yönelik 5403 sayılı "Toprak Koruma ve Arazi Kullanımı Kanunu" ve bu kanun gereği olarak çıkarılan "Uygulama Yönetmeliği" uyarınca toprak ve arazi sınıflaması yapılmasının usul ve esaslarının yer aldığı, "Tarım ve Orman Bakanlığı Toprak ve Arazi Sınıflaması Standartları Teknik Talimatı" kullanılmıştır. Bu çalışmada; Tarım ve Orman Bakanlığı'nın yukarıda bahsedilen çalışmalar doğrultusunda oluşturmuş olduğu erozyon risk analizi CBS verileri kullanılmış ve Kesikköprü Baraj Havzası'nda erozyon risk haritası oluşturularak dört sınıf altında incelenmiştir.

Erozyon riski çok şiddetli olan alanlar Kesikköprü Barajı çevresinde yoğunlaşırken aynı zamanda dere yataklarının çevresini de kapsamaktadır. Özellikle Kesikköprü Barajı'nın doğusunda kalan ve baraj ile yükselti farkının fazla olduğu bilinen bu alanlar şiddetli ve çok şiddetli erozyon sınıfında yer almaktadır (Şekil 5).

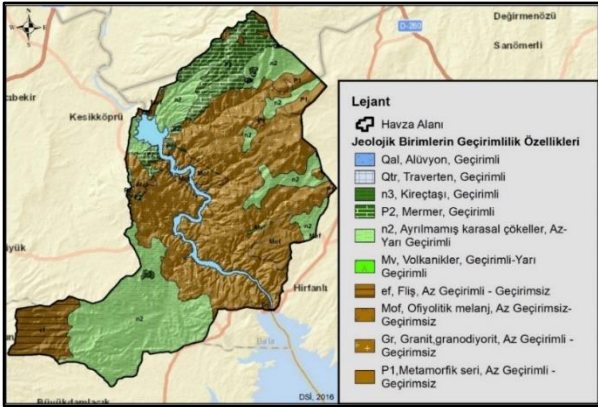


Şekil 5. Erozyon risk haritası

### 2.6. Çalışma Alanı Hidrojeolojisi

Kesikköprü Baraj Havzası; Savcılı YAS Alt Havzası (No: 15-2-9) ve Hirfanlı-Kesikköprü YAS Alt Havzası (No: 15-2-10) olmak üzere iki yeraltı suyu

havzası sınırları içerisinde kalmaktadır. Kesikköprü Baraj Havzasının 11.122 ha'lık alanı Hirfanlı-Kesikköprü YAS Alt Havzası içinde, 14.120 ha'lık kısmı ise Savcılı YAS Alt Havzası içinde kalmaktadır. Buna göre Hirfanlı-Kesikköprü YAS Alt Havzası'nın %21,14'ü, Savcılı Alt Havzasının ise %26,84'lük kısmı Kesikköprü Baraj Havzası alanını oluşturmaktadır (DSİ, 2016). Kesikköprü Hirfanlı YAS Alt Havzası; Paleozoyik yaşlı mermerler (P2) ve metamorfik seri (P1), Mesozoyik yaşlı granit-granodiyorit (Gr) ve ofiyolitik melanj (Mof), Neojen yaşlı ayrılmamış karasal çökeller (n2) ve kireçtaşı (n3), Eosen filiş (ef) ve baraj sınırı boyunca dar alanlarda gözlenen Kuvaterner alüvyon (Qal) birimlerini içermektedir. Kesikköprü Baraj Havzası'nın doğu kesiminde kalan Kırşehir ilini kapsayan Savcılı YAS Alt Havzası; Paleozoyik yaşlı mermerler (P2) ve metamorfik seri (P1), Mesozoyik yaşlı granit-granodiyorit (Gr), Volkanikler (Mv) ve ofiyolitik melanj (Mof), Neojen yaşlı ayrılmamış karasal çökeller (n2), Kuvaterner traverten (Qtr) ve yine baraj sınırı boyunca gözlenen Kuvaterner alüvyon (Qal) birimlerini içerdiği görülmektedir. Havza alanındaki jeolojik birimlerin geçirimsizlik özellikleri Şekil 6'da verilmiştir.



Şekil 6. Jeolojik birimler ve geçirimsizlik özellikleri

## 2.7. Meteorolojik Değerlendirme

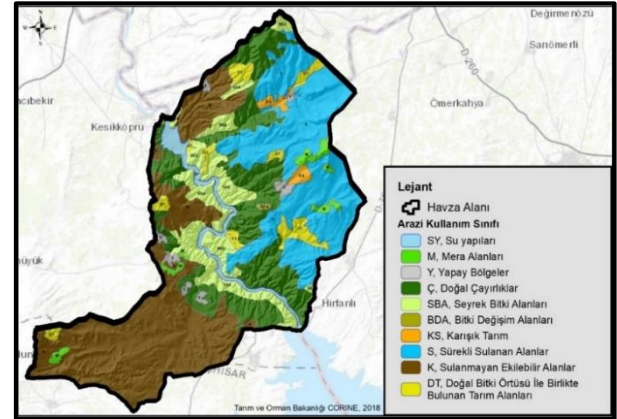
Kesikköprü Baraj Havzası; Ankara ili Bala ve Şereflikoçhisar ilçeleri, Kırşehir ili Kaman ilçesi ve havzanın kuzey uç kesimleri ise Kırıkkale ili Çelebi ilçesi sınırları içerisinde yer almaktadır. Bala ve Şereflikoçhisar ilçeleri yazları sıcak, kışları soğuk ve kar yağışlı geçen bir iklime sahiptir. Yüksekliği nedeniyle kış aylarında Ankara ilinin en soğuk ilçeleri arasında yer alır. Sıcak ve ılıman geçen yaz aylarına rağmen en kurak aylarda bile diğer ilçelere göre yağış miktarının oldukça fazla olduğu görülmektedir. Kaman ve Çelebi ilçesinde ise; yazlar ılık, kurak ve açık, kışlar çok soğuk ve karlıdır. Çalışma alanını en iyi temsil eden Meteoroloji Genel Müdürlüğü (MGM), Kaman Meteoroloji İstasyonu verileri incelendiğinde çalışma alanında yıllık ortalama yağış 39,3 mm olarak görülmektedir. Ortalama maksimum yağış 64,7 mm ile Aralık ayında, ortalama minimum yağış ise 9,4 mm ile Ağustos ayında gözlenmiştir. Uzun yıllar ortalama

yağış verileri incelendiğinde, çalışma alanı için kurak dönem Nisan, Temmuz, Ağustos, Eylül ve Ekim aylarını kapsayan beş aylık dönem; yağışlı dönem ise Ocak, Şubat, Mart, Mayıs, Haziran, Kasım ve Aralık aylarını içeren sekiz aylık dönem olarak değerlendirilmiştir.

## 2.8. Arazi Kullanım Durumu

Kesikköprü Baraj Havzası'nda arazi kullanım durumunun belirlenmesi amacıyla Tarım Orman Bakanlığı'nın Coordination of Information on the Environment-Çevresel Bilginin Koordinasyonu (CORINE) verisi kullanılmıştır. CORINE, Avrupa Çevre Ajansı (AÇA) tarafından belirlenen Arazi Örtüsü/Kullanımı Sınıflandırmasına göre uydu görüntüleri üzerinden bilgisayar destekli görsel yorumlama metodu ile üretilen arazi örtüsü/kullanımı verisidir. AÇA kriterleri ve sınıflama birimlerine göre (44 sınıf), uydu görüntüleri üzerinden arazinin izlenmesine yönelik arazi örtüsü/arazi kullanımındaki değişiklikler uzaktan algılama ve coğrafi bilgi sistemleri yardımıyla tespit edilmektedir. Türkiye'de CORINE 1990, 2000, 2006, 2012, 2018 yılları arazi örtüsü haritaları ile 1990-2000, 2000-2006, 2006-2012, 2012-2018 yılları arası değişim veri tabanları oluşturmuş ve çalışmada kullanılmıştır (Tarım ve Orman Bakanlığı, 2022).

Genel olarak havzada arazi kullanım durumu incelendiğinde genel olarak doğal çayırliklar ile tarım arazilerinin baskın olduğu görülmüştür (Şekil 7).




Şekil 7. CORINE arazi kullanım haritası

## 2.9. Yerleşimler ve Nüfus

Çalışma alanında 13 adet yerleşim yeri bulunmaktadır (Şekil 8). Bu yerleşim yerlerinin altı âdeti Bala ilçesi sınırları içerisinde, yedi âdeti ise Kaman ilçesi sınırları içerisinde kalmaktadır. Kaman ilçesi sınırları içerisindeki Hirfanlı köyü, havza sınırı dışında olmasına karşın havzayı etkileyecek parsellerinin bulunması ve havza sınırına 365 m mesafede olması nedeniyle değerlendirmelere dâhil edilmiştir. Çalışma alanının, Bala ilçesi sınırları içerisinde kalan altı adet mahallenin tamamı Bala

Belediyesi ilçe mülki sınırları içerisindedir. Çalışma alanının Kaman ilçesinde kalan yedi adet yerleşim yeri ise Kırşehir İl Özel İdaresi mülki sınırları içerisindedir.




Şekil 8. Yerleşim yerleri

Kesikköprü Baraj Gölü Havzası'ndaki yerleşimlerin kanalizasyon ve fosseptik durumları, mahalle muhtarı ile yapılan görüşmeler sonucunda belirlenmiştir. Elde edilen sonuçlar, Bala Belediyesi ve Kırşehir İl Özel İdaresi'nden de teyit edilmiştir. Yerleşim yerlerinin kanalizasyon ve fosseptik durumları Tablo 1'de verilmiştir.

Tablo 1. Yerleşim kanalizasyon ve fosseptiklerinin mevcut durumu

Mahalle/Köy	Kanalizasyon Sistemi	Fosseptik	Fosseptik Yapısı/Deşarj Yeri	Kullanım Durumu
Kesikköprü <sup>1</sup>	Var	Merkezi	Betonarme	Faal
Tepeköy	Var	Merkezi	Betonarme	Faal
Küçükcamili	Var	Merkezi	Betonarme	Faal
Büyükcamili	Var	Merkezi	Betonarme	Faal
Bektaşlı	Var	Merkezi	Betonarme	Faal
Küçükbıyık	Var	Merkezi	Betonarme	Faal
Hirfanlı	Var	Merkezi	Betonarme	Faal
İkizler	Yok	Ferdi	Taşla örülü	-
Kargınyenice	Var	Yok	Kızılırmak'a deşarj	-
Tatık	Var	Merkezi	Betonarme	Faal
Ağapınar	Var	Merkezi	Betonarme	Faal
Karaosman	Var	Merkezi	Betonarme	Faal
Büğüz	Var	Merkezi	Betonarme	Faal

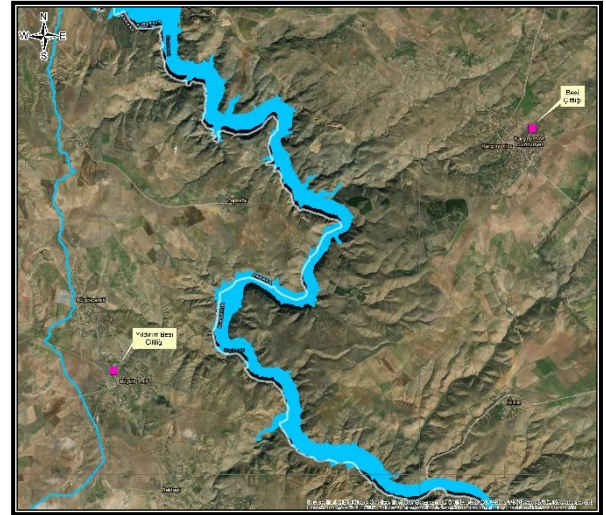
Çalışma alanındaki yerleşim yerlerinin fosseptiklerine ait harita Şekil 9'da verilmiştir.



Şekil 9. Fosseptik alanlarının konumları

## 2.10. Hayvancılık Faaliyetleri

Havzada bilinen büyük ölçekli bir besi çiftliği bulunmamaktadır. Bunun yanında havzada yoğun hayvancılık faaliyetleri yaptığı gözlenmiştir. Havza içerisinde yerli halkın kendi hayvanlarına baktıkları küçük ve orta ölçekli mandıra, ahır ve ağılların olduğu görülmüştür. Yapılan incelemelerde bu mandıra, ahır ve ağıllardaki hayvan gübrelerinin çoğunlukla toprak bir alan üzerine yığıldığı ve daha sonra bu gübrelerin tarımsal amaçlı kullanıldığı ortaya konulmuştur (Şekil 10).



Şekil 10. Besicilik çiftliklerinin konumları

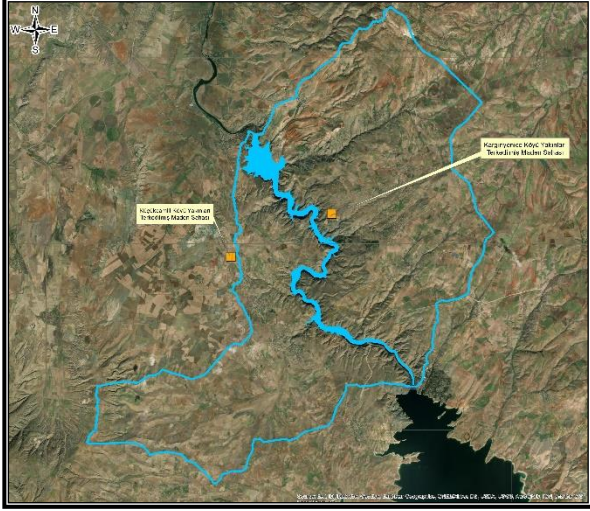
## 2.11. Terk Edilmiş ve Aktif Maden Sahaları

Kesikköprü Baraj Gölü Havzası'nda Kırşehir ili, Kaman İlçesi, Büğüz, Ağapınar ve Tatık köyleri sınırı, Karaosman yaylası mevkiinde işletilmekte olan bir adet aktif durumda Demir Ocağı ve Kırma-Elemente Tesisi ile Kalsit Ocağı ve Kalsit Tesisi aynı alan içinde bulunmaktadır. Bu tesisler, 1740,24 ha alan için verilen IV. Grup İşletme Ruhsatı (Demir) sahası içerisinde bulunmaktadır. Demir madeni işletme ruhsatı sahası içerisindeki maden ocağındaki atık barajının altı kil ile kaplıdır dolayısı ile alıcı ortama



sıfır deşarj söz konusudur. Bu nedenle maden ocağında sızıntı yaratacak herhangi bir çalışma da bulunmamaktadır.

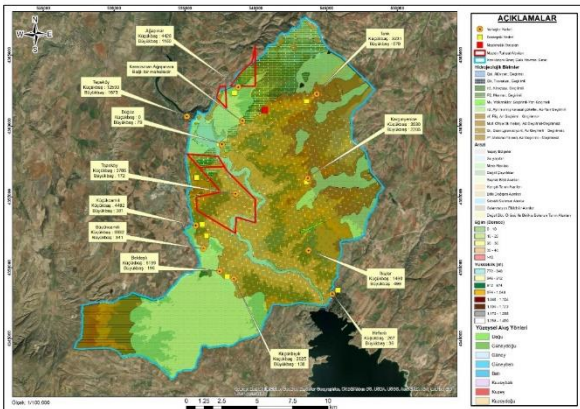
Kesikköprü Baraj Gölü Havzası'ndaki terk edilmiş maden sahaları yerinde tespit edilmiştir. Havza çalışma alanı sınırları içerisinde bir adet, çalışma alanı sınırı dışında ancak sınıra çok yakın bir konumda olan bir adet olmak üzere toplam iki adet terk edilmiş maden sahası tespit edilmiştir. Bu alanlara ait konum haritası Şekil 11'de verilmiştir.



Şekil 11. Terkedilmiş maden sahaları

## 2.12. Hassasiyet Haritası Oluşturulması

Havzanın hassasiyet haritasını oluştururken, havzadaki doğal (yüzey akış, eğim, erozyon, topoğrafik yapı, bitki örtüsü, jeolojik yapı, toprak özellikleri) ve antropojenik faaliyetler (arazi kullanım durumu, yerleşim yerleri, fosseptik, tarımsal faaliyetler, maden alanları, hayvancılık) coğrafik koordinatlarına göre ArcGIS 10.8 yazılımı kullanılarak CBS ortamına aktarılmış ve analiz edilmiştir (Şekil 12).



Şekil 12. Doğal ve antropojenik faaliyet haritası

Tüm veriler göz önüne alınarak, Kesikköprü Baraj Gölü Havzası'ndaki doğal (yüzey akış, eğim, jeolojik, toprak özellikleri, erozyon) ve antropojenik faaliyetler (yerleşim yerleri, fosseptik, tarımsal faaliyetler, maden alanları, hayvancılık)

tanımlanmıştır ve hassasiyet bölgeleri oluşturulmuştur.

Hassasiyet bölgeleri oluşturulurken, değerlendirilen parametreler arasında önceliklendirme yapılmış ve çoklu değerlendirme metodu ile belirlenen 12 öncelikli parametre analiz edilmiştir. Analizde çok kriterli değerlendirme yöntemi olan analitik hiyerarşi yöntemi kullanılmıştır.

Bu bağlamda alanda Tablo 2' de verilen puanlama sistemi uygulanmıştır. Puanlama yapılırken yüzey akışın baraj gölü ve nehir yönüne doğru baskın olduğu kabulü yapılmış olup, ara noktadaki sapmalar ihmal edilmiştir. Havzanın jeolojik yapısı değerlendirirken alanda baskın olarak faaliyetlerin yürütüldüğü formasyonlar puanlamaya dâhil edilmiştir. Puanlamada hayvancılık faaliyetlerinde hayvan sayısı dikkate alınmamış olup, faaliyetin varlığı puanlamaya dâhil edilmiştir. Havzadaki hayvancılık ve fosseptik faaliyetleri noktasal veri olarak kabul edilmiştir.

Tablo 2. Hassasiyet bölgelerini belirleyen parametreler ve değerlendirme puanları

Antropojenik Etkiler	Puan
Yerleşim yeri	1
Hayvancılık	1
Sürekli sulanan alanlar	1
Doğal Bitki Örtüsü İle Bulunan Tarımsal Alanlar	1
Karışık Tarım	1
Fosseptik Noktaları	1
Maden İşletme Alanı	1
Doğal Etkiler	Puan
Erozyon Yüksek Alanlar	1
Hidrolik Eğim (%20-40)	1
Granit Alan (jeolojik yapısı az geçirimli/geçirimsiz)	2
Kireçtaşı+Mermer Alan (jeolojik yapısı geçirimli)	0
Ayrılmamış Karasal Çökeller (jeolojik yapısı yarı-az geçirimli)	1

Tablo 2'den elde edilen puanlar ile Tablo 3'te verilen hassasiyet ölçeği elde edilmiştir. Ölçekten elde edilen veriler alanın 1/25000 sayısallaştırılmış haritası üzerine aktarılmış ve Kesikköprü Baraj Gölü Havzası hassasiyet haritası oluşturulmuştur (Şekil 13).

**Tablo 3.** Hassasiyet ölçeği

Derece	Puan	Renk
Çok Yüksek	>7	Kırmızı
Yüksek	7	Turuncu
Orta	5-6	Mavi
Düşük	<5	Yeşil

### 3. BULGULAR

#### 3.1. Çalışma alanındaki doğal faaliyetlerin su kalitesi üzerine etkileri

Çalışma alanında yükseklik verileri incelendiğinde Kesikköprü Baraj Gölü Havzasını ikiye ayıran Kızılırmak nehrinin batı yönünde kalan alanda yüksekliğin havzanın kuzeyinden güneyine doğru 1258 m'den nehrin kıyısına kadar yaklaşık 772 m ye kadar düştüğü, nehrin doğu tarafında ise yer yer maksimum 1173-1104 m arasında yükseklik göstererek yine nehrin kıyısında 772 m civarına düştüğü görülmektedir.

Çalışma alanında yüzey akış yönleri, yükseklik ve eğim verileri birlikte incelendiğinde havza alanını ikiye ayıran Kızılırmak nehrine doğru eğimin artıp, yüksekliğin düştüğü dolayısıyla yüzey akışın toplanma noktası olduğu söylenebilir. Topografik özelliklerinin yanı sıra, alanın toprak yapısı ve jeolojik özellikleri de değerlendirildiğinde aşağıdaki sonuçlar elde edilmiştir.

Çalışma alanı jeolojisi incelendiğinde, nehrin her iki yönü olmakla birlikte özellikle batı yönünde yaygın olarak az geçirimli-geçirimsiz granit kayalardan; Kesikköprü Baraj gölü etrafının ise Az geçirimli-Yarı geçirimli ayrılmamış karasal çökellerden oluştuğu görülmektedir. Alanın toprak ve jeolojik özellikleri yüzey akışın ne kadarının yeraltına ne kadarının cazibeli olarak yüzey akışta seyredeceği konusunda önemlidir. Kesikköprü Baraj Gölü Havzası'nın toprak ve jeolojik özellikleri göz önüne alındığında, alanda yapılan antropojenik herhangi bir faaliyetten yüzey sularının akış yönünde etkilenme potansiyeli olduğunu göstermektedir.

Kaman Meteoroloji istasyonlarından elde edilen verilere göre çalışma alanı değerlendirildiğinde; yağışın özellikle ilkbahar ve kış aylarında fazla olduğu söylenebilmektedir. Sonuç olarak bu mevsimlerde yüzey sularında kirletici parametrelerin daha yüksek konsantrasyonlara ulaşması muhtemeldir.

#### 3.2. Çalışma Alanındaki Antropojenik Faaliyetlerin Su Kalitesi Üzerine Etkileri

##### Yerleşimler

Kesikköprü Baraj Gölü Havzasında başlıca 13 adet kırsal yerleşim yeri bulunmaktadır. Bu yerleşim yerlerinin altısı nehrin doğu yönünde, yedisi ise batı

yönündedir. Oluşan atık suların çok az bir kısmı Kesikköprü Atık Su Arıtma Tesisinde, geriye kalan kısmı ise merkezi ve ferdi fosseptiklerde toplanmaktadır. Yerinde yapılan gözlemlerde, fosseptik yapısı betonarme olmasına rağmen bazı yerleşim yerlerindeki fosseptiklerin bakımsızlıktan dolayı üstten sızdirdığı ve sızan suların Kızılırmak'a karıştığı tespit edilmiştir. Geçirimsiz tabaka üzerinde konumlanan fosseptiklerden meydana gelebilecek herhangi bir sızıntının yüzey suyunu kirletmesi olasıdır.

Ağapınar, Büğüz, Büyükcamili, Bektaşlı yerleşim yerleri yarı -az geçirimli kayalar üzerinde olup yüzeyde meydana gelebilecek olan tüm faaliyetlerden yeraltı suyuna sızma yaşanabileceği gibi; bu yerler dışında kalan yerleşim birimleri genel olarak az geçirimli-geçirimsiz tabaka üzerinde olduğu görülmektedir. Bu noktalarda yaşanabilecek herhangi bir faaliyetten yüzey suları daha fazla etkilenecektir.

##### Tarım

Kesikköprü Baraj Gölü Havzası'nda daha çok doğal çayırliklar ile tarım arazilerinin baskın olduğu görülmektedir. Kızılırmak Nehri'nin doğu ve batı kıyı yönlerinde seyrek bitki alanları; batı yönünde ise sürekli sulanan alanlar, doğal bitki örtüsü ile birlikte bulunan tarım alanları, karışık tarım alanları mevcuttur. Havzanın yüzey suyu akış yönü ile birlikte değerlendirildiğinde, tarımsal faaliyetlerde kullanılan gübre ve pestisitlerin sulama suyu ve yağmur sularının yüzey akışa geçmesi ile birlikte yüzey sularına taşınabilmesi olasıdır. Yaygın olarak tarım yapılan arazilerin, granit tabaka üzerinde olması da, suyun büyük bir kısmının drenajının yüzeyden gerçekleşmesine zemin hazırlamaktadır.

##### Hayvancılık

Havza içerisinde Büyükcamili ve Kargınyenice yerleşim yerlerinin bulunduğu mevkide küçük ölçekli besicilik çiftlikleri bulunmaktadır. Havza içerisinde yerli halkın kendi hayvanlarına baktıkları küçük ve orta ölçekli mandıra, ahır ve ağılların olduğu görülmüştür. Yapılan incelemelerde bu mandıra, ahır ve ağıllardaki hayvan gübrelerinin çoğunlukla toprak bir alan üzerine yığıldığı ve daha sonra bu gübrelerin tarımsal amaçlı kullanıldığı bilgisi alınmıştır. Havzada küçük ölçekli yapılan hayvancılık faaliyetlerinde hayvan gübrelerinin biriktirildiği alanda yeraltı ve yüzey suyuna karışması olasıdır.

##### Maden Ocakları

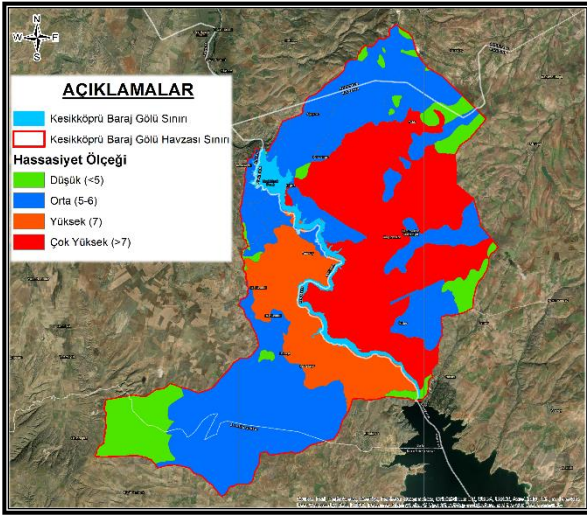
Havza içinde ruhsatlı ikisi nehri batısında, ikisi nehrin doğusunda olmak üzere toplam dört adet demir madeni alanı mevcuttur. Tüm maden alanlarının konumları havza içinde yüzey akış yönü doğrultusunda konumlanmıştır.

Erişim Numarası 3188447 No.lu maden işletmesi az geçirimli/geçirimsiz olarak sınıflandırılan granit kayalar üzerinde konumlanmış olup, bu noktada meydana gelebilecek deşarj, sızıntı,

kaza durumlarında toprak tarafından yeteri kadar filtre edilemeyeceğinden, yüzey akışa geçmesi yüksektir. Yüzey akışa geçen sızıntı veya bulaşın akış yönü boyunca nehri ve nehri besleyen kolları kontamine etme riski yüksektir.

Erişim Numarası 3326626, 3393019 No.lu maden işletmeleri geçirimli olarak sınıflandırılan kireç taşı ve mermer kayaları üzerinde konumlanmıştır. Bu noktalarda meydana gelebilecek deşarj, sızıntı, kaza durumlarında toprak filtrasyonu gerçekleşebileceğinden, yeraltı suyu akış yönü boyunca ilerleyerek yeraltı suyu kirliliğine neden olabileceği gibi, yüzey akışta kalan kısmı ise yüzey akış yönü boyunca ilerleyerek özellikle civarında bulunan baraj gölüne risk teşkil etmektedir.

Hassasiyet haritası incelendiğinde, noktasal evsel kirlilik yükü kaynağı olan yerleşim yerlerinin ve fosseptiklerinin bulunduğu alanların *Çok Yüksek Hassasiyet* sahip bölgelerde olduğu tespit edilmiştir. Bu bölgelerde var olan fosseptiklerin ıslah edilerek, atıksuların ilerleyen zamanlarda havzadan güvenli yollarla aktarımının sağlanması gerekmektedir. Bölgede hayvancılık faaliyetlerinin bireysel oluşu ile mevcut durumda kirlilik yaratmayacağı düşünülmektedir (Şekil 13).



Şekil 13. Kesikköprü Baraj Gölü Havzası hassasiyet haritası

Kesikköprü Baraj Gölü Havzası'nda hâlihazırda işletmede olan bir adet maden ocağı işletmesi ve bir adet terk edilmiş maden sahası havzanın Hassasiyet Haritası ile değerlendirildiğinde, bu alanların *Çok Yüksek Hassasiyet* ve *Orta Hassasiyet* sahip bölgelerde olduğu tespit edilmiştir (Şekil 13). Maden alanlarının havzanın Hassasiyet Haritası'nda *Çok Yüksek Hassasiyet* ve *Orta Hassasiyet* sahip bölgelerde olması bize bu bölgelerde meydana gelebilecek herhangi bir faaliyetin havzayı etkileyebileceğini göstermektedir. Kısa ve uzun vadede hala hazırda işletilmekte olan maden ocaklarının üzerinde buldukları alanın hassasiyeti nedeniyle üretim ve depolama aşamalarının düzenli takip edilmesi ve izlenmesi önerilmektedir. Orta vadede de ise yukarıda açıklanan sebeplerden ötürü,

terkedilmiş maden sahalarının rehabilitasyonunun (doğaya yeniden kazandırma çalışması) gerçekleştirilmesi önerilmektedir.

Elde edilen hassasiyet haritasının, bölgede yapılması planlanan antropojenik faaliyetlerin yer seçimi ve bu faaliyetlerin su kaynaklarına etkisinin önceden tahmin edilmesine yardımcı olacağı düşünülmektedir.

#### 4. SONUÇLAR

Bu çalışma, Kesikköprü Baraj Gölü Havzası'ndaki doğal ve antropojenik faaliyetlerinin su kaynaklarının kalitesine etkilerini analiz edip tanımlamış ve su kaynaklarının kirlenebilirliğe karşı hassasiyetini tanımlayan haritası oluşturulmuştur.

Havzaya ait özelliklerin bir arada değerlendirilmesi adına, her parametreye ait değerlendirme puanı oluşturulmuştur. Puanlamanın havza ölçeğinde değerlendirilmesi ile de çalışma alanına ait hassasiyet ölçeği geliştirilmiştir. Bu ölçeğe göre elde edilen harita yorumlandığında, Kesikköprü Baraj Gölü Havzası'nın su kaynaklarının genelde "Çok yüksek", "Yüksek" "Orta Hassasiyet" olarak belirlenen alanlarda olduğu tespit edilmiştir.

Baraj Gölü'nün "Orta hassasiyet" olarak belirlenen bölgede konumlanması, Gölün Ankara ili için alternatif su kaynağı olmasından dolayı, korunması ve yönetiminin önemli olduğunu ortaya koymaktadır.

Baraj Gölünü besleyen Kızılırmak nehrinin akım yolu, büyük oranda "Çok yüksek", "Yüksek" hassasiyet içeren bölgelerden oluşmaktadır. Havza'nın ana su kaynağı olan Kızılırmak Nehri içinde düzenli olarak takip edilip, korunması ve yönetilmesi gerekmektedir.

Bu bölgelerde arazi kullanımı ve su hassasiyeti koordinasyonuna dikkat edilmeli ve su sistemi desenini değiştirecek her türlü mekânsal geliştirme yönteminden kaçınılmalıdır. Bu çalışmada kullanılan metodoloji ile elde edilen hassasiyet haritasının, su kaynaklarını koruma geliştirme, kentsel-kırsal kalkınma ve göl havzası planlaması gibi çeşitli planlama programlarında yol gösterici olacaktır.

#### Bilgilendirme/Teşekkür

Bu çalışma Ankara Büyükşehir Belediyesi, Su ve Kanalizasyon İşleri Genel Müdürlüğü tarafından yürütülen "Kesikköprü Barajı Havza Koruma Planı ve Özel Hüküm Belirleme Projesi" çerçevesinde gerçekleştirilmiştir.

#### Araştırmacıların katkı oranı beyan özeti

O. Gülçiçek Uysal: Veri analizi, Araştırma, Modelleme, Makale yazımı;

K. Cebe: Arazi çalışması, Görselleştirme, Kontrol, Modelleme.

### Çıkar çatışması beyanı

Makale ile ilgili olarak, herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

### Araştırma ve yayın etiği beyanı

Yapılan çalışmada yazarlar, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul izni gerektirmediğini beyan etmektedir.

### KAYNAKÇA

Abbaspour, K., Rouholahnejad, E., Vaghefi, S., Srinivasan, R., Yang, H., & Kløve, B. (2015). A continental-scale hydrology and water quality model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. *Journal of Hydrology*, 524, 733-752. <https://doi.org/10.1016/j.jhydrol.2015.03.027>

Beheim, E., Rajwar, G. S., Haigh, M. & Krecek, J. (2012). *Integrated Watershed Management: Perspectives and Problems*. Springer Science & Business Media. <https://doi.org/10.1007/978-90-481-3769-5>

DSİ (2016). Kızılırmak Havzası Master Plan Raporu Hazırlanması İş, Havza Çevre ve Su Kalitesi Nihai Raporu, Devlet Su İşleri Genel Müdürlüğü, Ankara.

Garipağaoğlu N. & Uzun, M. (2019). İznik Gölü Havzası'nda Doğal Ortam Koşullarının Havza Yönetimi ve Planlamasına Etkisi. *Doğu Coğrafya Dergisi*, 24(42), 1-15. <https://doi.org/10.17295/ataunidcd.621776>

Karadağ, A. A. & Barış, M. E. (2012). Kovada Gölü Alt Havza Yönetim Planının Geliştirilmesi. *Düzce Üniversitesi Orman Fakültesi Ormanlık Dergisi*, 8 (1), 118-136. Retrieved from <https://dergipark.org.tr/tr/pub/duzceod/issue/4822/290256>

Öztürk, S. (2011). Devrekani Çayı Alt Havzası örneğinde havza yönetim planının geliştirilmesi [Yayınlanmamış Doktora tezi].

Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

Xue, B., Zhang, H., Wang, Y., Tan, Z., Zhu, Y., & Shrestha, S. (2021). Modeling water quantity and quality for a typical agricultural plain basin of northern China by a coupled model. *Science of The Total Environment*, 790, 148139. <https://doi.org/10.1016/j.scitotenv.2021.148139>

Sun, B., Zhang, L., Yang, L., Zhang, F., Norse, D. & Zhu, Z. (2012). Agricultural non-point source pollution in China: causes and mitigation measures. *AMBIO*, 41, 370-379. <https://doi.org/10.1007/s13280-012-0249-6>

Tarım ve Orman Bakanlığı, (2022). <https://corine.tarimorman.gov.tr/corineportal/> Erişim: 7 Mayıs 2022.

Vörösmarty, C., McIntyre, P., Gessner, M., Dudgeon, D., Prusevich, A., Green, P., Glidden, S., Bunn, S., Sullivan, C. & Liermann, C. (2010). Global threats to human water security and river biodiversity. *Nature*, 467, 555. <https://doi.org/10.1038/nature09440>

Yao, J., Wang, P., Wang, G., Shrestha, S., Xue, B., & Sun, W. (2020). Establishing a time series trend structure model to mine potential hydrological information from hydrometeorological time series data. *Science of the Total Environment*, 698, 134227. <https://doi.org/10.1016/j.scitotenv.2019.134227>



© Author(s) 2023.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>