

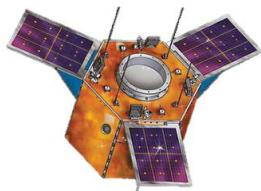
# Turkish Journal of REMOTE SENSING

Türkiye Uzaktan Algılama Dergisi



Yıl 16 Sayı 6  
Haziran 2024  
Bölüm: Uzaktan Algılama ve Geoteknoloji

e-ISSN: 2687-4997



## Dergi Hakkında

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

## Amaç & Kapsam

TUZAL Dergisi,

- ✚ Uzaktan algılama bilimi ve teknolojisinde özgün araştırmaları teşvik etmek ve yayinallyamak.
- ✚ Farklı disiplinlerden bilim insanları ve uzmanları arasında bilgi alışverisini ve iş birliğini geliştirmek.
- ✚ Uzaktan algılama uygulamalarının teorik ve pratik yönlerini ele alan yüksek kaliteli makaleler sunmak.
- ✚ Uzaktan algılama alanındaki en son gelişmeleri ve yenilikleri bilim camiasına ve kamuya duyurmak.
- ✚ Uzaktan algılama araştırmalarının etik ve sorumlu bir şekilde yürütülmesini teşvik etmek.

Derginin kapsamı;

- ✚ Uzaktan algılama sensörleri ve platformları
- ✚ Görüntü işleme ve analiz teknikleri
- ✚ Veri füzyonu ve modelleme
- ✚ RADAR/SAR/LIDAR uygulamaları
- ✚ Hiperspektral uzaktan algılama
- ✚ Uzaktan algılama uygulamaları:
  - Çevre izleme
  - Afet yönetimi
  - Tarım ve ormancılık
  - Kentsel planlama ve altyapı
  - Jeoloji ve jeomorfoloji
  - Hidrolojisi
  - Okyanus bilimi
  - Atmosferik bilimler
- ✚ Uzaktan algılama ve CBS yöntemlerinin entegrasyonu
- ✚ Coğrafi Bilgi Sistemleri Uygulamaları,
- ✚ İnsansız Hava Araçları (İHA) ve Yersel Lazer Tarama ile gözlem uygulamaları
- ✚ Uzaktan algılama eğitimi ve kapasite geliştirme
- ✚ Uzaktan algılama ile ilgili yasal ve politik konular

## Yayınlanma Sıklığı

Yılda 2 sayı(Haziran-Aralık)

## ISSN

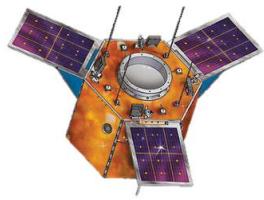
2687-4997

## WEB

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

## İletişim

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



*Turkish Journal of Remote Sensing*

**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 promote and publish original research in remote sensing science and technology.
- To foster information exchange and collaboration among scientists and experts from different disciplines.
- To present high-quality articles that address the theoretical and practical aspects of remote sensing applications.
- To disseminate the latest developments and innovations in remote sensing to the scientific community and the public.
- To encourage the ethical and responsible conduct of remote sensing research.

Scope of The Journal;

- Remote sensing sensors and platforms
- Image processing and analysis techniques
- RADAR/SAR/LIDAR
- Hyperspectral remote sensing
- Data fusion and modeling
- Remote sensing applications:
  - Environmental monitoring
  - Disaster management
  - Agriculture and forestry
  - Urban planning and infrastructure
  - Geology and geomorphology
  - Hydrology
  - Ocean science
  - Atmospheric sciences
- Integration of remote sensing and GIS methods
- Applications of geographic information systems
- Observation applications with Unmanned Aerial Vehicles (UAV) and Terrestrial Laser Scanning
- Remote sensing education and capacity building
- Legal and policy issues related to remote sensing

**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



Turkish Journal of Remote Sensing

---

## 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 Haci 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. Nebiye MUSAOĞLU, İstanbul Technical University, TR
- Prof. Dr. Semih EKERCİN, Necmettin Erbakan University, TR
- Prof. Dr. Taşkin KAVZOĞLU, Gebze Technical University, TR
- Prof. Dr. Uğur AVDAN, Eskişehir Technical University, TR
- Prof. Dr. Alper ÇABUK, Eskişehir Technical University, TR
- Prof. Dr. Murat UYSAL, Afyon Kocatepe University, TR
- Prof. Dr. Saygın ABDİKAN, Hacettepe University, TR
- Prof. Dr. Djamil Al-halbouni, University of Leipzig, DE
- Prof. Dr. Khalil Valizadeh KAMRAN, University of Tabriz, IR
- Assoc. Prof. Dr. Muammer TÜN, Eskişehir Technical University, TR
- Assoc. Prof. Dr. Ali İhsan ŞEKERTEKİN, İğdır University, TR
- Assoc. Prof. Dr. Mehmet Ali DERELİ, Giresun University, AU
- Assoc. Prof. Dr. Ben JARIHANI, James Cook University, AU
- Assist. Prof. Dr. Mustafa ÜSTÜNER, Artvin Çoruh University, TR
- Dr. Emre HAVAZLI, NASA, USA
- Dr. Fabiana CALO, Irea Cnr, IT
- Dr. Kaan KALKAN, TÜBİTAK, TR
- Dr. Yasser MAGHSOUDI, University of Leeds, GB
- Dr. Mahmud Haghshenas Haghghi, Leibniz University Hannover, DE
- Dr. Giuseppe Pulighe, CREA Research Centre for Agricultural Policies and Bioeconomy, IT

---

## DANIŞMA KURULU /ADVISORY BOARD

- Prof. Dr. Semih EKERCİN, Necmettin Erbakan University, TR
- Prof. Dr. Ferruh YILDIZ, Konya Technical University, TR
- Prof. Dr. Fevzi KARSLI, Karadeniz Technical University, TR
- Assoc. Prof. Dr. Yaohui LIU, Shandong Jianzhu University, CN

---

## 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

### **Mohammad Maleki**

Kharazmi University / Tehran, IR

# İçindekiler

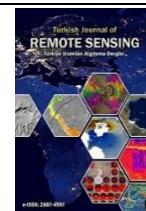
## Contents

### Araştırma Makaleleri;

### *Research Articles;*

#### **S. No**

- 
- 68-84 Tarımda Sulama Göletlerinin İklim Üzerine Etkilerinin Uydu Görüntüleri ve Meteorolojik Verilerle Karşılaştırmalı Olarak İncelenmesi  
(Comparative Investigation of the Effects of Irrigation Ponds on Climate in Agriculture Using Satellite Imagery and Meteorological Data)  
**Abdurahman Yasin Yiğit, Oğuz Şimşek, Halil İbrahim Şenol**
- 85-96 EXOLIFE: Detection and Habitability Estimation of Exoplanets Using Machine Learning Techniques  
(EXOLIFE: Makine Öğrenmesi Kullanarak Ötegezegenlerin Tespit Edilmesi ve Yaşanabilirlik Tahmini Yapılması)  
**Eren Yılmaz, Muhammet Enes Artan, Ahmet Bilal Yanartaş**
- 97-111 Use of Hyperspectral Data for Chlorophyll Estimation Based on Leaf Area Index (LAI) in Wheat  
(Buğdayda Yaprak Alanı İndekslerine (LAI) Dayalı Klorofil Tahmini İçin Çok Bantlı (Hiperspektral) Verilerin Kullanımı)  
**Metin Aydoğdu, Hakan Yıldız**
- 112-121 Production of WebGL Based Digital Documentation of Ponte Molino Gate From Point Cloud  
(Ponte Molino Kapısının Nokta Bulutundan WebGL Tabanlı Dijital Dokümantasyonunun Üretimi)  
**Büşranur Güvercin, Kasım Erdal, Hasan Bilgehan Makineci, Alberto Guarneri**
- 122-131 Simülasyon Modeli ile Deprem Senaryosu Oluşturulması ve Aksaray İli Triage Tahmin Analizi  
(Creating an Earthquake Scenario Using a Simulation Model and Triage Prediction Analysis for Aksaray Province)  
**Asuman Akşit, Semih Ekercin, Ümran Kaya**



## Tarımda Sulama Göletlerinin İklim Üzerine Etkilerinin Uydu Görüntüleri ve Meteorolojik Verilerle Karşılaştırmalı Olarak İncelenmesi

Abdurahman Yasin Yiğit<sup>\*1</sup>, Oğuz Şimşek<sup>2</sup>, Halil İbrahim Şenol<sup>3</sup>

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

<sup>2</sup>Harran Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Şanlıurfa, Türkiye

<sup>3</sup>Harran Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Şanlıurfa, Türkiye

### Anahtar Kelimeler:

Kuraklık  
Kuraklık Analizi  
Tarımsal Sulama Göletleri  
Arazi Sınıflandırması  
Mikro İklim Düzenlemesi

### ÖZ

Bu çalışma, Türkiye'nin Akdeniz Bölgesi'nde yer alan Mersin ili örneğinde, tarımsal sulama göletlerinin bölgesel iklim, bitki örtüsü ve su kaynakları üzerindeki uzun vadeli etkilerini uydu görüntüleri ve meteorolojik verilerle incelemektedir. Çalışmanın metodolojisi, 1985-2023 yılları arasındaki Landsat uydu verileri ile meteorolojik veri setlerinin entegrasyonuna dayanmaktadır. Arazi sınıflandırması için nesne tabanlı görüntü işleme teknikleri kullanılarak bitki örtüsünün ve su kütelerinin değişimleri haritalanmış, sınıflandırma doğruluğu hata matrisi ve farklı doğruluk metrikleriyle değerlendirilmiştir. Ayrıca, kuraklık analizinde Standartlaştırılmış Yağış İndeksi kullanılarak Mann-Kendall, Spearman Rho ve Sen Slope gibi trend analiz yöntemleriyle kuraklık eğilimleri incelenmiştir. Sonuçlar, 1985 yılında 51 olan sulama göleti sayısının 2023'te 1935'e çıktığını ve bu artışın NDVI değerlerindeki yükselişle birlikte bitki örtüsünün korunmasına katkı sağladığını ortaya koymaktadır. Kuraklık analizleri, çalışma bölgesinde kurak dönemlerin bitki örtüsüne olan olumsuz etkilerinin sulama göletleri sayesinde azaldığını göstermektedir. Özellikle mikro iklim üzerinde düzenleyici bir etkisi olan bu göletler, yarı kurak bölgelerde tarımsal üretim sürdürilebilirliği için stratejik bir su yönetimi aracı olarak değerlendirilmektedir. Bu bulgular, tarımsal sulama göletlerinin su kaynaklarının sürdürülebilir yönetimi, iklim değişikliği ile mücadele ve çevresel direnci artırma gibi konularda önemli bir potansiyele sahip olduğunu göstermektedir. Bu kapsamda, yarı kurak ve kurak bölgelerde sulama göletlerinin sayısının artırılması ve bu yapıların planlamasında iklim dostu yaklaşımlar benimsenmesi önerilmektedir.

## Comparative Investigation of the Effects of Irrigation Ponds on Climate in Agriculture Using Satellite Imagery and Meteorological Data

### Keywords:

Drought  
Drought analysis  
Agricultural irrigation ponds  
Land classification  
Microclimate regulation

### ABSTRACT

This study examines the long-term effects of agricultural irrigation ponds on regional climate, vegetation cover, and water resources in the Mersin province, located in Turkey's Mediterranean region, using satellite imagery and meteorological data. The methodology of the study is based on the integration of Landsat satellite data and meteorological datasets from 1985 to 2023. Object-based image processing techniques were employed for land classification to map changes in vegetation and water bodies, and classification accuracy was evaluated using an error matrix and various accuracy metrics. Additionally, drought trends were analyzed using the Standardized Precipitation Index and trend analysis methods such as Mann-Kendall, Spearman Rho, and Sen's Slope. The results reveal that the number of irrigation ponds increased from 51 in 1985 to 1,935 in 2023, contributing to the preservation of vegetation cover as indicated by rising NDVI values. Drought analyses indicate that the adverse effects of drought periods on vegetation cover have been mitigated by these irrigation ponds in the study region. These ponds, with their regulatory effect on the microclimate, are considered a strategic water management tool for the sustainability of agricultural production in semi-arid regions. The findings demonstrate the significant potential of agricultural irrigation ponds for sustainable water resource management, climate change mitigation, and environmental resilience. In this context, it is recommended to increase the number of irrigation ponds in semi-arid and arid regions and adopt climate-friendly approaches in the planning of these structures.

### Makale Bilgileri

Geliş : 16/09/2024  
Kabul: 28/11/2024  
Yayınlanma: 30/12/2024

### Ahırtı:

Yiğit, A. Y., Şimşek, O. & Şenol, H. İ. (2024). Tarımda Sulama Göletlerinin İklim Üzerine Etkilerinin Uydu Görüntüleri ve Meteorolojik Verilerle Karşılaştırmalı Olarak İncelenmesi. Türkiye Uzaktan Algılama Dergisi, 6 (2), 68-84.

## 1. GİRİŞ

Su, yeryüzündeki en önemli yaşam kaynaklarından biridir. Yenilenebilir bir kaynak olsa da sınırlı olması ve artan su ihtiyacı, su kaynaklarının sürdürülebilir yönetimini günümüzün en acil önceliklerinden biri haline getirmiştir (Koutsoyiannis, 2011). Bu bağlamda, tarımsal üretimde verim ve kalitenin arttırılması için hayatı önem taşıyan sulamada kullanılan suyun miktarı, zamanı ve yöntemi kadar kalitesi de büyük önem taşımaktadır (Huang vd., 2024; Malakar vd., 2019; Gürgülü ve Ul, 2024)). Kurak ve yarı kurak iklimlerde, sulama suyu temininde sıklıkla düşük kaliteli su kaynaklarının kullanımı yaygındır (Kabadayı ve Kaya, 2023). Tuzlu sular ve drenaj suları gibi bu tür su kaynakları mahsul verimini düşürmekte ve toprak ekosistemini olumsuz etkilemektedir (Adanalı, 2022; Atıcı vd., 2024). Bu durum, gıda güvenliği ve tarımsal sürdürülebilirlik açısından önemli bir tehdit oluşturmaktadır.

Su mevcudiyeti açısından, Türkiye yıllık yaklaşık 643 mm yağış almakta ve bu da yılda ortalama 501 milyar  $m^3$  suya karşılık gelmektedir (Aktaş, 2014). Bu suyun 274 milyar  $m^3$ 'ü toprak ve su yüzeyleri ile bitkilerden buharlaşma yoluyla atmosfere geri dönmekte, 69 milyar  $m^3$ 'ü yeraltı sularını beslemekte, 158 milyar  $m^3$ 'ü ise irili ufaklı akarsular vasıtıyla kapalı havzalardaki deniz ve göllere akmaktadır. Yeraltı sularını besleyen 69 milyar  $m^3$  suyun 28 milyar  $m^3$ 'ü kaynaklar vasıtıyla yüzey sularına tekrar katılmaktadır. Ayrıca, komşu ülkelerden yaklaşık 7 milyar  $m^3$ /yıl su gelmektedir. Su, yaşamın sağlıklı bir şekilde sürdürülebilmesi için insan hayatında çok önemli bir gereksinimdir.

Türkiye'nin toplam su potansiyeli zaman içinde azalmaktadır (Merdan, 2024). Suyun genel kullanım amaçları; içme ve günlük kullanım, hayvan su ihtiyacı, tarımsal sulama, balık yetiştiriciliği, endüstriyel ihtiyaçlar, rekreasyon, su taşımacılığı vb. olarak sıralanabilir. Bunlardan en önemlisi tarımsal sulamadır. Sulama, tarımsal üretimde verimi ve ürün kalitesini artırır. Tarımsal sulama göletlerinin çevresel ve iklimsel etkileri üzerine yapılan çalışmalar sınırlı kalmakta ve çoğu araştırma yalnızca sulama göletlerinin kısa vadeli tarımsal verimlilik üzerindeki etkilerine odaklanmaktadır. Ancak, bu göletlerin bögesel iklim ve bitki örtüsü üzerindeki uzun vadeli sonuçları yeterince araştırılmamıştır. Literatürde, bu kapsamda uydu görüntülerini ve meteorolojik verileri birlikte kullanarak yapılan uzun dönemli analizlerin eksikliği göze çarpmaktadır. Bu çalışma, bu eksikliği gidermeyi amaçlayarak, sulama göletlerinin iklim ve çevresel değişkenler üzerindeki uzun vadeli etkilerini çok boyutlu olarak ortaya koymaktadır.

Yeterli ve kaliteli su bulunmadığında, sulamaya uygun olmayan tuzlu sular ve drenaj suları sulama için kullanılmaktadır (Zaman vd., 2018). Sulama suyunun dinamik kullanımını, bitkinin su

tüketimine göre sulama yapılmasını gerektirmektedir. Ayrıca, suyun kit olduğu bölgelerde su tasarrufu sağlamak için aşırı su ile bitki ve toprak yapısına zarar vermemek için bitkinin su tüketimi hesaplanmalı, kontrollü ve düzenli bir şekilde su verilmelidir. Su kaynaklarının yönetimi ve kullanım alanlarının uygun şekilde belirlenmesi günümüzün en önemli sorunlarından biridir (Andriushchenko vd., 2019). Örneğin Abera vd. (2021), çalışmalarında, 1986-2016 yılları arasında Etiyopya'nın Tana Gölü Havzası'ndaki sulama genişlemesini ve su kaynaklarına olan etkilerini incelemektedir. Landsat uydu görüntüleri ve tematik haritalarla yapılan sınıflandırma, sulanan tarım arazilerinin %55'ten %65'e yükseldiğini göstermektedir. Sulama suyu tüketimi, büyük ölçüde artış göstererek 1986'da 0.380  $km^3$ 'ten 2016'da 0.798  $km^3$ 'e ulaşmıştır. Ancak mevcut su kaynakları, planlanan sulama genişlemesini destekleyemez. Bu nedenle, daha verimli sulama teknolojilerinin uygulanması ve alternatif su kaynaklarının bulunması gerekliliği vurgulanmıştır.

Özellikle tarımsal sulama ve gıda üretim faaliyetlerinin yaygınlaştırılması için çeşitli yöntemler ön plana çıkmaktadır. Ancak, kullanılan yöntemlerin bazı avantaj ve dezavantajları olduğu görülmektedir. Tarımsal sulama için yeraltı suyu kaynaklı kuyular kullanılsa da yeraltı suyunun yetersiz olduğu yerlerde farklı yöntemler geliştirilmiştir. Tarımsal sulama amacıyla çeşitli fiziksel su toplama alanları oluşturulmaktadır (Angelakis vd., 2020). Bunlardan en önemlisi, tarımsal sulama dışındaki faaliyetlerde de avantajlara sahip olan barajlardır. Barajlar tarımsal sulama, kentsel temiz su temini, enerji üretimi gibi çeşitli alanlarda kullanılabilmektedir.

Bir diğer kullanım alanı ise sulama kanallarıdır. Bu kanallar da tarımsal sulama ve kentsel temiz su temini için kullanılmakla birlikte kanal tiplerine göre dezavantajları olabilen bir su depolama ve aktarma yöntemidir. Bir diğer tarımsal su depolama yöntemi olan göletler, arazi eğimlerinden ve su toplama çizgilerinden yararlanarak arazinin şekli nedeniyle toplanan suyun tarımsal sulama amaçlı kullanılmasını sağlar. Faydalı bir yöntem olarak görülse de arazinin doğal eğiminde suyun hareketini engellediği için nehirlerin beslenmesinde sorunlara yol açabilmekte ve bunun sonucunda bazı göller kuruyabilmektedir.

Bu çalışmada inclenecek olan yağmur suyundan su depolayan tarımsal sulama göletleri, tamamen bögesel olarak tarımsal sulamaya katkı sağlamak amacıyla çiftçiler tarafından oluşturulan göletlerdir. Günümüzde iklimsel nedenlerden dolayı su kaynaklarının etkilenmesi nedeniyle bu göletlerin kullanımı artmıştır. Göletler, özellikle tarımsal sulama sağlaması ve çevresel etkileri nedeniyle önemli bir araştırma konusudur. Ayrıca, iklime bağlı parametreler ve uzaktan algılamaya dayalı bitki deseni oluşumları incelenerek bu göletlerin faydalari artırılabilir.

Kaur vd. (2024), Hindistan'ın Mahatma Gandhi National Rural Employment Guarantee Act programı kapsamında inşa edilen tarla havuzlarının tarımsal verimlilik üzerindeki etkisini incelemektedir. Sonuçlar, tarla havuzlarının özellikle muson mevsiminde ve kurak yıllarda tarımsal üretimi artırdığını ve kuraklığa karşı duyarlılığı azalttığını göstermektedir. Muson sonrası ve yaz tarım sezonlarındaki etkiler daha düşük seviyede bulunmuştur. Araştırma, tarla havuzlarına sahip ve sahip olmayan alanları karşılaştırmak için uzaktan algılama verilerini kullanarak, bu yapıların tarımsal verimlilikteki rolünü ortaya koymaktadır (Kaur vd., 2024).

Staccione vd. (2021), çalışmalarında Lamone Nehri havzasındaki doğal su tutma göletlerinin tarımsal su yönetimi üzerindeki etkilerini analiz etmektedir. Göletlerin su dengesine katkı sağlarken ekosistemi nasıl iyileştirdiğini, sulama için su teminini artırarak tarımsal üretme katkıda bulunduğunu incelemiştir. Ayrıca, iklim değişikliği senaryoları altında göletlerin hidrolojik etkileri değerlendirilmektedir. Yatırım maliyetlerinin ekonomik faydalara nasıl dengelendiği ve yenilikçi teşvik modelleriyle bu tür doğa temelli çözümlerin uygulanmasının desteklenebileceği tartılmaktadır. Sonuç olarak sulama için daha fazla su, ek tarımsal üretimi destekleyebilken, göletlerin daha ekolojik odaklı tasarımları, peyzaj ekolojik iyileştirmelerini destekleyebileceği vurgulanmıştır (Staccione vd., 2021).

Vico vd. (2020), iklim değişikliği ve düzensiz yağışların tarımsal su ihtiyacını karşılamadığı bölgelerde çiftlik göletlerinin kullanımını incelemiştir. Çiftlik göletleri, yeraltı suyunun aşırı kullanımını azaltarak sürdürülebilir bir su kaynağı sağladığı çalışmada vurgulanmıştır. Ancak, göletlerin doğru boyutlandırılması ve yönetimi kritik öneme sahiptir. Çalışmada, ortalama verim maksimize edilmesi ve minimum kabul edilebilir verimin sağlanması için çiftlik göletlerinin en uygun boyutunu belirleyen bir model geliştirilmiştir. Simülasyonlar, risk azaltma ve verim maksimize etmenin zor üzlaştığını göstermektedir (Vico vd., 2020).

Literatürde henüz çok fazla araştırmaya konu olmayan tarım göletleri veya havuzları için en kapsamlı araştırmayı ise López-Felices vd., (2020) yapmışlardır. Çalışmalarında, sulama göletlerinin tarımsal su kaynaklarının sürdürülebilirliği üzerindeki etkisini incelemekte ve son 20 yıldaki araştırma dinamiklerini değerlendirmektedir. Belirledikleri anahtar kelimelere göre sulama göletleri hakkındaki makalelerin sistematik ve bibliyometrik analiziyle, bu konuda artan bir araştırma ilgisi olduğu ortaya konulmuştur (López-Felices vd., 2020).

Araştırmalar, savunmasız bölgelerde sürdürülebilir kalkınma, tarımsal iyileştirme, çevresel etki değerlendirme ve su kaynaklarının ortak yönetimi gibi konulara odaklanmaktadır.

Ancak, sulama göletlerinin tarımda kullanım kapasitesi, çiftçilerin tutumları ve sistemlerin ekonomik fizibilitesi konusunda literatürde boşluklar tespit edilmiştir. Buna ek olarak, bu alanların hem uzaktan algılama hem de meteorolojik veriler ile karşılaşmalı analizleri içeren çalışmalarla fazla odaklanılmamıştır.

Tarımsal sulama göletlerinin iklimsel ve çevresel etkilerini Türkiye özelinde ele alan uzun dönemli çalışmaların sınırlı olması literatürde belirgin bir eksiklik olarak öne çıkmaktadır. Türkiye, su kaynaklarının giderek daha fazla baskı altında olduğu bir bölge olarak, tarımsal sulama göletlerinin etkilerinin daha kapsamlı bir analizine ihtiyaç duymaktadır.

Bu çalışmada da Türkiye'de sulama göletlerinin dağılımı ve tarımsal sürdürülebilirlik üzerindeki uzun dönemli etkilerini incelemek amacıyla Mersin ili çalışma alanı olarak belirlenmiştir. Mersin ili özelinde yapılan analizler ve Türkiye'ye odaklanan kapsamlı değerlendirmelerle, ülkenin tarımsal sürdürülebilirlik ve su yönetimi açısından karşı karşıya olduğu sorunlara yönelik özgün bir katkı sunmaktadır.

Ayrıca, bölge çalışma bölgesinde içerisinde konumlanmış meteoroloji gözlem istasyonlarında kaydedilen uzun yıllara ait yağış verileri kullanılarak bölgenin meteorolojik kuraklığını sadece yağış parametresine dayalı Standartlaştırılmış Yağış İndeksi (SYİ) yöntemiyle analiz edilmiştir. Elde edilen 12 aylık SYİ zaman serilerinde meydana gelen değişimin incelenmesi için parametrik olmayan yöntemlerden ve oldukça sık kullanılan Mann Kendall ve Spearman Rho yöntemleri kullanılmıştır (Gumus vd., 2022; Achite vd., 2023; Çelebioğlu ve Tayanç, 2024). Zaman serisinde meydana gelen değişimlerin büyüklüğünün belirlenmesinde Şen'in eğim metodundan yararlanılmıştır (Şen ve Şişman, 2024; Kartal ve Emiroğlu, 2024). Bu bölgeye ait 40 yıllık meteorolojik parametreler ve uydu verileri analiz edilmiştir.

Bölgesel iklim değişikliği ve tarımsal sulama göletlerinin inşa oranları ve dağılımları incelenmiş ve bu veriler ışığında tarımsal sulama göletlerinin su kaynaklarının sürdürülebilir yönetimi ve tarımsal üretimde su kalitesinin önemine dikkat çekilecektir. Bu araştırma, tarımsal sulama göletlerinin iklim değişkenleri üzerindeki uzun vadeli etkilerini ve tarımsal sürdürülebilirliğe katkılarını analiz ederek literatüre önemli bir katkı sağlamaktadır. Sulama göletlerinin çevresel ve iklimsel sonuçlarını daha geniş bir perspektifle değerlendiren bu çalışma, mevcut araştırmalardaki eksiklikleri giderme amacı taşımaktadır ve bu yönyle literatürdeki önemli bir boşluğu doldurmaktadır.

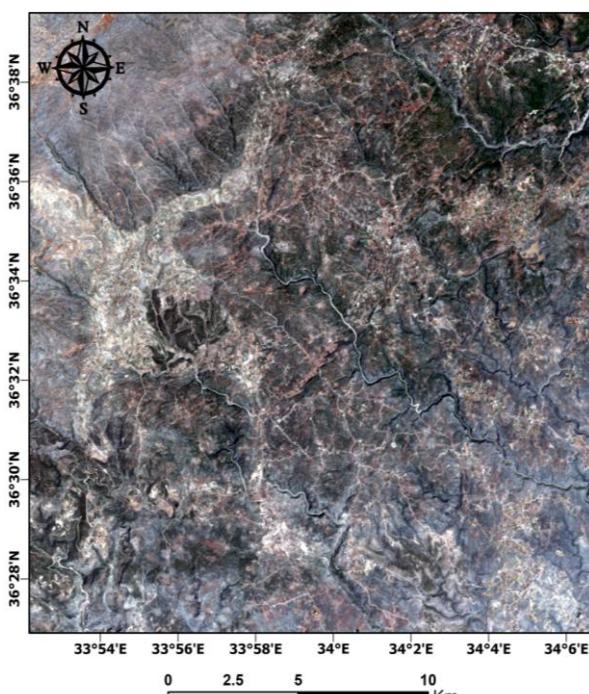
## 2. MATERİYAL ve METOT

### 2.1. Çalışma Alanı

Bu çalışma, Türkiye'nin Akdeniz Bölgesi'nde yer alan Mersin iline bağlı Silifke ilçesinde

gerçekleştirilmiştir. Çalışma alanı, yaklaşık olarak  $36^{\circ}52'50.42''K$  ve  $34^{\circ}18'36.07''D$  koordinatlarında bulunmakta ve Toros Dağları'nın güney eteklerinde yer almaktadır (Şekil 1). Bölge, tipik Akdeniz iklimi özelliklerine sahiptir; yazları sıcak ve kurak, kışları ılıman ve yağlı geçmektedir. Bölgedeki yıllık ortalama sıcaklık  $18-20^{\circ}C$  arasında değişirken, yıllık ortalama yağış miktarı  $600-700$  mm civarındadır. Ancak son yıllarda iklim değişikliğinin etkisiyle sıcaklık artışı ve düzensiz yağışlar dikkat çekmektedir.

Çalışma alanı, tarımsal üretimin yoğun olduğu bir bölgedir ve bu alanda sulama göletlerinin kullanımı yaygındır. Özellikle, kurak dönemlerde sulama göletleri bölgedeki tarımsal faaliyetlerin devamlılığı için kritik öneme sahiptir. Göletlerin oluşturulması, tarımsal sulama için sürekli bir su kaynağı sağlamak ve ürün verimliğini artırmaktadır. Bölgedeki başlıca tarımsal ürünler arasında narenciye, zeytin, domates ve diğer sebzeler bulunmaktadır. Silifke bölgesinin tarım alanlarında, su kaynaklarının sürdürülebilir kullanımı giderek önem kazanmaktadır. Bu nedenle bölge halkı kuraklığın etkisini en aza indirmek için tarım arazileri üzerine sulama göletleri inşa ederek ürünlerini sulamaya devam etmektedir. Bu da bu bölgenin seçilmesinde önemli bir faktördür. Çalışma alanı ilk olarak arazi sınıflandırmasına tabi tutulmuştur. Bu amaçla, çalışma alanı üç sınıfa (ekili alan - yeşil alan - ormanlık alan) ayrılmıştır.



Şekil 1. Çalışma Alanı

## 2.2. Veri

Bu çalışmada, tarım alanlarındaki sulama göletlerinin çevresel etkilerini analiz etmek için

uydu görüntülerini ve meteorolojik veriler bir arada kullanılmıştır. Uydu görüntülerini olarak Landsat platformu tercih edilmiştir. Landsat, 50 yılı aşkın süredir dünya genelinde çevresel değişimleri izleme amacıyla yüksek çözünürlüklü görüntüler sunan bir platformdur. Landsat 5 ve Landsat 8 uydularından elde edilen veriler, geniş zamansal kapsamı ve farklı spektral bantları sayesinde bitki örtüsünü sağlığını, arazi değişikliklerini ve su kaynaklarını analiz etmek için idealdir. Çalışmada, bu uydu verilerinin tercih edilme nedeni özellikle tarım ve çevre çalışmalarında sıkça kullanılan Normalize Edilmiş Fark Bitki Örtüsü İndeksi (Normalized Difference Vegetation Index/NDVI) gibi göstergeleri üretme ve uzun dönemli eğilimleri inceleme imkânı sunmasıdır.

Meteorolojik veriler ise çalışmanın odaklandığı bölgedeki uzun vadeli iklim değişkenlerini izlemek için kullanılmıştır. Bu veriler, sulama göletlerinin bölgesel iklim üzerindeki etkilerini değerlendirmek amacıyla elde edilmiştir ve analizlerde kullanılmak üzere ilgili istasyonlardan temin edilmiştir. Meteorolojik verilerin uzun yıllara yayılan kapsamı, çalışma alanındaki kuraklık ve yağış eğilimlerinin incelenmesine olanak tanımıştir.

Landsat Misyonu, Dünya'yı 50 yılı aşkın süredir gözlemleyen ve gezegenimizin değişimini izleyen bir uydu programıdır. ABD Jeoloji Araştırmaları Kurumu (United States Geological Survey/USGS) ve Ulusal Havacılık ve Uzay Dairesi (National Aeronautics and Space Administration/NASA) tarafından ortaklaşa yürütülen bu program, Dünya'nın en uzun süredir devam eden uydu görüntüleme programlarından biridir. Landsat uyduları, yeryüzünün her noktasını 16 günlük aralıklarla tarayarak zamansal ve mekânsal yüksek çözünürlüklü görüntüler sunar (Oğuz, 2016; Erdoğan vd., 2022). Bu görüntüler, ormancılık, tarım, jeoloji, su kaynakları ve şehir planlaması gibi çeşitli alanlarda araştırma ve uygulama için kullanılır (Roy vd., 2014; Bandyopadhyay vd., 2023). Bu platformun tercih edilmesinde; Landsat uydularının, Dünya'nın yüzeyini farklı dalga boylarında (bantlarda) algılayan çeşitli sensörler taşıması, uzun zamandır (1972'den beri veri toplamaktadır) devam eden veri setine sahip olması ve açık erişim politikası sayesinde USGS tarafından ücretsiz olarak kullanılabilir olması etken olmuştur.

Landsat platformu, şu ana kadar toplamda 9 uyduya sahiptir. Her Landsat uydusu, Dünya'nın yüzeyini farklı dalga boylarında (bantlarda) algılayan çeşitli sensörler taşır. Bu, araştırmacıların yeryüzünün farklı özelliklerini, örneğin bitki örtüsünü, toprağı ve su kütlelerini daha iyi anlamalarını sağlar. Bu çalışmada uzun yıllara ait veriler tercih edildiğinden Landsat-5 TM ve Landsat-8 uydu görüntü verileri kullanılmış olup Kırmızı-Yeşil-Mavi-NIR-SWIR bantları kullanılmıştır.

**Tablo 1.** Çalışmada kullanılan uydu verilerinin özellikleri

Platform	Tarih	Yörunge/Dizi	Bulutluluk oranı (%)
Landsat 5 TM	17.06.1985	28.06.1994	09.07.2003 176/35 0
	22.06.1986	27.06.1995	06.07.2004 176/35 0
	09.06.1987	01.06.1996	13.07.2005 176/35 0
	27.06.1988	26.06.1997	16.07.2006 176/35 0
	16.06.1989	26.07.1998	18.07.2007 176/35 0
	03.07.1990	12.07.1999	18.06.2008 176/35 0
	20.06.1991	30.07.2000	01.08.2009 176/35 0
	08.07.1992	15.06.2001	24.07.2010 176/35 0
	25.06.1993	26.06.2002	13.07.2011 176/35 0
	29.06.2013	27.06.2017	21.06.2021 176/35 0
Landsat 8 TM	19.06.2014	04.07.2018	29.06.2022 176/35 0
	13.06.2015	17.06.2019	14.07.2023 176/35 0
	04.06.2016	09.07.2020	176/35 0
Konumsal Çözünürlük (m)		Spektral Çözünürlük (μm)	
Kırmızı - Yeşil - Mavi - Yakın Kızılılolesi		Kırmızı	Yeşil
Landsat 5 TM	30	0.63-0.69	0.52-0.6
Landsat 8 TM	30	0.63 - 0.67	0.53 - 0.59
		0.45-052	0.45 - 0.51
		0.76-0.9	0.85 - 0.88

Çalışma kapsamında iklim değişikliğinin ve tarımsal sulamanın etkileri araştırıldığı için nispeten bulutluluğun az olduğu Haziran-Temmuz ayları arasına ait veriler kullanılmıştır. Bulut etkisinden kaçınmak için çalışma tarihi geniş tutulmuştur. Çalışmada kullanılan verilere ait bilgiler Tablo 1'de aktarılmıştır.

Uzaktan algılamada doğru sınıflandırılmış bir sonuç elde etmek büyük önem taşımaktadır. Bu doğruluklar sınıflandırıcı seçimi, eğitim verisinin kalitesi, veri heterojenliği, veri seti ve referans haritalar vb. gibi çeşitli faktörlerden etkilenmektedir. Sınıflandırma yöntemi olarak, uydu görüntülerini önce nesne tabanlı bir sınıflandırma algoritması kullanılarak segmentlere ve daha sonra indeks kullanılarak sınıflara ayrılmıştır.

### 2.3. Sınıflandırma

Detay çıkarma ve sınıflandırma çalışmaları için literatürde birçok yöntem bulunmaktadır (Blaschke vd., 2014; Ma vd., 2017; Luo vd., 2020). Sınıflandırma çalışmaları genellikle piksel tabanlı ve obje tabanlı olmak üzere iki ana yaklaşımı ayırmaktadır. Piksel tabanlı sınıflandırma, her bir pikselin spektral özelliklerine dayalı olarak sınıflandırılmasıdır (Guan vd., 2014; Senthilkumaran & Vaithogi, 2016). Bu yöntem, daha basit bir yaklaşım sunar (Gupta & Bhaduria, 2014; Tehrany vd., 2014; Khatami vd., 2016). Objeye tabanlı sınıflandırma ise, görüntüdeki homojen objeleri veya segmentleri tanımlayarak sınıflandırır ve piksel seviyesinden daha yüksek doğrulukla arazi örtüsü sınıflarını temsil eder (Wei vd., 2005; Gupta & Bhaduria, 2014; Ozturk & Cölkesen, 2024).

Bu çalışmada obje tabanlı sınıflandırmanın ilk aşaması olan segmentasyon işlemi, eCognition Developer yazılımı ile gerçekleştirilmiştir. eCognition yazılımı, uydu görüntülerini ve hava

fotoğrafları gibi yüksek çözünürlüklü verilerin analizinde güçlü ve esnek bir araçtır (Hossain vd., 2016; Hossain & Chen, 2019). Objeye tabanlı görüntü analizi yaklaşımını kullanan bu yazılım, çok çözünürlüklü segmentasyon algoritması ile görüntüyü homojen segmentlere ayırarak, analiz edilen nesnelerin daha anlamlı sınıflar oluşturmasını sağlar (Baatz, 2000; Definiens, 2012). Bu sayede, yalnızca piksel değeri değil, aynı zamanda nesnelerin geometrik ve yapısal özelliklerine göre de sınıflandırma yapılmaktadır; bu da daha yüksek doğruluk oranları elde edilmesine yardımcı olur (Bergsjö, 2014). Ayrıca, eCognition yazılımının esnek ve kullanıcı dostu arayüzü, analistlerin segmentasyon ve sınıflandırma parametrelerini kolayca ayarlamasına olanak tanıyarak analiz sürecini hızlandırır. Yazılımın çok katmanlı veri entegrasyonunu desteklemesi sayesinde multispektral, hiperspektral ve diğer veri türleri aynı anda analiz edilebilir, bu da sınıflandırma doğruluğunu artırır (Carleer & Wolff, 2006; Blaschke vd., 2011). eCognition ayrıca, modüler yapı ve otomasyon seçenekleri ile büyük veri setlerinde zamanlı tasarruf sağlar ve kullanıcıların tekrarlayan işlemleri otomatikleştirmesine imkân tanır. Destek Vektör Makineleri, Rastgele Orman ve Karar Ağacıları gibi çeşitli sınıflandırma algoritmalarını desteklemesi sayesinde, projeye en uygun algoritmanın seçilmesine olanak tanıyan bu yazılım, uydu görüntülerinde detaylı analiz yapmak isteyen araştırmacılar için ideal bir seçenek sunar.

Segmentasyon işleminde ölçek, şekil ve kompaktlık gibi parametreler kullanılarak görüntü farklı alt bölgelere ayrılmıştır. Bu çalışmada ölçek parametresi görsel olarak değerlendirilerek 10 olarak belirlenmiş, şekil ve kompaktlık parametreleri ise 0.5 olarak uygulanmıştır (Benz vd., 2004).

Segmentasyon işlemi tamamlandıktan sonra, segmentlerin homojenliği ve boyutları görsel olarak incelenmiş ve her segmentin çeşitli spektral, tekstürel ve şekil özellikleri araştırılmıştır. Bu özellikler arasında ortalama yansımaları, NDVI, şekil metrikleri (kompaktlık, uzunluk-genişlik oranı vb.) ve tekstürel metrikler bulunmaktadır. Sınıflandırma aşamasında kullanılan eğitim veri seti, ekili alan - yeşil alan - ormanlık alan olarak ayrılmıştır. Sınıflara ait örnek segmentlerden manuel olarak etiketlenmiştir.

Çalışmamızda kullanılan sınıflandırma algoritmaları literatürde ayrıntılı şekilde değerlendirilmiş olup, çeşitli sınıflandırma teknikleri dikkate alınmıştır. Rastgele Orman algoritması genellikle yüksek doğruluk oranları sağlarken, karar ağaçları basit veri kümelerinde daha hızlı sonuçlar sunar. Ancak, karar ağaçları aşırı öğrenmeye yatkındır. K-En Yakın Komşu ve Naive Bayes gibi algoritmalar ise daha küçük veri kümeleri ve bağımsız özellikler varsayımlı altında iyi sonuç verir. Bu çalışmanın amacı ve veri yapısı göz önünde bulundurulduğunda, ekili alan - yeşil alan - ormanlık alan olarak ayrılmıştır. Sınıfları ayırt etme kabiliyeti nedeniyle Destek Vektör Makineleri tercih edilmiştir. Destek Vektör Makineleri algoritması, özellikle az sayıda ve spektral olarak benzer sınıfların ayrımında yüksek doğruluk sağlaması nedeniyle bu çalışmada etkili bir çözüm sunmaktadır.

Görüntü sınıflandırma işlemi tamamlandıktan sonra, elde edilen sonuçların doğruluğunu değerlendirmek önemlidir. Doğruluk analizi yapmak, sınıflandırma sonuçlarının ne kadar doğru olduğunu değerlendirmek için kritik bir adımdır. Doğruluk analizi, sınıflandırılmış verilerin, bilinen doğrulukta referans veri seti ile karşılaştırılması ile gerçekleştirilir. Doğruluk analizinde kullanılan 195 nokta, çalışma alanının büyütülüğü ve sınıflandırmanın doğruluğunu sağlamak amacıyla her bir sınıfa yeterli sayıda nokta düşecek şekilde orantılı olarak belirlenmiştir. Bu örnekleme yöntemi, her sınıfın doğruluk değerlendirmesini desteklemek amacıyla yapılmıştır ve üç sınıfın her birine dengeli şekilde dağıtılmıştır.

Doğruluk analizinde, sınıflandırma modelinin performansını değerlendirmek amacıyla hata matrisi kullanılmıştır. Hata matrisi, sınıflandırılan her bir sınıfın doğru ve yanlış sınıflandırma durumlarını ayrıntılı bir şekilde gösterir. Çalışmamızda üç sınıfın doğruluk değerlendirmesi yapılmıştır. Sınıflandırma sonuçlarının doğruluğunu kontrol etmek için bilinen sınıflara ait referans alanları seçilmiştir. Bu alanlar, her sınıf için temsil edici ve belirgin net olan alanlardır. Daha sonra doğrulama alanlarını temsil eden bir katman oluşturulmuş ve bu katmanda her sınıfa ait örnek alanlar (poligonlar veya noktalar) manuel olarak etiketlenmiştir. Hata matrisi, sınıflandırma sonuçları ile doğrulama veri seti arasındaki doğruluğu karşılaştırmak için kullanılan bir tablodur. eCognition, hata matrisi oluşturmak için yerleşik

araçlar sağlar. Hata matrisi ayrıca dolaylı olarak yanlış sınıflandırma oranlarını gösteren bir tablodur. Her bir referans sınıfı için yanlış sınıflandırma sayısını ve yanlış sınıflandırılan nesnelerin hangi sınıflara atadığını gösterir ve her bir sınıfın hangi diğer sınıflara karıştırıldığını belirlemeyi sağlar.

Hata matrisi kullanılarak çeşitli doğruluk metrikleri hesaplanabilir. Doğruluk analizi metrikleri, sınıflandırma sonuçlarının performansını değerlendirmek için kullanılan temel ölçütlerdir. Çalışmada; Genel doğruluk, Kesinlik, Geri Çağırma ve Belirlilik metrikleriyle birlikte F1 skoru hesaplanmıştır ve sırasıyla Denklem 1-5'te sunulmuştur.

**Genel Doğruluk:** Hata matrisinde doğru sınıflandırılan tüm örneklerin toplamının, tüm örneklerin toplamına oranlanmasıyla elde edilen bu metrik, sınıflandırma modelinin genel başarısını yansıtır. Çalışmamızda elde edilen genel doğruluk değeri, sınıflandırma işleminin genel olarak başarılı olduğunu göstermektedir.

$$\text{Genel Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

**Kesinlik:** Modelin, belirli bir sınıfta pozitif olarak sınıflandırıldığı örneklerin gerçekte de o sınıfta ait olma oranını gösterir. Bu, yanlış pozitifleri azaltmak için önemli bir metriktir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

**Belirlilik:** Modelin negatif sınıfları doğru bir şekilde ayırt etme başarısını yansıtır. Diğer bir deyişle, belirli bir sınıfta ait olmayan örnekleri doğru şekilde sınıflandırma oranını ifade eder.

$$\text{Belirlilik} = \frac{TN}{TN + FP} \quad (3)$$

**F1 Skoru:** Hassasiyet ve belirliliğin bir kombinasyonudur ve her iki metriğin de dengesini sağlayarak modelin genel performansını değerlendirdir. F1 skoru, kesinlik ve geri çağrımanın harmonik ortalaması olarak elde edilmiştir. Çalışma boyunca mikro veya makro modda hesaplama yapılmadığı için bireysel kesinlik ve geri çağrıma değerleri üzerinden elde edilmiştir.

$$F1score = \frac{2 \times \text{Kesinlik} \times \text{Geri Çağırma}}{\text{Kesinlik} + \text{Geri Çağırma}} \quad (4)$$

**Geri Çağırma:** Pozitif sınıf örneklerinin ne kadarının doğru sınıflandırıldığını gösteren bu metrik, özellikle eksik sınıflandırmaları azaltmak için önemlidir.

$$\text{Geri Çağırma} = \frac{TP}{TP + FN} \quad (5)$$

Bu denklemlerde:

TP: Doğru Pozitif (Doğru sınıflandırılan örneklerin sayısı)

TN: Doğru Negatif (Yanlış sınıflandırılmayan örneklerin sayısı)

FP: Yanlış Pozitif (Yanlışlıkla pozitif olarak sınıflandırılan örneklerin sayısı)

FN: Yanlış Negatif (Yanlışlıkla negatif olarak sınıflandırılan örneklerin sayısı) (Yiğit vd., 2022; Orhan vd., 2022)

Bu metriklerin sınıflandırma doğruluğu üzerindeki etkileri, modelin ekili alan - yeşil alan - ormanlık alan olarak ayrılmıştır ve sınıfları ayırt etmedeki başarısını farklı açılarından değerlendirmemize olanak tanımaktadır.

#### 2.4. Standartlaştırılmış Yağış İndeksi ve Kuraklık Trend Analizi

Standartlaştırılmış Yağış İndeksi (SYİ), sadece yağış verilerine dayalı bir yöntem olup bu özelliğinden dolayı oldukça sık tercih edilen bir yöntemdir (Şimşek vd., 2024a; Simsek vd., 2024b). Bu yöntem uygulanmadan önce yağış verileri bir dağılıma uydurulur ve normalize edilir. Daha sonra yeni oluşturulan veri setine bu yöntem uygulanarak kuraklık indis değeri elde edilir. İndis değeri, herhangi bir zaman ölçüğündeki yağış değerinin uzun yıllara ait ortalamadan farkının, uzun yıllar veri setine ait standart sapma değerine bölünmesiyle elde edilir. İndis değerinin negatif olması kurak, pozitif olması ise yağışlı olarak tanımlanır (Keskiner ve Simsek, 2023; Simsek vd., 2024a).

Bu kuraklık analiz yönteminde indis değerlerinin şiddetine göre sınıflandırılması ve indis değerlerinin aralıkları Tablo 2'de verilmiştir. Araştırma bölgesinde Tablo 3'te verilen istasyonların 1985 ile 2022 yılları arasındaki 38 aylık ortalama yağış verileri kullanılarak bölgenin kuraklık analizi gerçekleştirılmıştır. SYİ yöntemiyle ele alınan istasyonlarda 12 aylık zaman ölçüğünde indis değerleri hesaplanmış ve meydana gelen lineer trendler ve Mann-Kendall ve Spearman Rho yöntemiyle elde edilen monotonik trend durumu değerlendirilmiştir.

Herhangi bir zaman serisinde meydana gelen değişimin belirlenmesi için oldukça sık kullanılan Mann kendall ve Sperman Rho yöntemleri parametrik olmayan yöntemlerdir (Keskiner ve Simsek, 2024). Zaman serisinde meydana gelen değişimin belirlenmesinde kullanılan bu yöntemler non parametrik yöntemlerdir. Test istatistiği ( $Z$ ) değerinin pozitif olması zaman serisinde artış trendini, negatif olması ise zaman serisinde azalış trendini ifade etmektedir.  $Z$  test istatistik değerinin belirlenen güven aralığı değerinden büyük olması durumunda bu zaman serisinde istatiksel olarak anlamlı trend varlığından bahsetmek mümkündür. Bu çalışmada, güven aralığı %95 olarak belirlenmiş

ve bu güven aralığı için  $Z$  değeri  $\pm 1.96$ 'dır. SYİ yöntemiyle ele alınan istasyonlarda 12 aylık zaman ölçüğünde indis değerleri hesaplanmış ve elde edilen SYİ zaman serilerine Mann-Kendall ve Spearman Rho yöntemiyle elde edilen monotonik trend durumu değerlendirilmiştir. Ayrıca, meteorolojik kuraklığa ait SYİ zaman serilerinde meydana gelen değişimin büyülüğünün belirlenmesinde Sen Slope yöntemi yaygın olarak kullanılan yöntemler arasındadır (Gumus vd., 2023). Sen slope değerinin negatif olması zaman serinde azalı, pozitif olması ise zaman serisinde artışı temsil etmektedir. Değerin büyük olması artış veya azalın daha hızlı olacağını anlamına gelmektedir.

**Tablo 2.** SYİ yöntemine ait kuraklık sınıfları ve indis değerleri aralığı

Kuraklık Sınıfı	İndis değeri aralığı
Aşırı Kurak	SYİ < -2.00
Çok Kurak	-2.00 ≤ SYİ < -1.50
Orta Kurak	-1.50 ≤ SYİ < -1.00
Hafif Kurak	-1.00 ≤ SYİ < 0
Hafif Yağışlı	0 < SYİ ≤ 1.00
Orta Yağışlı	1.00 < SYİ ≤ 1.50
Çok Yağışlı	1.50 < SYİ ≤ 2.00
Aşırı Yağışlı	SYİ > 2.00

**Tablo 3.** Meteorolojik istasyon bilgileri

Istasyon Adı	Istasyon No	Enlem	Boylam
Anamur	17320	36.0686	32.8649
Erdemli	17958	36.6268	34.3380
Silifke	17330	36.3824	33.9373
Mut	17956	36.6514	33.4339

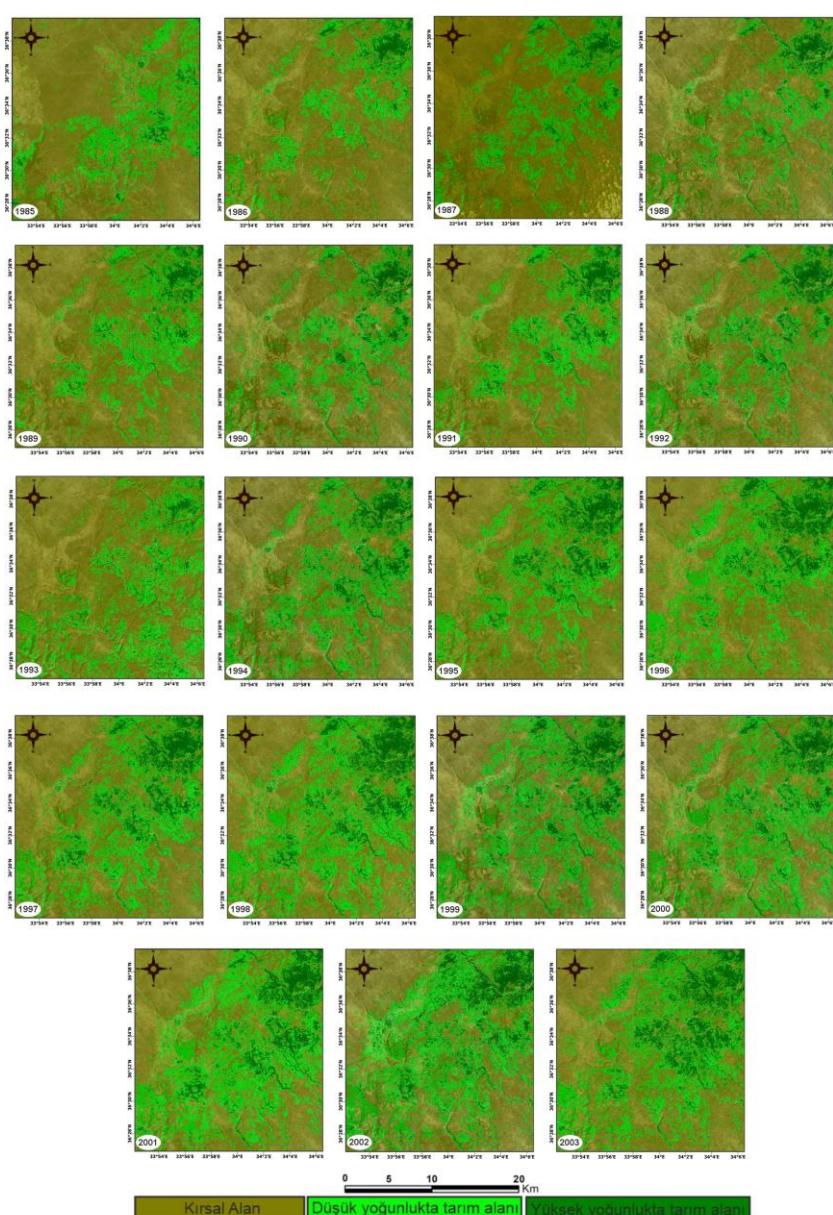
### 3. BULGULAR

Tarım alanları, her zaman iklim, çevresel ve kentsel gelişim gibi uzun ve kısa vadeli değişiklikler tarafından çeşitli etkilerin tesirinde kalmıştır. Tarım alanlarında sürdürülebilir kalkınma ve çevrenin korunması için bitki deseni değişiminin sürekli olarak izlenmesi gerekmektedir. Geleneksel olarak, arazi sınıflandırılması ve tarimsal alanlardaki değişiklikleri tespit etmek için yerinde saha araştırmaları kullanılmıştır. Ancak, bu geleneksel yöntemle değişikliklerinin kapsamlı ve uzun vadeli izlenmesi maliyetli ve zaman alıcıdır. Bu bağlamda, uzaktan algılama verileri yer gözlem çalışmaları için en uygun çözümü oluşturmaktak ve zamansal çözünürlük, çok bantlı algılama ve göreceli maliyet kabiliyetleri nedeniyle yaygın olarak kullanılmaktadır. Tarimsal alanlardaki değişiklikleri tespit etmek için verilerin hassas bir biçimde analiz edilmesi ve bunların haritalarının üretilmesi gereklidir. Uzaktan algılama teknikleri ile belirlenen araziler daha sonra coğrafi bilgi sistemleri ortamında analiz edilerek yıllar arasındaki değişim analiz edilebilir. Bu amaçla, öncelikle çalışma alanının Landsat görüntüleri kullanılarak obje tabanlı sınıflandırma yöntemiyle arazi sınıflandırılması tanımlaması yapılmıştır. Ardından, kullanılan sınıflandırma yönteminin doğruluk analizi yapılmış ve belirlenen sınıfların doğrulukları

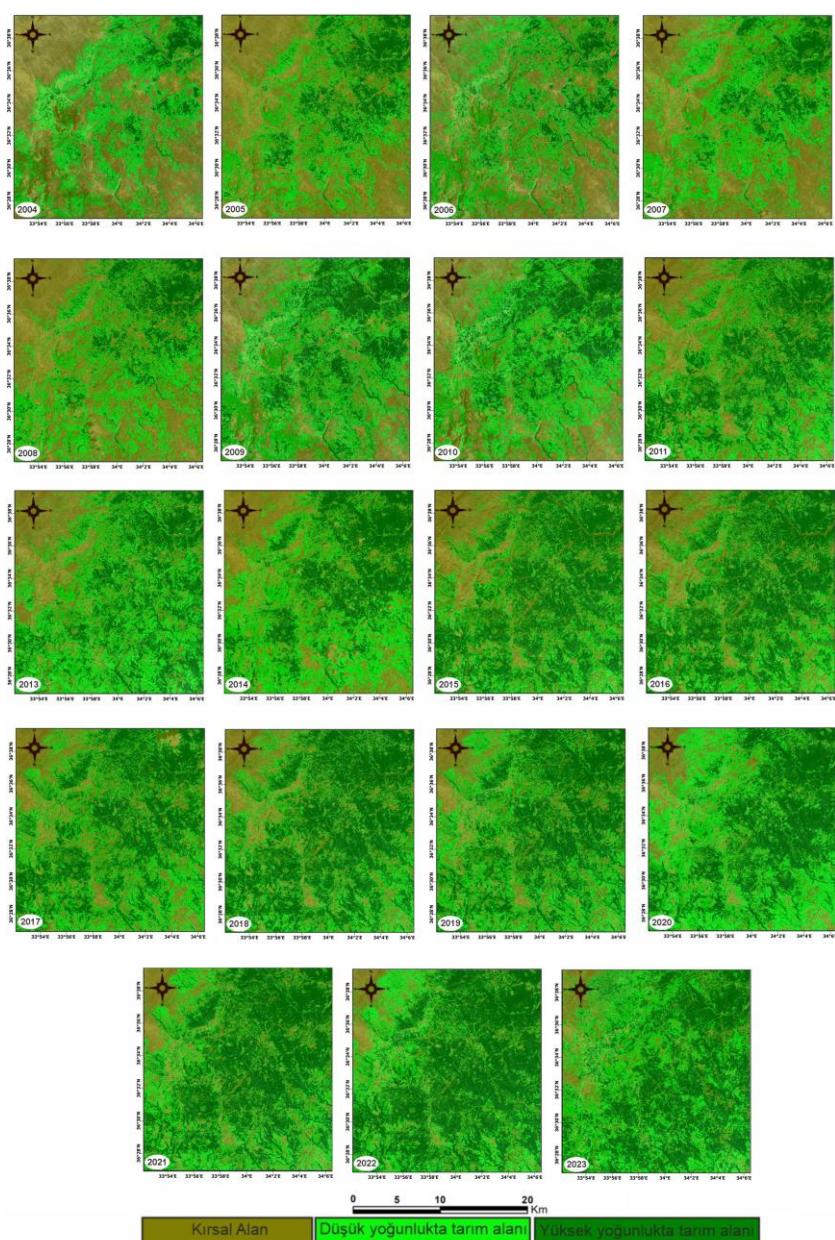
incelemiştir. Son olarak incelenen alanın bölgdedeki istasyonlardan alınan meteorolojik veriler kullanılarak çeşitli kuraklık analizleri gerçekleştirilmiştir. Bu analizler sayesinde, tarım alanlarındaki değişikliklerin nedenleri ve etkileri daha iyi anlaşılır ve gelecekteki sürdürülebilir tarım uygulamaları için önemli veriler elde edilebilir.

Şekil 2 ve 3'te çalışma alanının yillara göre sınıflandırılması verilmiş ve incelendiğinde, 1985 ile 2023 yılları arasında ekili arazilerin giderek azlığı, yeşil alan ve ormanlık alanların ise arttığı görülmektedir. Artan alanların çoğu orman alanları olsa da yeşil alanlarında da artış görülmüştür ancak kullanım alanları azalmıştır. Diğer bir deyişle, tarım arazilerinin miktarı artmasına rağmen kullanılan alanlar parçalanmıştır. Nüfus, iklim koşulları ve kentleşmenin bu anlamda etkisi fark edilmektedir. Ayrıca büyük tarım alanlarını sulamak zor

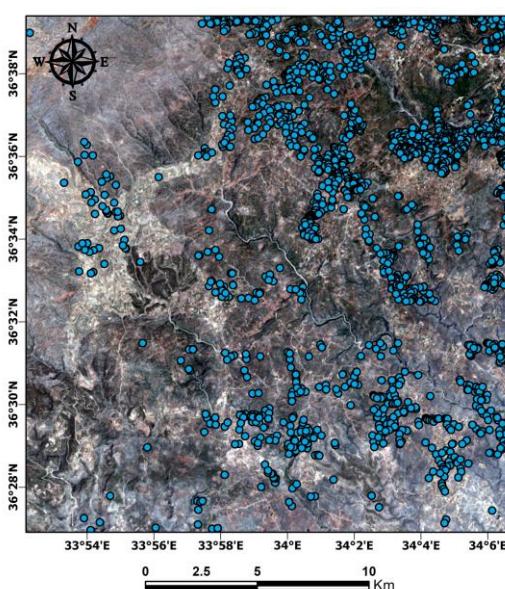
olduğundan küçük tarım alanları kullanılmaya devam etmektedir (Şahin & Kahraman, 2021). Sınıflandırma sonucunda bölgeden elde edilen NDVI indeks değerlerinde de bir artış gözlenmektedir. Bu artış kuraklık sonrasında da devam etmektedir. Bunun temel nedeni bölgede bulunan özel tarımsal sulama göletleridir. Şekil 4'te yillara göre uydu görüntülerinden görsel inceleme sonucu tespit edilen sulama havuzlarının güncel sayı ve konumları gösterilmektedir. Güncel olarak 2023 yılında çalışma alanında 1935 adet sulama havuzu bulunmaktadır. Bölgede inceleme gerçekleştiren resmi kurumlardan ve uydu görüntülerinden tespit edilen 1985 yılında ise 51 sulama havuzu bulunmaktadır. Yine aynı şekilde 1990, 2000, 2010, 2015, 2020 yıllarında ise sırasıyla 112, 363, 718, 1227, 1782 adet sulama havuzu bulunmaktadır.



**Şekil 2.** Arazi sınıflandırması (1985-2003)



Şekil 3. Arazi sınıflandırması (2004-2023)



Şekil 4. Çalışma alanındaki sulama havuzlarının konumu

### 3.1. Doğruluk Analizi

Doğruluk analizi, uydu görüntüsü sınıflandırmasında sınıflandırmanın doğruluğunu ve sonuç ürünün güvenilirliğini belirlemek için kritik bir araçtır. Bu analiz, sınıflandırılan alanların doğru kullanımını ve değerlendirmesini sağlamada önemli bir rol oynar. Modellerin performansını çeşitli metriklerle değerlendiren bu doğruluk analizleri, modellerin doğruluğunu ve güvenilirliğini belirlemeye yol gösterici olur.

Bu çalışmada, sınıflandırma modelinin performansını ölçmek amacıyla Hata Matrisi

kullanılmıştır. Hata Matrisi, her bir referans sınıfı için doğru ve yanlış sınıflandırılmış nesne sayısını göstererek modelin sınıflandırma yeteneğini ayrıntılı bir şekilde ortaya koyar. Bu matris temel alınarak elde edilen doğruluk metrikleri, sınıfların ne kadar doğru bir şekilde sınıflandırıldığını ve modelin genel başarısını değerlendirmek için kullanılmıştır. Çalışmada kullanılan doğruluk analizi kapsamında, Genel Doğruluk, Kesinlik, Belirlilik, F1 Skoru ve Geri Çağırma gibi metrikler hesaplanmıştır. Bu metrikler, modelin hem genel performansını hem de sınıflar düzeyinde başarayı detaylı bir şekilde analiz etme imkânı sunmuştur.

**Tablo 4.** Arazi sınıflandırmasındaki her sınıfa ait 1985-2003 yılları doğruluk değerleri

Yıl	Sınıf	Genel Doğruluk	Kesinlik	Belirlilik	F1 Score	Geri Çağırma
1985	Ekili Alan	0.88	0.92	0.93	0.87	0.91
	Yeşil Alan	0.93	0.83	0.85	0.92	0.88
	Ormanlık Alan	0.85	0.86	0.86	0.83	0.89
1986	Ekili Alan	0.90	0.86	0.91	0.82	0.82
	Yeşil Alan	0.90	0.89	0.89	0.87	0.85
	Ormanlık Alan	0.83	0.84	0.84	0.89	0.85
1987	Ekili Alan	0.89	0.92	0.84	0.91	0.92
	Yeşil Alan	0.86	0.83	0.82	0.93	0.87
	Ormanlık Alan	0.85	0.83	0.83	0.94	0.84
1988	Ekili Alan	0.88	0.89	0.84	0.82	0.92
	Yeşil Alan	0.87	0.92	0.87	0.88	0.86
	Ormanlık Alan	0.83	0.93	0.82	0.94	0.83
1989	Ekili Alan	0.87	0.92	0.88	0.88	0.85
	Yeşil Alan	0.90	0.91	0.94	0.92	0.84
	Ormanlık Alan	0.85	0.91	0.92	0.86	0.89
1990	Ekili Alan	0.89	0.9	0.81	0.85	0.86
	Yeşil Alan	0.82	0.88	0.92	0.93	0.88
	Ormanlık Alan	0.86	0.87	0.81	0.83	0.93
1991	Ekili Alan	0.87	0.88	0.84	0.89	0.86
	Yeşil Alan	0.90	0.86	0.85	0.92	0.85
	Ormanlık Alan	0.82	0.84	0.91	0.89	0.91
1992	Ekili Alan	0.93	0.88	0.87	0.93	0.91
	Yeşil Alan	0.88	0.82	0.94	0.83	0.86
	Ormanlık Alan	0.87	0.84	0.83	0.87	0.93
1993	Ekili Alan	0.94	0.93	0.86	0.89	0.84
	Yeşil Alan	0.84	0.88	0.84	0.89	0.88
	Ormanlık Alan	0.88	0.82	0.82	0.94	0.81
1994	Ekili Alan	0.86	0.89	0.87	0.81	0.83
	Yeşil Alan	0.83	0.87	0.93	0.86	0.91
	Ormanlık Alan	0.84	0.87	0.82	0.82	0.89
1995	Ekili Alan	0.91	0.87	0.85	0.87	0.87
	Yeşil Alan	0.85	0.86	0.93	0.82	0.85
	Ormanlık Alan	0.88	0.85	0.93	0.91	0.89
1996	Ekili Alan	0.88	0.89	0.89	0.88	0.85
	Yeşil Alan	0.86	0.92	0.91	0.87	0.93
	Ormanlık Alan	0.82	0.87	0.84	0.85	0.89
1997	Ekili Alan	0.88	0.81	0.92	0.88	0.92
	Yeşil Alan	0.88	0.94	0.89	0.84	0.92
	Ormanlık Alan	0.88	0.86	0.86	0.84	0.94
1998	Ekili Alan	0.93	0.85	0.83	0.94	0.84
	Yeşil Alan	0.87	0.92	0.92	0.92	0.82
	Ormanlık Alan	0.93	0.83	0.88	0.91	0.81
1999	Ekili Alan	0.82	0.82	0.88	0.85	0.88
	Yeşil Alan	0.94	0.81	0.85	0.81	0.84
	Ormanlık Alan	0.85	0.81	0.92	0.84	0.94
2000	Ekili Alan	0.82	0.85	0.83	0.83	0.93
	Yeşil Alan	0.82	0.86	0.92	0.93	0.87
	Ormanlık Alan	0.88	0.82	0.91	0.91	0.92
2001	Ekili Alan	0.81	0.89	0.88	0.86	0.89
	Yeşil Alan	0.84	0.88	0.89	0.86	0.82
	Ormanlık Alan	0.83	0.87	0.85	0.88	0.88
2002	Ekili Alan	0.92	0.87	0.86	0.93	0.92
	Yeşil Alan	0.83	0.83	0.81	0.86	0.86
	Ormanlık Alan	0.91	0.87	0.83	0.87	0.85
2003	Ekili Alan	0.93	0.83	0.88	0.83	0.93
	Yeşil Alan	0.89	0.88	0.86	0.81	0.91
	Ormanlık Alan	0.85	0.88	0.82	0.88	0.91

**Tablo 5.** Arazi sınıflandırmasındaki her sınıfın 2004-2023 yılları doğruluk değerleri

Yıl	Sınıf	Genel Doğruluk	Kesinlik	Belirlilik	F1 Score	Geri Çağırma
2004	Ekili Alan	0.92	0.85	0.83	0.93	0.91
	Yeşil Alan	0.84	0.82	0.83	0.83	0.90
	Ormanlık Alan	0.83	0.93	0.85	0.85	0.82
2005	Ekili Alan	0.94	0.88	0.83	0.88	0.90
	Yeşil Alan	0.87	0.84	0.94	0.86	0.89
	Ormanlık Alan	0.89	0.94	0.84	0.9	0.87
2006	Ekili Alan	0.91	0.89	0.87	0.87	0.94
	Yeşil Alan	0.84	0.81	0.87	0.93	0.91
	Ormanlık Alan	0.81	0.84	0.87	0.86	0.88
2007	Ekili Alan	0.87	0.88	0.86	0.92	0.94
	Yeşil Alan	0.83	0.91	0.87	0.82	0.84
	Ormanlık Alan	0.92	0.92	0.85	0.86	0.91
2008	Ekili Alan	0.91	0.89	0.93	0.87	0.87
	Yeşil Alan	0.82	0.84	0.89	0.93	0.85
	Ormanlık Alan	0.81	0.84	0.88	0.92	0.82
2009	Ekili Alan	0.83	0.89	0.91	0.92	0.82
	Yeşil Alan	0.88	0.85	0.86	0.92	0.87
	Ormanlık Alan	0.9	0.81	0.85	0.93	0.84
2010	Ekili Alan	0.89	0.87	0.91	0.86	0.85
	Yeşil Alan	0.83	0.93	0.83	0.87	0.92
	Ormanlık Alan	0.85	0.91	0.86	0.82	0.86
2011	Ekili Alan	0.83	0.93	0.93	0.93	0.83
	Yeşil Alan	0.84	0.92	0.92	0.85	0.88
	Ormanlık Alan	0.91	0.85	0.83	0.84	0.89
2013	Ekili Alan	0.93	0.86	0.82	0.91	0.86
	Yeşil Alan	0.86	0.81	0.83	0.84	0.85
	Ormanlık Alan	0.94	0.86	0.91	0.86	0.93
2014	Ekili Alan	0.88	0.87	0.88	0.92	0.83
	Yeşil Alan	0.92	0.83	0.88	0.89	0.81
	Ormanlık Alan	0.84	0.89	0.82	0.92	0.89
2015	Ekili Alan	0.86	0.93	0.89	0.85	0.89
	Yeşil Alan	0.82	0.89	0.84	0.81	0.88
	Ormanlık Alan	0.88	0.92	0.9	0.94	0.83
2016	Ekili Alan	0.84	0.91	0.94	0.91	0.86
	Yeşil Alan	0.92	0.89	0.82	0.81	0.81
	Ormanlık Alan	0.89	0.89	0.91	0.94	0.94
2017	Ekili Alan	0.91	0.91	0.85	0.89	0.93
	Yeşil Alan	0.82	0.84	0.92	0.87	0.86
	Ormanlık Alan	0.88	0.92	0.91	0.93	0.92
2018	Ekili Alan	0.87	0.82	0.84	0.84	0.94
	Yeşil Alan	0.94	0.93	0.94	0.82	0.88
	Ormanlık Alan	0.84	0.85	0.84	0.85	0.88
2019	Ekili Alan	0.88	0.93	0.82	0.83	0.88
	Yeşil Alan	0.87	0.89	0.93	0.84	0.93
	Ormanlık Alan	0.93	0.91	0.86	0.94	0.93
2020	Ekili Alan	0.81	0.92	0.81	0.91	0.85
	Yeşil Alan	0.94	0.88	0.93	0.84	0.82
	Ormanlık Alan	0.87	0.83	0.89	0.84	0.88
2021	Ekili Alan	0.89	0.94	0.93	0.93	0.89
	Yeşil Alan	0.89	0.89	0.91	0.84	0.86
	Ormanlık Alan	0.92	0.93	0.85	0.82	0.93
2022	Ekili Alan	0.89	0.83	0.93	0.87	0.93
	Yeşil Alan	0.91	0.94	0.85	0.83	0.81
	Ormanlık Alan	0.86	0.91	0.86	0.93	0.92
2023	Ekili Alan	0.89	0.92	0.91	0.89	0.86
	Yeşil Alan	0.82	0.85	0.82	0.81	0.85
	Ormanlık Alan	0.85	0.84	0.84	0.84	0.94

Sonuç olarak, Tablo 4 ve 5'te sunulan doğruluk analizi sonuçları, sınıflandırılan her bir sınıfın yüksek doğruluk oranlarına sahip olduğunu ortaya koymaktadır. Bu durum, modelin uydu görüntüsü sınıflandırmasında başarılı bir performans sergilediğini ve sınıfların doğru bir şekilde sınıflandırıldığını göstermektedir.

1985-2023 yılları arasında yapılan arazi sınıflandırması çalışmasında elde edilen doğruluk analizleri, sınıflandırmanın yüksek güvenilirlik düzeyinde gerçekleştirildiğini göstermektedir. Tüm

yıllar boyunca genel doğruluk değerlerinin %81 ile %94 arasında değiştiği, çoğunlukla %88 ve üzerinde kaldığı gözlemlenmiştir. Bu durum, sınıflandırma işleminin uzun vadede tutarlı sonuçlar sunduğunu göstermektedir.

Sınıflar bazında yapılan değerlendirmede, ekili alan genellikle en tutarlı doğruluk oranlarına sahip olup %85 ile %94 arasında değişen bir doğruluğa sahiptir ve yıllar boyunca göreceli olarak daha az dalgalanma göstermiştir. Yeşil alan ise doğruluk açısından hafif iniş çıkışlar sergilese de genel olarak

%82 ile %94 arasında değerler almış ve özellikle 2000'li yılların ortalarından itibaren doğruluğunda belirgin bir iyileşme gözlemlenmiştir. Ormanlık alan dönemsel olarak daha fazla dalgalanma görülmüş olup doğruluk oranları bazı yıllarda %82 seviyesine kadar düşerken, diğer yıllarda %93 seviyelerine ulaşmıştır. Bu durum, sınıflandırma performansının bazı yıllarda ormanlık alan daha değişken olduğunu ortaya koymaktadır.

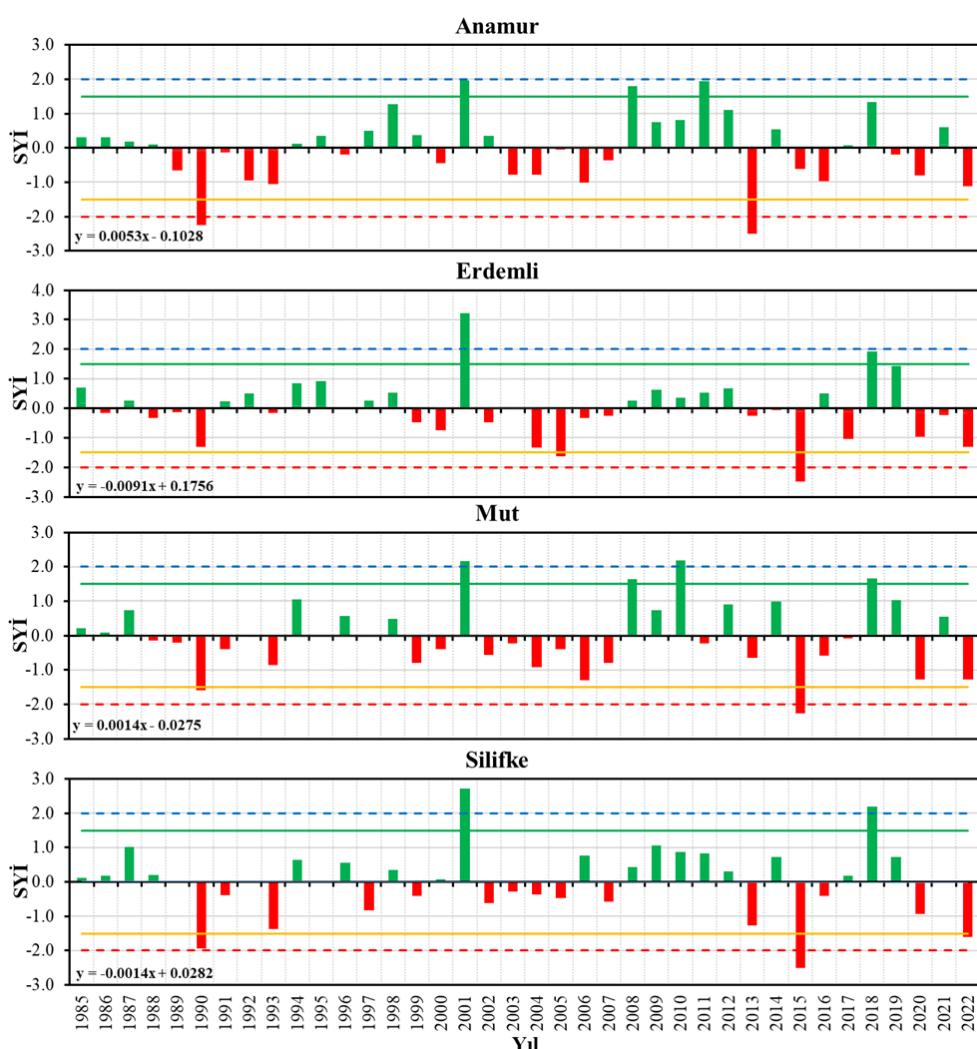
Kesinlik ve belirlilik metrikleri incelendiğinde, ekili alan ve ormanlık alan için kesinlik değerlerinin daha tutarlı olduğu, özellikle 2005 ve sonrası dönemde bu sınıfların kesinlik değerlerinin %85'in altına düşmediği görülmektedir. Yeşil alanın belirlilik değerleri ise %83 ile %94 arasında dalgalanma göstermiştir, ancak 2010 yılından itibaren belirlilik değerlerinde genel bir artış trendi ortaya çıkmıştır. F1 skoru ve geri çağrıma değerleri açısından ekili alan çoğunlukla yüksek performans sergilemiş, %85'in altına nadiren düşmüş ve özellikle 1990-2010 yılları arasında %90 civarında sabit kalmıştır. Yeşil alan ise F1 skoru ve geri çağrıma değerleri yıllar arasında %81 ile %94 arasında değişiklik göstermiş olup son yıllarda bu sınıfta daha stabil bir seyir gözlenmiştir. Ormanlık alan ise bazı dönemlerde %82 seviyelerine kadar

düşen geri çağrıma değerleri, bazı yıllarda %93 ve üzerine çıkararak performansın arttığını göstermektedir.

1985-2003 dönemi ile 2004-2023 dönemi karşılaştırıldığında, 2004 sonrasında genel doğruluk, kesinlik ve geri çağrıma gibi metriklerde sınıflandırma performansında belirgin bir iyileşme olduğu gözlemlenmiştir. Bu iyileşme, kullanılan teknoloji veya veri işleme yöntemlerindeki gelişmelerden kaynaklanıyor olabilir. Tüm bu sonuçlar, sınıflandırma işleminin yüksek doğruluk oranlarıyla gerçekleştirilmiş olduğunu göstermektedir. Ancak, bazı sınıflarda dönemsel olarak gözlemlenen dalgalanmalar sınıfların ayrıştırılmasında zorluklar yaşanabileceğini işaret etmektedir.

### 3.2. Kuraklığın Değerlendirilmesi

Çalışma bölgesinde konumlanmış olan 17320-Anamur, 17958-Erdemli, 17330-Silifke ve 17956-Mut istasyonlarında 1985-2022 yılları arasında ölçülen yağış verileri kullanılarak elde edilen 12 aylık SYİ indis değerlerinin zamansal değişimleri Şekil 4'te verilmiştir.



**Şekil 4.** Meteorolojik gözlem istasyonlarına ait SYİ 12 değerlerinin zamansal değişimleri

Anamur istasyonuna ait SYİ değerlerinin zamansal değişiminden, istasyonda aşırı yağışlı (SYİ<-2) sınıfın oluşmadığı buna karşılık ele alınan zaman periyodu içerisinde iki yılda aşırı kuraklık yaşanmıştır. 2013 yılından önceki yıllarda aralıksız olarak kuraklık veya yağışlı geçen yılların uzunluğu daha fazla iken bu tarihten itibaren kurak ve yağışlı dönemler arasında geçiş daha kısa yıllar sürmüştür. Bu istasyonda uzun kurak ve yağışlı dönem 5 yıl sürmüştür.

En şiddetli kuraklığın yaşandığı dönem olan 1989-1993 yılları arasında kuraklık şiddeti-5.036 olarak gerçekleşmiştir. Ele alınan diğer istasyonlarda en şiddetli kuraklık 2015 yılında, en yağışlı indis değeri ise 2001 yılında hesap edilmiştir. Erdemli istasyonunda en şiddetli kuraklık-4.061 değerinde, Mut istasyonunda -4.193 değerinde ve Silifke istasyonunda ise -2.923 değerinde yaşanmıştır. En uzun kuraklık Erdemli ve Mut istasyonlarında 6 yıl, Silifke istasyonunda ise 5 yıl sürmüştür. Linear eğim değerleri incelendiğinde Anamur ve Mut istasyonlarında pozitif bir eğim yani kuraklıktan azalma görülürken, Erdemli ve Silifke istasyonlarında tam tersi bir durum söz konusudur.

Ele alınan istasyonlara ait 12 aylık indis değerlerinin zamansal değişim grafiklerinden, son yıllarda bölgede kuraklık ve yağışlı dönemlerin 2013 yılından itibaren daha kısa aralıklarla geçiş yaptığı belirlenmiştir. İncelenen bölgede, 2008-2012 yıllarının yağışlı geçtiği, 1988-1993 ve 2002-2007 yıllarında ise genel olarak kuraklığın belirgin bir şekilde meydana geldiği söylenebilir.

12 aylık zaman ölçüğinde elde edilen indis değerlerinin Mann-Kendall ve Spearman Rho trend analizi sonuçları ve Sen Slope değerleri Tablo 6'da verilmiştir. %95 güven aralığında gerçekleştirilen trend analizi sonuçlarına göre herhangi bir istasyonda istatistiksel olarak anlamlı herhangi bir trend belirlenmemiştir. Her iki yöntem ile Anamur istasyonunda artan trend, Erdemli, Mut ve Silifke istasyonlarında ise azalan trend vardır. En büyük azalma eğilimi Erdemli istasyonunda-0.0061 olarak elde edilmiştir. Sonuç olarak ele alınan istasyonların büyük bir çoğunluğunda indis değerlerinde azalma eğilimi yani kuraklıktan artma eğilimi söz konusudur.

Çalışma bölgesi içerisinde Anamur istasyonu incelenen istasyonlar arasında kuraklık açısından en az riske sahip istasyon olarak belirlenmiştir. Bölge genelinde meteorolojik kuraklığını incelemek için sadece yağışa dayalı hesaplanan indis değerlerinde meydana gelen azalma eğilimi bölgede her ne kadar kuraklığın artacağını ifade etse de elde edilen test istatistiklerinin %95 güven aralığında statistiksel olarak anlamlı olmaması ve Sen Slope değerlerinin oldukça küçük olması çalışma bölgesinde kuraklık riskinin az olduğu ve değişimin kısıtlı olacağı anlamına gelmektedir.

Ayrıca, bölgede artan sulama göletleri ve sıcaklık değerlerinden çalışma bölgesinde nemin artması kaçınılmazdır. Artan sıcaklık ve nemlilik, bölgede iklim değişikliğinin meydana gelmesine neden olacaktır.

**Tablo 6.** Trend analizi sonuçları

İstasyon	Mann-Kendall	Spearman Rho	Sen Slope
Anamur	0.1509	0.2267	0.0035
Erdemli	-0.4274	-0.5931	-0.0061
Mut	-0.2514	-0.1412	-0.0033
Silifke	-0.1006	-0.0282	-0.0020

#### 4. TARTIŞMA

Bu çalışmanın bulguları, tarımsal sulama göletlerinin tarımsal sürdürülebilirlik ve ekosistem sağlığı üzerindeki olumlu etkilerini ortaya koyarak, su yönetimi ve iklim değişikliğiyle mücadelede önemli bir araç olabileceğini göstermektedir. Özellikle kurak dönemlerde bitki örtüsünün korunmasına katkı sağlayan bu göletler, su yönetimi politikalarında değerli bir bileşen olarak düşünülebilir. Çalışmanın sunduğu bulgular, sulama göletlerinin yerel su kaynaklarının etkin yönetimi için stratejik bir araç olduğunu göstermekte ve bu yapılarla doğal su döngüsünün uyumlu bir şekilde entegre edilmesi gerektiğini vurgulamaktadır. Bu doğrultuda, küresel su yönetimi politikaları kapsamında yarı kurak ve kurak bölgelerde sulama göletlerinin inşasını teşvik eden fonların artırılması ve sürdürülebilir yönetim uygulamalarının geliştirilmesi önerilmektedir.

Aynı zamanda, sulama göletlerinin iklim değişikliğiyle mücadelede doğa temelli çözümler olarak kullanılabilirliği, çalışmanın diğer önemli katkılardan biridir. Bulgular, bu göletlerin mikro iklimi düzenleyici etkilerini ve karbon emisyonlarını azaltmaya yönelik potansiyellerini ortaya koymaktadır. Bu bağlamda, göletlerin mikro iklim üzerindeki düzenleyici etkileri, tarımsal alanlarda iklim dostu uygulamaların geliştirilmesi için güçlü bir arguman sunmaktadır. Bu tür uygulamalar, yarı kurak bölgelerde sürdürülebilir tarım pratikleri ve ekolojik dengeyi destekleyen iklim adaptasyon stratejilerinin temelini oluşturabilir.

Çalışmamız ayrıca, diğer yarı kurak ülkeler için de stratejik öneriler sunmaktadır. Bu ülkelerde tarımsal sulama göletlerinin, kuraklık stresini azaltmada ve tarımsal sürdürülebilirliği desteklemeye önemli bir rol oynayabileceği anlaşılmıştır. Göletlerin, bölgesel coğrafi ve iklimsel koşullara uygun şekilde tasarlanarak yaygınlaştırılması, yerel su kaynaklarının verimli kullanımını destekleyebilir. Bu uygulama, mikro iklim desteği sağlayarak bölgedeki kuraklık etkilerinin azaltılmasına katkıda bulunacaktır.

Bu çalışmanın sonuçları, önemli bilgiler sunmakla birlikte bazı sınırlamaları da beraberinde getirmektedir. Özellikle bulutlu günlerde uydu görüntülerinde yaşanan veri eksiklikleri, bazı analizlerde zaman sürekliliğini kısıtlamıştır. Gelecekteki çalışmalarda, daha sık veri toplayabilen uydu platformlarının veya bulut örtüsünden etkilenmeyen radar görüntüleme tekniklerinin kullanılması, veri setinin sürekliliğini artırarak bu sınırlamayı azatabilir. Ayrıca, sulama göletlerinin olumlu yönlerinin yanı sıra diğer su kaynakları

üzerindeki olumsuz etkileri de dikkate alınmalıdır. Bu göletler, doğal su döngüsüne müdahale ederek bölgedeki akarsu, nehir ve yeraltı sularının doğal dengesini bozabilir. Bu bağlamda, yarı kurak ve kurak bölgelerde sulama göletlerinin potansiyel çevresel riskleri göz önünde bulundurularak daha geniş kapsamlı çalışmalar yapılması gerekmektedir.

Sonuç olarak, bu çalışma, sulama göletlerinin tarımsal sürdürülebilirliği ve iklim değişikliği ile mücadeleye yönelik stratejik bir çözüm olarak önemini vurgulamaktadır. Bulgular, su yönetimi ve iklim değişikliği politikalarına katkı sağlayacak, yarı kurak bölgeler için uygulanabilir öneriler sunmaktadır. Ancak, sulama göletlerinin çevresel etkilerini daha kapsamlı şekilde ele alan ileri araştırmaların yapılması, bu yapılarla sürdürülebilir su yönetimi arasında denge kurmak adına önem taşımaktadır.

## 5. SONUÇLAR

Bu çalışma, tarımsal sulama göletlerinin tarımsal sürdürülebilirlik ve ekosistem sağlığı üzerindeki katkılardır, uzun vadeli uydu görüntüleri ve meteorolojik veriler ışığında analiz etmiştir. Elde edilen bulgular, sulama göletlerinin kurak dönemlerde bitki örtüsünü koruyarak ekosistem sağlığını destekleme ve tarımsal verimliliği artırmada önemli bir rol oynadığını göstermektedir. Ayrıca, göletlerin mikro iklim üzerindeki olumlu etkileri, bölgesel iklim düzenlemelerine katkıda bulunabileceğini ortaya koymaktadır.

Elde edilen bulgulara göre, 1985 yılında 51 adet olan sulama göleti sayısının 2023 yılında 1935'e çıktığı tespit edilmiştir. Bu artış, bölgedeki bitki örtüsü oranının yükselmesine doğrudan katkı sağlamıştır. Özellikle, NDVI değerlerinde gözlemlenen iyileşme, sulama göletlerinin toprak nemini koruma ve tarımsal ürün büyümесini destekleme konusundaki etkisini açıkça ortaya koymaktadır. Ayrıca, bu göletlerin, bölgenin tarımsal üretim kapasitesini artırırken kuraklık etkilerini hafiflettiği belirlenmiştir. Kuraklık analizleri, çalışma alanında 1988-1993 ve 2002-2007 yılları arasında belirgin kuraklık dönemlerinin yaşandığını, ancak 2013 yılından itibaren kurak ve yağışlı dönemlerin daha kısa aralıklarla değiştigini göstermektedir. Sulama göletlerinin bu kısa süreli kuraklık dönemleri boyunca tarımsal üretimin devamlılığını sağladığı gözlemlenmiştir. Göletler, sadece su depolama kapasitesi ile değil, aynı zamanda çevresel direnç sağlamada da önemli bir rol üstlenmiştir. Ele alınan bölgede, kuraklıktaki olası artışlara bağlı olarak sulama göletlerinin sayısının arttırılması sonucunda bitki deseninde meydana gelen artış, sulama göletleri vasıtıyla olası kuraklık etkilerinin azaltılmasının mümkün olduğu değerlendirilmektedir.

Çalışma, sulama göletlerinin bitki örtüsüne ve su kaynaklarının sürdürülebilir yönetimine katkı sağladığını vurgulamaktadır. Özellikle kurak iklim koşullarında, bu göletlerin stratejik bir su yönetim

aracı olarak kullanılması, su kıtlığı ve iklim değişikliği ile mücadelede büyük bir potansiyel sunmaktadır. Ancak, sulama göletlerinin yaygınlaşmasının doğal su döngüsünü ve nehirlerin beslenme süreçlerini olumsuz etkilememesi için dikkatli bir planlama ve yönetim gereklidir. Ayrıca yarı kurak ve kurak bölgelerde bu göletlerin yaygınlaştırılması, kuraklık stresini azaltarak tarımsal üretimin sürdürülebilirliğini sağlayabilir. Göletlerin karbon emisyonlarını azaltma ve toprağın nemini koruma gibi faydalari, iklim değişikliği ile mücadelede doğa temelli çözümler kapsamında değerlendirilebilir.

Sonuç olarak, tarımsal sulama göletleri, su kaynaklarının verimli yönetimini sağlama ve iklim değişikliğine karşı direnç oluşturma potansiyeliyle önemli bir çözüm olarak öne çıkmaktadır. Ancak, bu tür yapıların doğal su döngüsüne olası etkilerinin de dikkatle değerlendirilmesi gerektiği açıklıktır. Bu çalışma, tarımsal sulama göletlerinin sürdürülebilir su yönetimi ve iklim değişikliği politikalarına katkı sağlayacak şekilde daha geniş bir stratejik çerçevede ele alınması gerektiğini vurgulamaktadır. Gelecekte yapılacak araştırmaların, göletlerin çevresel etkilerini daha kapsamlı inceleyerek bu yapılarla ilgili sürdürülebilir politikaların geliştirilmesine katkı sunması önerilmektedir.

## Bilgilendirme/Teşekkür

Bu makalenin özet hali, 12th Global Conference on Global Warming (GCGW-2024) sempozyumunda sunulmuştur. Bu çalışma sunulan bildirinin genişletilmiş ve büyük oranda geliştirilmiş halidir. Yazarlar ayrıca Meteorolojik veriler için Meteoroloji Genel Müdürlüğü'ne ve ücretsiz uydu verileri için NASA ve ABD Jeoloji Araştırması'na teşekkür eder.

## Araştırmacıların katkı oranı beyan özeti

A. Y. Yiğit: Veri analizi, Araştırma, Uygulama, Görselleştirme, Makale yazımı, Revizyon;  
O. Şişek: Veri analizi, Verilere ait istatistikler, Uygulama, Makale yazımı, Kontrol, Revizyon;  
H. İ. Şenol: Konsept Oluşturma, Veri temini, Görselleştirme, 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 gerektirdiğini beyan etmektedir.

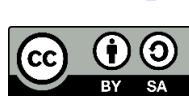
## KAYNAKÇA

Abera, A., Verhoest, N. E., Tilahun, S., Inyang, H., & Nyssen, J. (2021). Assessment of irrigation

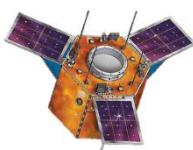
- expansion and implications for water resources by using RS and GIS techniques in the Lake Tana Basin of Ethiopia. *Environmental Monitoring and Assessment*, 193, 1–17. <https://doi.org/10.1007/s10661-021-08924-2>
- Achite, M., Simsek, O., Adarsh, S., Hartani, T., & Caloiero, T. (2023). Assessment and monitoring of meteorological and hydrological drought in semiarid regions: The Wadi Ouahrane basin case study (Algeria). *Physics and Chemistry of the Earth, Parts A/B/C*, 130, 103386. <https://doi.org/10.1016/j.pce.2022.103386>
- Adanalı, T. (2022). Rekreasyon alanlarında kullanılan farklı sulama yöntemlerinin topraktaki tuz dağılımına etkisi [Master's thesis, Tekirdağ Namık Kemal Üniversitesi].
- Aktaş, Ö. (2014). Impacts of climate change on water resources in Turkey. *Environmental Engineering & Management Journal (EEMJ)*, 13(4), 799–810.
- Andriushchenko, K., Datsii, O., Aleinikova, O., Abdulla, A. M., & Ali, A. M. (2019). Improvement of the water resources management system at the territorial level. *Problems and Perspectives in Management*, 17(3), 421–430. [https://doi.org/10.21511/ppm.17\(3\).2019.34](https://doi.org/10.21511/ppm.17(3).2019.34)
- Angelakis, A. N., Zaccaria, D., Krasilnikoff, J., Salgot, M., Bazza, M., Roccaro, P., ... & Fereres, E. (2020). Irrigation of world agricultural lands: Evolution through the millennia. *Water*, 12(5), 1285. <https://doi.org/10.3390/w12051285>
- Atıcı, A., Paksoy, M. F., & Kabadayı, A. (2024). Maden sahalarındaki stok miktarının İHA yardımıyla belirlenmesi. *Türkiye Fotogrametri Dergisi*, 6(1), 8–13. <https://doi.org/10.53030/tufod.1489122>
- Baatz, M. (2000). Multiresolution segmentation: An optimization approach for high-quality multi-scale image segmentation. *Angewandte Geographische Informationsverarbeitung*, 12–23.
- Bandyopadhyay, J., Rahaman, S. H., & Karan, C. (2023). Agricultural potential zone mapping with surface water resource management using geo-spatial tools for Jhargram district, West Bengal, India. *Knowledge-Based Engineering and Sciences*, 4(1), 1–18.
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., & Heynen, M. (2004). Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3–4), 239–258.
- <https://doi.org/10.1016/j.isprsjprs.2003.10.002>
- Bergsjö, J. (2014). Object-based change detection in urban area using KTH-SEG. *KTH Royal Institute of Technology, Sweden*.
- Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., ... & Tiede, D. (2014). Geographic object-based image analysis: Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 180–191. <https://doi.org/10.1016/j.isprsjprs.2013.09.014>
- Blaschke, T., Hay, G. J., Weng, Q., & Resch, B. (2011). Collective sensing: Integrating geospatial technologies to understand urban systems—An overview. *Remote Sensing*, 3(8), 1743–1776. <https://doi.org/10.3390/rs3081743>
- Carleer, A. P., & Wolff, E. (2006). Urban land cover multi-level region-based classification of VHR data by selecting relevant features. *International Journal of Remote Sensing*, 27(6), 1035–1051. <https://doi.org/10.1080/01431160500219302>
- Çelebioğlu, T., & Tayanç, M. (2024). A study on precipitation trends in Türkiye via linear regression analysis and non-parametric Mann-Kendall test. *Sürdürülebilir Çevre Dergisi*, 4(1), 19–28.
- Definiens. (2012). *Definiens Developer XD 2.0.4: Reference Book*. Definiens AG, München, Germany. Retrieved from <https://www.imperial.ac.uk/media/imperialcollege/medicine/facilities/film/Definiens-Developer-Reference-Book-XD-2.0.4.pdf>
- Erdoğan, A., Görken, M., Kabadayı, A., & Temizel, S. (2022). Evaluation of green areas with remote sensing and GIS: A case study of Yozgat city center. *Advanced Remote Sensing Journal (ARSEJ)*, 2(2), 1–9.
- Guan, H., Li, J., Yu, Y., Chapman, M., & Wang, C. (2014). Automated road information extraction from mobile laser scanning data. *IEEE Transactions on Intelligent Transportation Systems*, 16(1), 194–205. <https://doi.org/10.1109/TITS.2014.2326795>
- Gumus, V., Avsaroglu, Y., & Simsek, O. (2022). Streamflow trends in the Tigris river basin using Mann– Kendall and innovative trend analysis methods. *Journal of Earth System Science*, 131(1), 34. <https://doi.org/10.1007/s12040-022-01837-3>

- Gumus, V., Simsek, O., & Seaid, M. (2023). Investigating recent changes in the wind speed trends over Turkey. *Acta Geophysica*, 71(3), 1305–1319. <https://doi.org/10.1007/s11600-023-00938-4>
- Gupta, N., & Bhaduria, H. S. (2014). Object-based information extraction from high-resolution satellite imagery using eCognition. *International Journal of Computer Science Issues (IJCSI)*, 11(3), 139–144.
- Gürgülü, H., & Ul, M. A. (2024). Different effects of irrigation water salinity and leaching fractions on pepper (*Capsicum annuum L.*) cultivation in soilless culture. *Agriculture*, 14(6), 827. <https://doi.org/10.3390/agriculture14060827>
- Hossain, K. T., Salauddin, M., & Tanim, I. A. (2016). Assessment of the dynamics of coastal island in Bangladesh using geospatial techniques: Domar Char. *Journal of the Asiatic Society of Bangladesh Science*, 42, 219–228.
- 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. <https://doi.org/10.1016/j.isprsjprs.2019.02.019>
- Huang, M., Mu, Z., Zhao, S., & Yang, R. (2024). Ecological water requirement of natural vegetation in the Tarim River Basin based on multi-source data. *Sustainability*, 16(16), 7034. <https://doi.org/10.3390/su16167034>
- Kabadayı, A., & Kaya, Y. (2023). Monitoring shoreline and areal change with UAV data. *Intercontinental Geoinformation Days*, 7, 153–156.
- Kartal, V., & Emiroglu, M. E. (2024). Hydrological drought and trend analysis in Kızılırmak, Yeşilırmak and Sakarya Basins. *Pure and Applied Geophysics*, 1–25. <https://doi.org/10.1007/s00024-024-03289-9>
- Kaur, R., Bansal, K., Garg, D., Sardana, R., Vishnubhatla, S., Agrawal, S., ... & Seth, A. (2024, July). Assessing the impact of farm ponds on agricultural productivity in Northern India. In *Proceedings of the 7th ACM SIGCAS/SIGCHI Conference on Computing and Sustainable Societies* (pp. 281–293). <https://doi.org/10.1145/3457607.3460648>
- Keskiner, A. D., & Simsek, O. (2024). Evaluation of the sensitivity of meteorological drought in the Mediterranean region to different data record lengths. *Environmental Monitoring and Assessment*, 196(7), 1–29. <https://doi.org/10.1007/s10661-023-10949-y>
- Keskiner, A. D., & Şimşek, O. (2023). Olasılıklı meteorolojik kuraklık analizi: Göller yöresinde bir uygulama. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 27(1), 160–169.
- Khatami, R., Mountrakis, G., & Stehman, S. V. (2016). A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*, 177, 89–100. <https://doi.org/10.1016/j.rse.2016.02.028>
- Koutsoyiannis, D. (2011). Scale of water resources development and sustainability: Small is beautiful, large is great. *Hydrological Sciences Journal*, 56(4), 553–575. <https://doi.org/10.1080/02626667.2011.579076>
- López-Felices, B., Aznar-Sánchez, J. A., Velasco-Muñoz, J. F., & Piquer-Rodríguez, M. (2020). Contribution of irrigation ponds to the sustainability of agriculture: A review of worldwide research. *Sustainability*, 12(13), 5425. <https://doi.org/10.3390/su12135425>
- Luo, Y., Qin, J., Xiang, X., & Tan, Y. (2020). Coverless image steganography based on multi-object recognition. *IEEE Transactions on Circuits and Systems for Video Technology*, 31(7), 2779–2791. <https://doi.org/10.1109/TCSVT.2020.2975078>
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., & Liu, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 277–293. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Malakar, A., Snow, D. D., & Ray, C. (2019). Irrigation water quality—A contemporary perspective. *Water*, 11(7), 1482. <https://doi.org/10.3390/w11071482>
- Merdan, K. (2024). Türkiye'nin tarım sektörü: Tarımının dünü, bugün ve yarını. *Bingöl Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 8(1), 47–70.
- Oğuz, H. (2016). LST Calculator: A Python tool for retrieving land surface temperature from Landsat 8 imagery. *Environmental Sustainability and Landscape Management*, 560, 1–14.

- Orhan, O., Bilgilioglu, S. S., Kaya, Z., Ozcan, A. K., & Bilgilioglu, H. (2022). Assessing and mapping landslide susceptibility using different machine learning methods. *Geocarto International*, 37(10), 2795–2820. <https://doi.org/10.1080/10106049.2021.1955249>
- Ouma, Y., Nkwae, B., Moalafhi, D., Odirile, P., Parida, B., Anderson, G., & Qi, J. (2022). Comparison of machine learning classifiers for multitemporal and multisensor mapping of urban LULC features. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 681–689. <https://doi.org/10.5194/isprs-archives-XLIII-B2-2022-681-2022>
- Ozturk, M. Y., & Colkesen, I. (2024). A novel hybrid methodology integrating pixel-and object-based techniques for mapping land use and land cover from high-resolution satellite data. *International Journal of Remote Sensing*, 45(16), 5640–5678.
- Roy, D. P., Wulder, M. A., Loveland, T. R., Woodcock, C. E., Allen, R. G., Anderson, M. C., ... & Zhu, Z. (2014). Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154–172. <https://doi.org/10.1016/j.rse.2014.02.001>
- Senthilkumaran, N., & Vaithogi, S. (2016). Image segmentation by using thresholding techniques for medical images. *Computer Science & Engineering: An International Journal*, 6(1), 1–13. <https://doi.org/10.5121/cseij.2016.6101>
- Simsek, O., Bazrafshan, O., & Azhdari, Z. (2024a). A 3-D copula for risk analysis of meteorological drought in the Black Sea Region. *Theoretical and Applied Climatology*, 155(2), 1185–1200. <https://doi.org/10.1007/s00704-023-04541-7>
- Simsek, O., Ceyhunlu, A. I., Ceribasi, G., & Keskiner, A. D. (2024b). Evaluation of long-term meteorological drought in the Aras and Coruh Basins with Crossing Empirical Trend Analysis. *Physics and Chemistry of the Earth, Parts A/B/C*, 135, 103611. <https://doi.org/10.1016/j.pce.2024.103611>
- Staccione, A., Broccoli, D., Mazzoli, P., Bagli, S., & Mysiak, J. (2021). Natural water retention ponds for water management in agriculture: A potential scenario in Northern Italy. *Journal of Environmental Management*, 292, 112849. <https://doi.org/10.1016/j.jenvman.2021.112849>
- Şahin, G., & Kahraman, M. (2021). Kent içi tarım uygulamalarında dünyanın en eski örneği: Yedikule Bostanları. *Turkish Studies-Social Sciences*, 16(1), 401–416.
- Şen, Z., & Şışman, E. (2024). Risk attachment Sen's Slope calculation in hydrometeorological trend analysis. *Natural Hazards*, 120(4), 3239–3252. <https://doi.org/10.1007/s11069-023-05852-7>
- Şimşek, O., Soydan Oksal, N. G., Uncu, E. M., Gümüş, V., & Şeker, M. (2024). SYİ yöntemiyle Çoruh havzası uzun dönem (1969–2020) meteorolojik kuraklığının analizi. *Politeknik Dergisi*, 27(4), 1553–1564.
- Tehrany, M. S., Pradhan, B., & Jebuv, M. N. (2014). A comparative assessment between object and pixel-based classification approaches for land use/land cover mapping using SPOT 5 imagery. *Geocarto International*, 29(4), 351–369. <https://doi.org/10.1080/10106049.2013.768300>
- Vico, G., Tamburino, L., & Rigby, J. R. (2020). Designing on-farm irrigation ponds for high and stable yield for different climates and risk-coping attitudes. *Journal of Hydrology*, 584, 124634. <https://doi.org/10.1016/j.jhydrol.2020.124634>
- Wei, W., Chen, X., & Ma, A. (2005, July). Object-oriented information extraction and application in high-resolution remote sensing image. In *Proceedings of the 2005 IEEE International Geoscience and Remote Sensing Symposium (IGARSS'05)* (Vol. 6, pp. 3803–3806). <https://doi.org/10.1109/IGARSS.2005.1526762>
- Yiğit, A. Y., Kaya, Y., & Şenol, H. İ. (2022). Monitoring the change of Turkey's tourism city Antalya's Konyaaltı shoreline with multi-source satellite and meteorological data. *Applied Geomatics*, 14(2), 223–236. <https://doi.org/10.1007/s12518-022-00410-9>
- Zaman, M., Shahid, S. A., & Heng, L. (2018). Irrigation water quality. In *Guideline for salinity assessment, mitigation and adaptation using nuclear and related techniques* (pp. 113–131). Springer. [https://doi.org/10.1007/978-3-319-96190-3\\_6](https://doi.org/10.1007/978-3-319-96190-3_6)



© Author(s) 2024.  
This work is distributed under  
<https://creativecommons.org/licenses/by-sa/4.0/>



## EXOLIFE: Detection and Habitability Estimation of Exoplanets Using Machine Learning Techniques

Eren Yılmaz<sup>\*1</sup>, Muhammet Enes Artan<sup>2</sup>, Ahmet Bilal Yanartaş<sup>3</sup>

<sup>1</sup> Hadımköy, Karaağaç Mah., 35000 Büyükçekmece, İstanbul

<sup>2</sup> Levent, Büyükdere Cd., 34394 Beşiktaş, İstanbul

<sup>3</sup> Acılar Mah., 34800, Beykoz, İstanbul

### Keywords

Exoplanet  
NASA  
Machine Learning  
XGBoost  
Biosignature

### ABSTRACT

Exoplanets are among the most studied and remarkable topics in astronomy. Over the years, various methods have emerged for exoplanet detection, allowing for the identification of numerous exoplanet types. In this context, remote sensing and machine learning, which are central to our research, have significantly accelerated the detection process by leveraging algorithms. Our study involved training several machine learning models, including XGBoost, Random Forest, Multilayer Perceptron, K-Nearest Neighbor, Logistic Regression, and Support Vector Classifier, to compare their performance in both habitability assessment and exoplanet detection. The research utilized machine learning models trained on space observation data obtained from NASA, with the Python programming language serving as the foundation for the system's infrastructure. Our hypothesis was that "The detection of exoplanets and their evaluation within the scope of the habitability criterion can be increased to high accuracy rates with machine learning." Unlike merely detecting exoplanets, this study specifically aimed to identify Earth-like exoplanets. The XGBoost algorithm emerged as the most successful model in determining habitability, achieving an accuracy rate of 97.46% and demonstrating high precision and sensitivity. For exoplanet detection, all models achieved a main test accuracy rate of 96%; however, when considering sensitivity and precision, XGBoost was again the most effective. This research, following the synthesis and analysis of these two parameters, achieved a very high success rate compared to previous studies and made a significant contribution to the astronomy/astrophysics literature. Additionally, a Graphical User Interface (GUI) was developed, making the tested models functional through an application. The study successfully reached its goal of contributing important findings to the field.

## EXOLIFE: Makine Öğrenmesi Kullanarak Ötegezegenlerin Tespit Edilmesi ve Yaşanabilirlik Tahmini Yapılması

### Anahtar Kelimeler:

Ötegezegen  
NASA  
Makine Öğrenmesi  
XGBoost  
Biyoimza

### ÖZ

Ötegezegenler, günümüzde astronomi alanında en çok çalışılan konular arasında yer almaktadır. Farklı türlerde oluşan ötegezegenlerin tespiti için çeşitli yöntemler geliştirilmiştir ve bu sayede saptama mümkün hale gelmiştir. Bu araştırmada, ötegezegen tespiti için kullanılan uzaktan algılama ve makine öğrenmesi yöntemleri, algoritmalarla süreci hızlandırmaktadır. Projede, XGBoost, Rastgele Orman, Çok Katmanlı Algılayıcı, K-En Yakın Komşu, Lojistik Regresyon ve Destek Vektör Sınıflandırıcı modelleri eğitilmiş ve hem yaşanılabilirlik hem de ötegezegen tespiti için karşılaştırmalar yapılmıştır. NASA verileriyle eğitilen bu makine öğrenmesi sistemi, Python yazılım diliyle oluşturulmuştur. Çalışma, "Ötegezegenlerin tespiti ve yaşanılabilirlik ölçütü kapsamında değerlendirilmesi makine öğrenmesi ile yüksek doğruluk oranlarına çıkarılabilir." hipotezine dayanarak Dünya benzeri ötegezegenleri bulmayı hedeflemiştir. Sonuçlarda, yaşanılabilirlik saptamasında %97.46 doğruluk oranı ile XGBoost algoritması en başarılı model olarak öne çıkmıştır. Gezegen tespitinde de %96'lık doğruluk oranıyla XGBoost, en başarılı model olmuştur. Araştırma, yüksek başarı oranıyla astronomi/astrofizik literatürüne önemli katkılar sağlamıştır. Ayrıca, çalışmanın sonucunda bir Grafiksel Kullanıcı Arayüzü (GUI) oluşturulmuş ve test edilen modeller işlevsel hale getirilmiştir.

### Article Info

Received: 22/09/2024  
Accepted: 28/11/2024  
Published: 30/12/2024

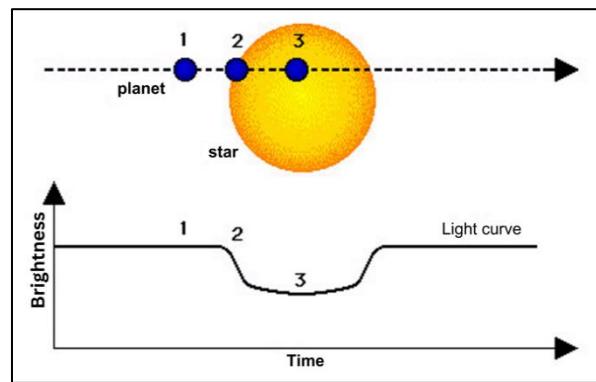
### Citation:

Yılmaz, E., Artan, M.E., Yanartaş, A. B. (2024). EXOLIFE: Detection and Habitability Estimation of Exoplanets Using Machine Learning Techniques. Turkish Journal of Remote Sensing, 6(2), 85-96.

## 1. INTRODUCTION

Exoplanets are planets that orbit stars outside the solar system. In recent years, scientists have carried out various studies on planets beyond the solar system and have planned long-term studies under this title (Patel, 2021). The idea of finding new habitable planets has been a topic of concern for researchers over the years, but as of today, exoplanets have made this issue a central issue again. It is predicted that exoplanets, which are also of great interest to the society, will become the center point of astronomy research in the coming years (Xin, 2022). When classifying exoplanets, scientists have divided them into four main categories based on their size: Terrestrial Planets, Super-Earths, Neptune-Like Planets, and Gas Giants (NASA, 2022). Terrestrial planets are rocky planets with Earth-like masses and iron-rich cores. Super-Earths, as the name suggests, are planets that are much larger than Earth but smaller than Uranus or Neptune. Neptune-like planets often have atmospheres with density H<sub>2</sub>/He similar to those of Neptune (Helled, 2020). Finally, gas giants are gaseous planets with a size similar to or much larger than Saturn or Jupiter.

Various techniques have been developed for the detection of exoplanets and different areas such as remote sensing have become available through advancing technology. In this context, the four main known techniques are; the transition method is the radial velocity method, microlensing, and direct imaging (Dai, 2021). The transition method is currently the most useful technique. When a planet passes in front of a star, some of the starlight that is emitted bounces off that planet's atmosphere and reaches the earth. Through the transit method, as shown in Figure 1, the use of radiated light and gravitational force helps provide information about the planet's atmospheric chemical compositions and habitability. In the radial velocity method, velocity changes are used as determined by the changing direction of the gravitational force that any exoplanet receives from an outer planet as it rotates on the axis of another star (Huang, 2017). The microlensing method is a technique in which reproducible measurements cannot be made due to the fact that the measured event occurs very rarely, and therefore it is not used much. Finally, the direct imaging technique is a method that can detect exoplanets with an inclination of 90 degrees in their entirety, but this rarely happens due to the combination of the planet's small size and proximity to its star (Dai, 2021). Of the 5523 exoplanets confirmed by NASA so far, 1895 are marked as Neptune-like, 1748 as Gas Giants, 1674 as Super-Earths, 199 as Terrestrial, and the remaining 7 as unknown. Of the detected planets, 74.6% were determined using the transit method, 19.3% using the radial velocity method, 3.7% using the microlensing method, and the remaining 1.3% using the direct imaging method. (Brennan, 2020)



**Figure 1.** Transit Method

A biosignature is defined as a characteristic that provides scientific evidence for the existence of life and can be detected by remote sensing. These signatures are; gases in the atmosphere have several variations, such as chemical compounds and physical properties (Schwieterman, 2018). The habitable zone, on the other hand, is characterized when the conditions around a star can create a suitable environment for the existence of water. Since water is a critical component for life, determining the habitable zone is extremely important for assessing potential habitability (Ramirez, 2018). In this context, biological signature is processed under three basic subheadings. Among the biosignatures, gases in the atmosphere play a very important role. The presence of certain gases in the atmosphere, such as oxygen, methane, can be considered a biosignature when it is not in balance with the geology and chemistry of the planet. Among the gases in the Earth's atmosphere, there are gases such as N<sub>2</sub>, Ar, CO<sub>2</sub>, H<sub>2</sub>O, which are associated with living life and are directly related to biological activity (Yung, 2015). "Bioindicators" refer to the fact that atmospheric signatures can be produced by life or non-biotic processes. For example, although water (H<sub>2</sub>O) is not a bioindicator, it is an important raw material and greenhouse gas for life. Other potential bioindicators include gases such as SO<sub>2</sub>, H<sub>2</sub>S. These gases can be considered biosignatures when they are produced by volcanic activity or when they are present in the atmosphere under certain conditions (Meadows, 2018). The presence of plants and plant pigments on the planet's surface can be detected by a spectrum feature called the "Red Edge". This trait is unique to vegetation and indicates the presence of organisms that carry out photosynthesis (Seager, 2005). These observations were made with the aim of investigating potential biosignatures by remotely detecting the atmospheres and surfaces of Earth-like planets. The NASA Astrobiology Program has led efforts to search for biosignatures of exoplanet atmospheres. These studies were carried out by studying spectral models of the planet's surface and testing the concentration of biogenic gases (NASA, 2022).

Humanity's exoplanet exploration process has been going on for more than 30 years and is considered one of the most interesting branches of space exploration. At the very beginning of the process, in April 1984, the 2.5-metre du Pont telescope in Chile produced the original discovery image of the disc of dust and gas around the star Beta Pictoris (Hale, 2020). Following ongoing studies, the first exoplanets were discovered in January 1992, but they were unable to support organic life because they were bombarded with radiation from dead neutron stars in their orbits. In 1995, the first exoplanet orbiting a star similar to the Sun was discovered using the radial velocity technique. Subsequently, the use of technology became active; On April 4, 2001, the first planet in the "habitable zone" was found. Then, in October 2001, the first measurement of the atmosphere of a planet outside the solar system was made, and the first data were entered into the scientific world. As a result of subsequent studies, in 2005, the first detection of light from a planet outside the Solar System was made using the Spitzer Space Telescope. This event showed that Spitzer, designed to observe objects in the infrared spectrum, is a revolutionary tool in the characterization of exoplanets, and was an innovation that excited researchers (NASA, 2022). Then, in May 2007, the Spitzer Space Telescope was used to create the first map of an exoplanet's surface. In 2016, the Small Telescope for Transiting Planets and Planetesimals in Chile announced that it had found an exoplanet system containing at least seven planets. NASA's Kepler and K2 studies have discovered almost more than 2,600 new exoplanets using the transit method (Betz, 2023). Kepler played a crucial role in the discovery of these planets, many of which could be suitable places for life from outside our solar system. The James Webb Space Telescope, which is known as the most up-to-date and equipped telescope today and over which the most comprehensive studies have been carried out, has the ability to characterize the atmospheres of Earth-sized exoplanets as a large infrared telescope. One of the most important instruments that provide the telescope's qualities is the 'Large Binocular Telescope Interferometer', a NASA-funded instrument used to make high-resolution measurements and measure the absorption of dust orbiting stars (Brennan, 2021).

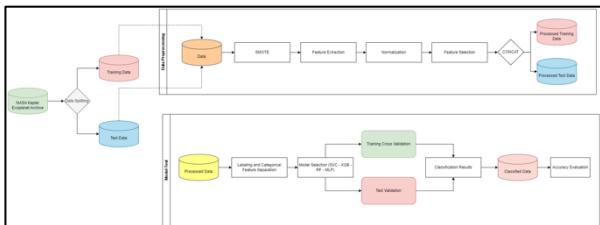
The discovery and characterization of extraterrestrial planets requires precise instrumentation and complex statistical methods. This process involves detecting weak planetary signals and modeling orbital and atmospheric features in detail. But the difficulties of sampling make it even more difficult to understand the characteristics of planetary populations derived from misleading or incomplete samples. The habitable zone does not only describe a certain distance at which a planet like Earth can be habitable, and it does not refer to the only location where habitable planets can exist. For example, the

moons of giant planets in our own solar system can host habitable environments. However, while assessing the habitability of such regions in our own solar system is a difficult task, it is almost impossible to assess the habitability of similar environments in other star systems, and biosignatures in these specific regions may lose their perceptibility. However, with the advancement of technology, the detection of exoplanets by remote sensing systems has become a very popular method. Various studies conducted in this context have contributed to the literature in different fields. For example, in a study, he developed a new variational autoencoder algorithm to detect anomalies in exoplanet properties (Patel, 2023). This algorithm aimed to identify possible habitable exoplanets based on a broad set of features using unsupervised learning techniques. In another study, the proposed ASTRONET was carried out to analyze large and complex astronomical datasets using the deep learning architecture (Jagtap, 2021). Ishaani Priyadarshini and his team detect exoplanets by evaluating light intensity data using artificial intelligence and machine learning algorithms (Priyadarshini, 2021). Another study has developed an automated classification system to distinguish exoplanet transit signals using deep learning techniques (Mathur, 2020). Using data from the Kepler space telescope, Rajeev Mishra has developed a machine learning model that can classify exoplanets based on planet and star characteristics (Mishra, 2017). These studies show that machine learning and deep learning can provide great advantages when used in studies of the habitability of exoplanets. These techniques make it possible to process large and complex data sets produced by space telescopes and analyze properties associated with many planets and stars at the same time. These models help categorize planets as habitable or uninhabitable by detecting complex patterns and relationships. This supports the use of machine learning and deep learning as important tools for the search for habitability on exoplanets and increases our knowledge of potentially habitable worlds beyond our solar system.

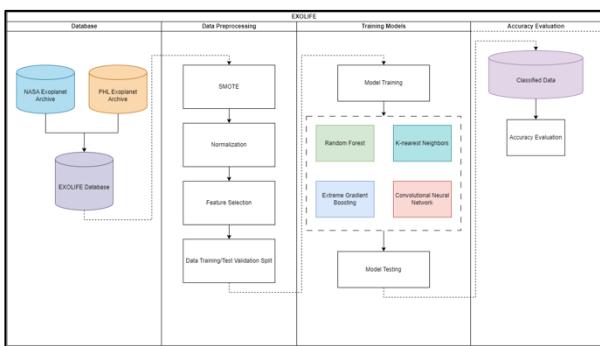
## 2. METHOD

Within the scope of this research, research was first conducted using different machine learning models for the classification of habitable exoplanets. In addition, by analyzing the performance of each model, a comparative study was created on their efficiency (Kong et al., 2017). Although the study highlights both machine learning and deep learning as powerful tools, only machine learning techniques were applied in this research. Deep learning models were not employed, focusing instead on efficient, interpretable machine learning methods. The process followed in the research is shown in Figure 2. Accordingly, the system is divided into (1) database, (2) data preprocessing, (3) training

models, and (4) accuracy evaluation. Second, exoplanet detection was performed using different machine learning algorithms, as shown in Figure 3. The main programming language used in the research is Python. In addition, Pandas, Matplotlib, Scikit-Learn libraries were used.



**Figure 2.** EXOLIFE exoplanet habitability model workflow diagram



**Figure 3.** EXOLIFE exoplanet detection model workflow diagram.

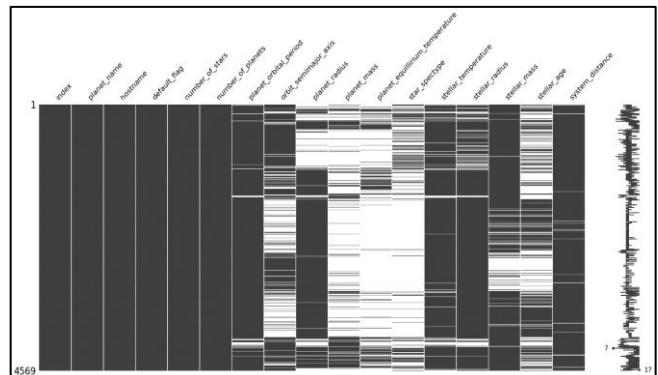
## 2.1. The Data Collection

At the beginning of the research, data collection was carried out from different archives. In this context, data were collected from the NASA Exoplanet Archive, Kepler Mission Data and TESS (Transiting Exoplanet Survey Satellite) archives. While the NASA archive provides a wide range of data, the Kepler Mission and TESS data are particularly focused on observing transits (NASA, 2022). The dataset includes variables such as planetary mass, radius, distance from the host star, and atmospheric composition indicators where available. These data points are instrumental in detecting exoplanets and evaluating their potential habitability. Specific features—such as planetary mass and radius—aid in categorizing planets by type, while the orbital distance and stellar luminosity of host stars are critical for determining habitability zones.

## 2.2. Data Pre-Processing

It is very important to pre-process the data before introducing it to the models used. This process results in high-quality data or precise information, which has a direct impact on the model's ability to learn. Data pre-processing involved multiple stages to ensure high-quality inputs for model training. Initially, missing data

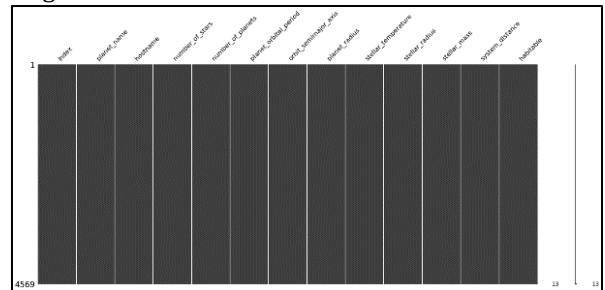
points were managed using imputation. Outliers were identified and handled. Normalization was applied to rescale features to a 0-1 range, standardizing inputs across different measurement scales. Figure 4 shows the first version of the data set.



**Figure 4.** Raw data set

### 2.2.1. SMOTE

SMOTE is an acronym for 'Synthetic Minority Oversampling'. It is a method used to address data imbalances. This method is used to minimize dependency on majority-class values. As visualized in Figure 5, the data became more stable after this stage.



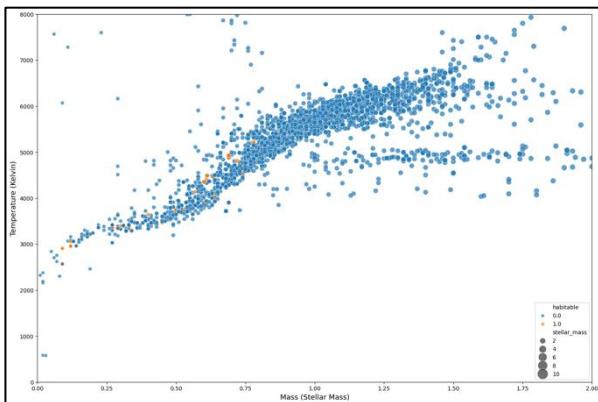
**Figure 5.** Post-SMOTE phase dataset

### 2.2.2. Normalization

The input dataset contains many features with different ranges, and normalization is helpful in bringing them to a similar scale. Values in the range [0, 1] are rescaled.

### 2.2.3. Feature selection

Feature selection is the process of identifying the most important and meaningful features in a data set (Mishra, 2017). This process ensures that the most appropriate features are selected for data analysis or machine learning models. The goal of feature selection is to improve model performance, reduce unnecessary or excess information, and prevent overfitting. In Figure 6, the mass-temperature relationship is visualized.



**Figure 6.** Temperature-mass relationship and habitability

#### 2.2.4. Data clustering

Data clustering is a critical step that is often used in machine learning or data analysis processes. This step is done by dividing the dataset into three main sections: training, validation, and testing sets. The training set is used in the learning process of the model, while the validation set is used to evaluate the performance of the model and set hyperparameters. Finally, the test set is used to assess how well the model adapts to real-world data. By ensuring that the model is trained correctly and adapts to real data, data clustering helps us better understand the predictive ability of the model.

### 2.3. Models

#### 2.3.1. Data exoplanet habitability prediction models

In this study, XGBoost, KNN, RF and LGR algorithms were used to predict the habitability of exoplanets (Jara-Maldonado et al., 2020).

XGBoost: It is a decision tree-based algorithm. This algorithm, which is based on the scikit-learn library, divides the data set into layers and makes optimal predictions. Based on the Gradient Boosting model, it minimizes errors and optimizes results.

K-Nearest Neighbor (KNN): It is a simple supervised learning algorithm. It makes predictions by placing nearby data points in the same class. Methods of calculating distances, such as Euclid or Minkowski, and optimization of the number of neighborhoods are important.

Random Forest (RF): It can be used for classification and regression purposes by combining various decision trees. For each data set, specific data is pulled and parameters are determined to improve the accuracy of the model.

Logistic Regression (LGR): It is an easy-to-apply classification method. With the Maximum Likelihood technique, a line is drawn separating the two classes, and this provides high accuracy rates overall.

#### 2.3.2. Exoplanet detection models

In this research, the process of choosing among various classification models and the stages of training are detailed to predict the states of candidate planets and false positives. Model selection is based on the specific characteristics of each algorithm and the specific requirements of this study.

The Random Forest (RF) model represents an effective batch learning approach in capturing complex data relationships. This model has the potential to perform superiorly, especially when working with imbalanced datasets.

Support Vector Classification (SVC), on the other hand, offers a powerful alternative, especially for nonlinear classification tasks. SVC improves generalization by maximizing classification limits, which increases the stability and accuracy of the model.

Multilayer Perceptron (MLP) can effectively model nonlinear relationships using a deep learning structure. This multi-layered artificial neural network stands out for its ability to process complex data structures.

Finally, the XGBoost model both improves performance and has the capacity to deal with imbalanced datasets by using the gradient boosting technique.

By combining these models, it is aimed to increase the accuracy and reliability of predicting candidate planet states. This approach is intended to make significant contributions to the fields of astronomy and astrophysics.

### 2.4. Accuracy Assessment

The scikit-learn library used has allowed the work to be facilitated through various modules. The main modules and functions in the coding section are as follows:

- cross\_val\_score and KFold are both cross-validation methods.
- Metrics such as accuracy\_score, balanced\_accuracy\_score, precision\_score, recall\_score, f1\_score, and fbeta\_score are used to measure the performance of classification models.
- make\_scorer is used to create a custom score function.
- precision\_recall\_fscore\_support function returns the classification report.
- The roc\_curve, auc, and roc\_auc\_score functions are used for ROC curve analysis.
- The confusion\_matrix function is used to evaluate the performance of a classification model.

These functions are taken as a basis when evaluating accuracy. While determining the extent to which the created software failed, the modules given

above were used and the result evaluation was carried out as a result of the results obtained from these modules.

In order to create a detailed confusion matrix, it is vital to apply 3 accuracy evaluation methods: sensitivity, precision and F-score. To begin with, sensitivity (D) was calculated by dividing the number of true positives within a class prediction by the total number of actual class instances, as shown in Eq. 1.

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (1)$$

Precision (K), on the other hand, is applied by dividing the actual number of positive pixels by the total estimated number of pixels of a class, as seen in Eq. 2.

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

The F measure (F1), which is used to evaluate Sensitivity and Precision in the same criterion, is used to provide the harmonic mean of them as given in Eq. 3. True Positive (DP) and False Negative (YN) variables used in sensitivity and precision calculations are values in the confusion metric that allow data sets to be tested for accuracy in different ways and show the accuracy of the classification made.

$$F1 = \frac{2 \times (D \times K)}{(D + K)} \quad (3)$$

## 2.5. GUI

The Graphical User Interface (GUI) developed within the scope of this research serves as an accessible platform that enables interaction with the machine learning model that performs the prediction of extraplanetary habitability. Built using Python's Tkinter library, the GUI provides an interface that includes input fields for off-planet parameters, a prediction trigger button, and an output screen that provides the model's habitability predictions. In the appendices section, there are interface images of the EXOLIFE application.

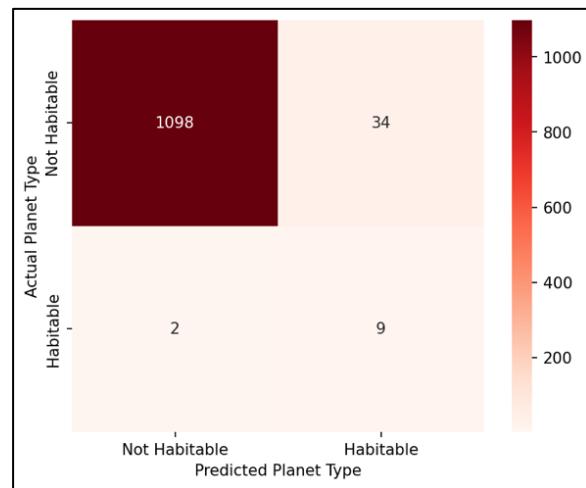
The GUI allows users to input planetary parameters and receive habitability predictions. This user-friendly interface is designed to make machine learning accessible for researchers and astronomers interested in real-time habitability assessments.

## 3. RESULTS & FINDINGS

### 3.1. Evaluation of the EXOLIFE Habitability Classification Model

So, the study results indicate a high overall accuracy of 97.46% for XGBoost in classifying exoplanets with potential habitability. Factors such

Table 1 shows the performance evaluation of the EXOLIFE habitability classification model using different machine learning algorithms. This evaluation includes various metrics that are used to understand the performance of the model. The XGBoost algorithm has the highest training accuracy rate. The model is able to learn the data with 99.32% accuracy during the training phase. At the same time, it has an accuracy rate of 97.46% during the testing phase. The sensitivity metric measures how accurate the model's positive predictions are, and the XGBoost model achieved a good result in this regard at 0.62%. In addition, metrics such as recall and F1 score are also high, indicating that the model provides a good balance of both true positive predictions and false positive predictions. Figure 7 shows the confusion matrix of the XGBoost model.



**Figure 7.** XGBoost confusion matrix

Looking at the results in Table 1, the KNN (K-Nearest Neighbor) algorithm also has high training and test accuracy rates (98.15% and 95.36%). However, the sensitivity and F1 score are lower, indicating that the model can make false positive predictions in some cases and has the potential to make improvements to the correct positive predictions.

The logistic regression model has lower training and test accuracy rates than the other two models (82.60% and 81.63%). The sensitivity and certainty values are moderate, indicating that there is potential to increase the model's accurate positive estimates.

The Random Forest algorithm achieved an excellent result in the training accuracy rate (100.00%) and the test accuracy rate is also high (98.34%) as given in Table 1. The sensitivity and precision values show a more balanced performance than other models, indicating that the model provides a good balance of true positive predictions and false positive predictions.

as planetary size, mass, and orbital distance were critical in habitability estimation, supporting XGBoost's strength in handling diverse feature sets.

This high accuracy and sensitivity (0.90) suggest a significant correlation between these parameters

and the habitability criteria established, confirming the efficacy of machine learning in exoplanet studies.

**Table 1.** Training and test results of habitability models

Model	Training Accuracy	Test Accuracy	Precision	Susceptibility	F1
XGBoost	99.32	97.46	0.62	0.90	0.69
KNN	98.15	95.36	0.57	0.84	0.49
Logistic Regression	82.60	81.63	0.52	0.82	0.49
Random Forest	100.00	98.34	0.62	0.68	0.64

### 3.2. Training Cross-Validation and Planet Detection Classification Model

The present study analyzes the performance of various classification models based on the results of instructional cross-validation. This analysis focuses specifically on the evaluation of Random Forest, XGBoost, Multilayer Perceptron (MLP), and Support Vector Classifier (SVC) models. These models were examined, especially in terms of 'sensitivity', 'precision', F1 score, and general accuracy parameters.

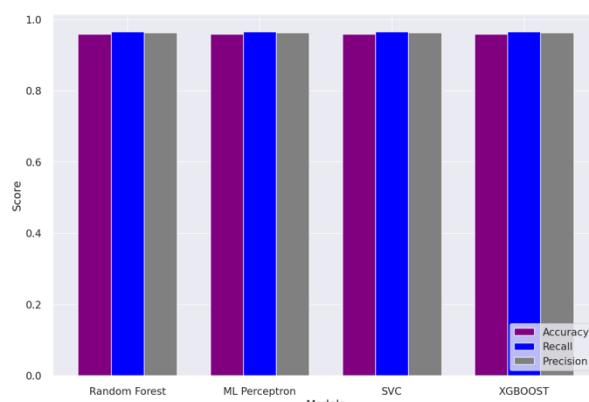
Random Forest (RF): This model demonstrated high sensitivity, recall, and an F1 score for both classes, achieving an overall accuracy of 96%, revealing that it had the capacity to effectively distinguish between "CANDIDATE" and "FALSE POSITIVE" samples.

XGBoost: In line with the Random Forest model, the XGBoost model also demonstrated consistent high sensitivity, precision, and an F1 score for both classes, demonstrating a strong performance with an accuracy rate of 96%.

Multilayer Sensor (MLP): This model was noted for its high sensitivity, precision, and F1 score for both classes, and was among the top-of-the-line models with an accuracy rate of 96%.

Support Vector Classifier (SVC): The SVC model achieved 96% accuracy, exhibiting high sensitivity, precision, and an F1 score for both classes.

As a result, the Random Forest, XGBoost, and Multilayer Detector models were identified as the best performing models with high sensitivity, precision, F1 score, and overall accuracy values, as shown in Figure 8. These findings suggest that these models are reliable options for classification tasks.



**Figure 8.** Training learning outcomes of detection models

### 3.3. Test Verification

This research on machine learning models evaluated the performance of the models, especially in the detection of candidate exoplanets. In the evaluation of the models, an analysis was made primarily on the sensitivity metric based on the research question. In this analysis, the XGBoost model, as shown in Table 2, stands out with a remarkable performance of 96.13%. This model showed a 96.50% sensitivity rate in detecting candidate exoplanets and a 95.64% success rate in identifying false positives, demonstrating its high competence in identifying true positive outcomes. In addition, with a precision of 96.62% and an accuracy of 95.48%, the XGBoost model has also shown an effective performance in minimizing false positive results. On the other hand, the Random Forest (RF) and Support Vector Classifier (SVC) models also achieved strong results, with high overall accuracy scores of 96.20% and 95.83%. These models have also shown impressive performance in accurately identifying true positives and reducing false positives.

**Table 2.** Exoplanet detection model results

Model	Test Accuracy	Susceptibility	Precision
Random Forest	0.962	[0.9559 0.9698]	[0.9761 0.9445]
MLP	0.955	[0.9507 0.9614]	[0.9695 0.9379]
SVC	0.958	[0.9520 0.9664]	[0.9734 0.9397]
XGBoost	0.959	[0.9649 0.9514]	[0.9624 0.9546]

In this context, based on the habitability criterion, the most successful study obtained after all data sets were trained and tested separately for each algorithm belonged to the XGBoost algorithm. The main test accuracy rate of 97.46% is seen as extremely high when studies on exoplanets are evaluated. In addition, the training accuracy rate of 99.32% obtained in the XGBoost algorithm appears to be a difficult rate to achieve. On the other hand, the XGBoost algorithm was well ahead of other algorithms in values such as sensitivity and F1 score, but it showed a result equivalent to the second most successful algorithm, Random Forest (RF), in terms of precision. RF, on the other hand, achieved 100% success by achieving an excellent rate in training accuracy, well above other compared algorithms. RF also stood out as the most successful algorithm in test accuracy rate with 98.34%. However, although the failure of the sensitivity score adversely affected the success of the RF algorithm, it remained constant at an average level in values such as precision and F1 score. On the other hand, KNN and Logistic Regression (LGR) algorithms were successful in a lower class than the other two algorithms. Although KNN did not perform poorly in the training set and main test accuracy rates, its failure in other metrics drew an incomplete image in the general scope. LGR, the most unsuccessful algorithm, was found to be around 80% in accuracy rates and was far away from the other three algorithms.

When the studies of S. Matheur et al. were evaluated, the Random Forest model reached 90%, the SVM model 88% and the KNN model 75%. This 2021 study 92 is seen as one of the leading current planetary detection studies. However, the accuracy rates obtained were well below the accuracy rate realized by us, and were even found to be in the same plane as the LGR model, which was described as the most unsuccessful. Therefore, the success shown in the study is seen at an advanced level considering the overseas studies and it seems that the research has successfully passed the livability determination accuracy rate test.

In another training, exoplanet detection was taken as a basis and the spectra of false positives and true positives were evaluated. In this context, the algorithms included in the study were RF, XGBoost, Multilayer Sensor and Support Vector Classifier. Although each of these has achieved an accuracy success rate of 96%, differences can be observed when examined in detail. The most successful algorithm at the overall level is the XGBoost algorithm. The XGBoost model seems to be quite successful with sensitivity and precision values of 0.95. The Random Forest algorithm, on the other hand, showed positive data with a sensitivity of 0.969 and a precision of 0.944. Although the SVC and MLP models do not seem to be low in general scope, they are below the other two algorithms, with a sensitivity of 0.96 and a precision of 0.93.

**Table 3.** Comparison of results with literature

Year and Author	Research	Method/Parameters	Results
Mislis et al. (2018)	Traversal of exoplanet light curves	Machine Learning Data Rejection Algorithm	Detection Efficiency ~ 80%
Zucker & Giryes (2018)	Detecting periodic transits of exoplanets	Deep Learning	Sensitivity = 0.94
Amin et al. (2018) Zingales & Waldmann (2018)	Detecting Exoplanet Systems Reclaiming the Extraplanetary Atmosphere	Adaptive Neuro-Fuzzy Systems Deep Convolutional Generative Adversarial Networks	Accuracy~81% 300x speed increase over traditional buybacks
Ansdell et al. (2018)	Improvised Exoplanet Transit Classification	Deep Learning	2.0%-2.5% increase in model accuracy and average accuracy
Chintarungruangchara i & Jiang (2019)	Detecting exoplanet transits	Machine Learning and CNN	Accuracy ~98%
Jara-Maldonado et al. (2020)	Research on Transiting Exoplanet Discovery	Machine Learning	Highest Accuracy achieved by Random Forests: 97.82
Sara Cuellar et al. (2022)	Exoplanet Detection with a Combination of Real and Synthetic Data	Deep Learning	Accuracy: 0.95

Exoplanet detection studies are followed closely at home and abroad and the number of researches is increasing. As can be seen in Table 3, the main studies that serve as examples for the general determination are in the 80% band, and the maximum rate is 98%, which is almost equivalent to the rate reached in this research. This clearly shows that the research is at a level that can compete with and even surpass the studies in the professional field and proves how comprehensive the research is.

Our research demonstrates an innovative approach that integrates machine learning approaches with traditional methods used in exoplanet data analysis. This is especially important in the context of processing and analyzing large data sets. The use of machine learning models speeds up the data analysis process and provides more accurate results. This allows for rapid and efficient progress in exoplanet research. In addition, the study shows the limitations of the methods used in exoplanet research and how machine learning

models can be applied to overcome these limitations. Analyses of the models' performance have demonstrated the potential of machine learning to overcome the challenges of exoplanet exploration. In particular, the use of these models to assess the habitability potential of exoplanets opens up new avenues for future research. Our research also takes an interdisciplinary approach to exoplanet science, offering a new perspective at the intersection of astrobiology, astronomy and computer science. Taking into account the complexity and multidisciplinary nature of exoplanet research, in particular, it contributes to the unification of knowledge and techniques in these areas. Transiting Exoplanet Survey Satellite (TESS) data were used in the data set of the study. TESS is a NASA-launched space mission that aims to scan most of the sky to detect thousands of new exoplanet candidates. The use of this data in our research significantly increases the innovative and up-to-date nature of the study.

The fact that the models used have many limitations has made it difficult to train the data sets throughout the process. Although the advantages of the models are more prominent when evaluated in general, some difficulties have prolonged the research process. XGBoost, for example, is a model that stands out for its high performance and fast training times, but it can be susceptible to a tendency to overfit. The Random Forest, on the other hand, is notable for its resistance to overlearning and feature importance, but it may require long training periods in large data sets. Logistic Regression can be effective in linear classification problems, but it can struggle to capture nonlinear relationships. KNN captures the local structure well and provides a clear model, but the cost of computation can increase with large data sets. SVC is useful in nonlinear classification problems, but large data sets may require long training times and correct parameter selection. MLP can learn complex relationships as a deep learning model, but it can be susceptible to overfitting, and hyperparameter tuning is important. Outliers and missing data should be managed in data collection and pre-processing processes. Model selection should be made depending on the characteristics of the data set, and methods such as cross-validation should be used in the accuracy evaluation process.

Apart from these, since exoplanets are a very current subject, it is very difficult to find a data set and reach the desired results. However, this can help to obtain more accurate results by increasing the data. Although the increase is possible with the addition of chemical data, the low number of scientists working on this subject today can be seen as a challenge. However, in this way, the quality of model training can be increased by using more data and accuracy rates can be kept constant in a successful plane.

The results of our study are important both scientifically and practically. Understanding the effectiveness of machine learning models in

exoplanet classification and habitability assessment opens up new horizons in astrophysics and astrobiology. While the comprehensive analysis of the models contributes to the development of the methods used in exoplanet research, the applications of these models, especially on large data sets, allow data analysis processes to be accelerated and more accurate results to be obtained. Using data from innovative observational tools such as TESS provides an excellent opportunity to test the effectiveness and applicability of these models on real-world data.

#### 4. CONCLUSION

This study investigates the use of various machine learning models to enhance the accuracy of exoplanet classification and predict habitability probabilities. The research compares the performance of different algorithms, including XGBoost, Logistic Regression, Random Forest, Multilayer Perceptron (MLP), and K-Nearest Neighbor (KNN), in the context of exoplanet classification. The models were evaluated on a variety of metrics such as training and test accuracy, sentiment, and F1 scores. This comparative analysis is crucial for understanding the potential and limitations of machine learning models in exoplanet research. Our research aims to contribute to the development of machine learning applications in exoplanet science, providing a solid foundation for further work in this area.

Evaluation of the findings obtained on the basis of different algorithms is very important in order to reach the most accurate and comprehensive result. Four different algorithms used in line with the method carried out drew separate conclusions from each other and facilitated concrete determinations in evaluating the processing of the data set specific to exoplanets.

In practical terms, this research helps to speed up and increase the efficiency of exoplanet exploration and assessment. In particular, the rapid and effective detection of habitable exoplanet candidates is critical for future space exploration and potentially humanity's efforts to colonize space. The findings of the research could provide important decision-making tools on issues such as space mission planning and prioritization of exoplanet observations. Furthermore, this interplay between machine learning and astrophysics could inspire innovative research in both fields and shape the direction of future scientific discoveries. The study can be considered as an important step in shaping the future of exoplanet science.

#### 4.1 Recommendations

We suggest several ways to enhance the use of machine learning in discovering exoplanets. Firstly, employing a variety of machine learning algorithms can lead to more accurate and thorough classifications of exoplanets and assessments of their

habitability. While our study focused on models like XGBoost, Random Forest, Multilayer Perceptron (MLP), and K-Nearest Neighbor (KNN), we believe that more advanced techniques, such as deep learning, could offer additional benefits. Specifically, convolutional neural networks and recurrent neural networks could be particularly effective in analyzing visual and time-series data. These algorithms are likely to be key in better understanding and managing the complex and varied data associated with exoplanets.

Second, the inclusion of data from next-generation space telescopes such as the James Webb Space Telescope (JWST) will broaden the scope of the research and provide more detailed information. The high-resolution spectroscopic data provided by the JWST will allow for more detailed analysis of exoplanet atmospheres and offer new perspectives on habitability assessments. This data could allow machine learning models to make more precise and accurate predictions, helping usher in a new era of exoplanet research.

A third proposal is to estimate the chemical data on the atmospheric and surface compositions of exoplanets. Machine learning models can play a vital role in habitability analyses by analyzing spectroscopic data to predict the presence and concentrations of components in exoplanet atmospheres. This approach will contribute to a faster and more accurate detection of potentially habitable exoplanets. It is also possible for these models to simulate atmospheric and surface conditions to determine whether the conditions necessary for life exist.

Finally, considering that limited data sources on exoplanets pose a challenge, it is recommended to use data augmentation techniques. In addition to real data sets, synthetic data generation or diversification of existing data sets will allow machine learning models to be trained and tested on larger and more diverse data sets. This approach could provide significant benefits, especially in the classification and analysis of rare or little-known exoplanet species.

The implementation of these recommendations will maximize the potential of machine learning applications in exoplanet research and contribute to significant advances in this field. These developments will make valuable contributions to both the scientific community and humanity's effort to understand space.

## Acknowledgment

This study was supported by TUBITAK 2204-A Scientific Research Program.

## Author contributions

E. Yilmaz: Literature review, conclusion and discussion sections, methodology (theoretical framework), contributions to astrophysics interpretations, and project administration.

M. E. Artan: Software development, findings analysis, methodology (algorithm implementation), and astrophysics-related evaluations.

A. B. Yanartaş: Introduction writing, compilation and organization of references, and contributions to the methodology (data collection and preprocessing).

## Conflicts of Interest

The authors declare no conflict of interest.

## Research and publication ethics statement

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

## REFERENCES

- Alei, E., Konrad, B. S., Angerhausen, D., Grenfell, J. L., Mollière, P., Quanz, S. P., ... & Wunderlich, F. (2022). Large Interferometer For Exoplanets (LIFE)-V. Diagnostic potential of a mid-infrared space interferometer for studying Earth analogs. *Astronomy & Astrophysics*, 665, A106. <https://doi.org/10.1051/0004-6361/202243760>
- Angerhausen, D. (2019). Big Data and Machine Learning for Exoplanets and Astrobiology: Results from NASA Frontier Development Lab. In The Tenth Moscow Solar System Symposium (pp. 244-245). <https://meetingorganizer.copernicus.org/EPSC-DPS2019/EPSC-DPS2019-588-1.pdf>
- Bapat, N. V., & Rajamani, S. (2023). Distinguishing Biotic vs. Abiotic Origins of 'Bio'signatures: Clues from Messy Prebiotic Chemistry for Detection of Life in the Universe. *Life*, 13(3), 766. <https://doi.org/10.3390/life13030766>
- Basak, S., Saha, S., Mathur, A., Bora, K., Makhija, S., Safonova, M., & Agrawal, S. (2020). Ceesa meets machine learning: A constant elasticity earth similarity approach to habitability and classification of exoplanets. *Astronomy and Computing*, 30, 100335. <https://doi.org/10.1016/j.ascom.2019.100335>
- Basant, R., Dietrich, J., & Apai, D. (2022). An Integrative Analysis of the Rich Planetary System of the Nearby Star e Eridani: Ideal Targets for Exoplanet Imaging and Biosignature Searches. *The Astronomical Journal*, 164(1), 12. <https://doi.org/10.3847/1538-3881/ac6f58>
- Belenkaya, E. S., Alexeev, I. I., & Blokhina, M. S. (2022). Modeling of Magnetospheres of Terrestrial Exoplanets in the Habitable Zone around G-Type Stars. *Universe*, 8(4), 231. <https://doi.org/10.3390/universe8040231>

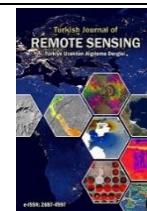
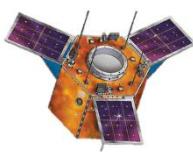
- Claudi, R., & Alei, E. (2019). Biosignatures search in habitable planets. *Galaxies*, 7(4), 82. <https://doi.org/10.3390/galaxies7040082>
- Cuéllar, S., Granados, P., Fabregas, E., Curé, M., Vargas, H., Dormido-Canto, S., & Farias, G. (2022). Deep learning exoplanets detection by combining real and synthetic data. *Plos one*, 17(5), e0268199. <https://doi.org/10.1371/journal.pone.0268199>
- Dai, Z., Ni, D., Pan, L., & Zhu, Y. (2021, September). Five methods of exoplanet detection. In *Journal of Physics: Conference Series* (Vol. 2012, No. 1, p. 012135). IOP Publishing. <https://doi.org/10.1088/1742-6596/2012/1/012135>
- Forestano, R. T., Matchev, K. T., Matcheva, K., & Unlu, E. B. (2023). Searching for Novel Chemistry in Exoplanetary Atmospheres Using Machine Learning for Anomaly Detection. *The Astrophysical Journal*, 958(2), 106. <https://doi.org/10.3847/1538-4357/ad0047>
- Fujii, Y., Angerhausen, D., Deitrick, R., Domagal-Goldman, S., Grenfell, J. L., Hori, Y., ... & Stevenson, K. B. (2018). Exoplanet biosignatures: observational prospects. *Astrobiology*, 18(6), 739-778. <https://doi.org/10.1089/ast.2017.1733>
- Hall, C., Stancil, P. C., Terry, J. P., & Ellison, C. K. (2023). A New Definition of Exoplanet Habitability: Introducing the Photosynthetic Habitable Zone. *The Astrophysical Journal Letters*, 948(2), L26. <https://doi.org/10.48550/arXiv.2301.13836>
- Helled, R., Nettelmann, N., & Guillot, T. (2020). Uranus and Neptune: origin, evolution and internal structure. *Space Science Reviews*, 216, 1-26. <https://doi.org/10.1007/s11214-020-00660-3>
- Huang, J. (2022). Planetary Science Meets Chemistry: Studying Potential Biosignature Gases in Terrestrial Exoplanet Atmospheres (Doctoral dissertation, Massachusetts Institute of Technology). <https://dspace.mit.edu/bitstream/handle/172.1.1/147547/Huang-huangjc-phd-chemistry-2022-thesis.pdf?sequence=1&isAllowed=y>
- Jagtap, R., Inamdar, U., Dere, S., Fatima, M., & Shadoor, N. B. (2021, April). Habitability of exoplanets using deep learning. In *2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)* (pp. 1-6). IEEE. <https://doi.org/10.1109/IEMTRONICS52119.2021.9422571>
- Jara-Maldonado, M., Alarcon-Aquino, V., Rosas-Romero, R. et al. Transiting Exoplanet Discovery Using Machine Learning Techniques: A Survey. *Earth Sci Inform* 13, 573-600 (2020). <https://doi.org/10.1007/s12145-020-00464-7>
- Kaltenegger, L. (2017). How to characterize habitable worlds and signs of life. *Annual Review of Astronomy and Astrophysics*, 55, 433-485. <https://doi.org/10.1146/annurev-astro-082214-122238>
- Kong, Z., Jiang, J. H., Burn, R., Fahy, K. A., & Zhu, Z. H. (2022). Analyzing the Habitable Zones of Circumbinary Planets Using Machine Learning. *The Astrophysical Journal*, 929(2), 187. <https://doi.org/10.3847/1538-4357/ac5c5a>
- Krissansen-Totton, J., Thompson, M., Galloway, M. L., & Fortney, J. J. (2022). Understanding planetary context to enable life detection on exoplanets and test the Copernican principle. *Nature Astronomy*, 6(2), 189-198. <https://doi.org/10.1038/s41550-021-01579-7>
- Meadows, V. S., Reinhard, C. T., Arney, G. N., Parenteau, M. N., Schwieterman, E. W., Domagal-Goldman, S. D., ... & Grenfell, J. L. (2018). Exoplanet biosignatures: understanding oxygen as a biosignature in the context of its environment. *Astrobiology*, 18(6), 630-662. <https://doi.org/10.1089/ast.2017.1727>
- Mishra, R. (2017). Predicting habitable exoplanets from NASA's Kepler mission data using Machine Learning. *Predicting habitable exoplanets from NASA's Kepler mission data using Machine Learning*.
- Novak, R., Bradak, B., Kovacs, J., & Gomez, C. (2023). Search for Exoplanets with a Possible Surface Water Ocean. *Physical Sciences Forum*, 7(1), 19. <https://doi.org/10.3390/ECU2023-14020>
- Priyadarshini, I., Puri, V. A convolutional neural network (CNN) based ensemble model for exoplanet detection. *Earth Sci Inform* 14, 735-747 (2021). <https://doi.org/10.1007/s12145-021-00579-5>
- Ramirez, R. M. (2018). A More Comprehensive Habitable Zone for Finding Life on Other Planets. *Geosciences*, 8(8), 280. <https://doi.org/10.3390/geosciences8080280>
- Ranjan, S., Seager, S., Zhan, Z., Koll, D. D., Bains, W., Petkowski, J. J., ... & Lin, Z. (2022). Photochemical Runaway in Exoplanet

- Atmospheres: Implications for Biosignatures. The Astrophysical Journal, 930(2), 131. <https://doi.org/10.3847/1538-4357/ac5749>
- Schwieterman EW, Kiang NY, Parenteau MN, Harman CE, DasSarma S, Fisher TM, Arney GN, Hartnett HE, Reinhard CT, Olson SL, Meadows VS, Cockell CS, Walker SI, Grenfell JL, Hegde S, Rugheimer S, Hu R, Lyons TW. Exoplanet Biosignatures: A Review of Remotely Detectable Signs of Life. Astrobiology. 2018 Jun;18(6):663-708. <https://doi.org/10.1089/ast.2017.1729>.
- Seager, S. (2014). The future of spectroscopic life detection on exoplanets. Proceedings of the National Academy of Sciences, 111(35), 12634-12640. <https://doi.org/10.1073/pnas.1304213111>
- Seager, S., & Bains, W. (2015). The search for signs of life on exoplanets at the interface of chemistry and planetary science. Science advances, 1(2), e1500047. <https://doi.org/10.1126/sciadv.1500047>
- Soboczenski, F., Himes, M. D., O'Beirne, M. D., Zorzan, S., Baydin, A. G., Cobb, A. D., ... & Domagal-Goldman, S. D. (2018). Bayesian deep learning for exoplanet atmospheric retrieval. arXiv preprint arXiv:1811.03390. <https://doi.org/10.48550/arXiv.1811.03390>
- Thompson, M. A., Krissansen-Totton, J., Wogan, N., Telus, M., & Fortney, J. J. (2022). The case and context for atmospheric methane as an exoplanet biosignature. Proceedings of the National Academy of Sciences, 119(14), e2117933119. <https://doi.org/10.1073/pnas.2117933119>
- Tuchow, N. W., & Wright, J. T. (2020). A Framework for Relative Biosignature Yields from Future Direct Imaging Missions. The Astrophysical Journal, 905(2), 108. <https://doi.org/10.3847/1538-4357/abc556>
- Xin, L. (2022). Exoplanets, extraterrestrial life and beyond: an interview with Douglas Lin. National Science Review, 9(2), nwac008. <https://doi.org/10.1093/nsr/nwac008>



© Author(s) 2024.

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



## Use of Hyperspectral Data for Chlorophyll Estimation Based on Leaf Area Index (LAI) in Wheat

Metin Aydoğdu<sup>1</sup> , Hakan Yıldız<sup>1</sup>

<sup>1</sup> T.C Tarım ve Orman Bakanlığı, Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü, Toprak Gübre ve Su Kaynakları Merkez Araştırma Enstitüsü Müdürlüğü, Ankara, Türkiye

### Keywords

Wheat  
Hyperspectral data  
Index  
Chlorophyll estimate  
Leaf area index (LAI)

### ABSTRACT

Spectral Indices are frequently used in the estimation of green parts of plants, usually developed to reduce the spectral effects of external factors such as atmosphere and soil. The aim of this study was to evaluate the ability of different spectral indices to estimate chlorophyll in wheat according to phenological developmental stages and to calculate their optimal band combinations. In this study, chlorophyll-pigment related indices primarily used in chlorophyll estimation, as well as structural and red edge indices were used. Spectral reflectance values obtained for different phenological periods were correlated with SPAD (Minolta-502) values and Partial Least Square (PLS) model was used to calculate the prominent hyperspectral indices and their optimal band combinations. In this study, the responses and sensitivities of different spectral indices for chlorophyll estimation against LAI change in phenological periods were investigated. As a result, the indices that were least and most affected by saturation changes were revealed. Thus, the power of the indices to predict the chlorophyll content of the canopy was demonstrated. In chlorophyll estimation, NDVI (705,750) was the least affected by the saturation change due to the increasing LAI value in the early period and showed a high correlation ( $LAI=2.63, R^2=0.554$ ). This was followed by Red Edge (740-720), ( $LAI=2.63, 1.722$ ), NDVI (550,780), ( $LAI=2.63, 0.733$ ), SRPI (430,680) ( $LAI=2.63, 0.661$ ), LCCI (705,750) ( $LAI=2.63, 0.554$ ), and NPCI (430,680) ( $LAI=2.63, 0.203$ ). These indices, which showed high correlation in the early period, were in the range of  $R^2=0.836-0.761$ . In Haymana in the late period between 2013-2014 (26 May, 04-12-24 June 2014) LAI values vary between 0.63-3.38 and correlation values are between  $R^2=0.892-0.862$ . MSR (705,750) was the least affected by the saturation change due to the increasing LAI value in the late period and showed high correlation ( $LAI=1.904, 0.906$ ). This was followed by NDVI<sub>670</sub> ( $LAI=1.904, 0.703$ ), NDVI<sub>550</sub> ( $LAI=1.904, 0.651$ ) and LCCI ( $LAI=1.904, 0.448$ ).

## Buğdayda Yaprak Alanı İndekslerine (LAI) Dayalı Klorofil Tahmini İçin Çok Bantlı (Hiperspektral) Verilerin Kullanımı

### Anahtar Kelimeler:

Buğday  
Çok bantlı veri  
İndeks  
Klorofil tahmini  
Yaprak alan indeksi (LAI)

### ÖZ

Spektral indeksler bitkide yeşil kısmın tahmin edilmesinde sıkça kullanılmaktadır. Bunlar genellikle atmosfer ve toprak gibi harici faktörlerin spektral etkilerini azaltmak için geliştirilmiştir. Bu çalışmanın amacı bugday'da fenolojik gelişim evrelerine göre farklı spektral indekslerin klorofil tahmin edebilme yeteneğini ortaya koymak ve bu indekslerin optimal band kombinasyonlarını hesaplamaktır. Çalışmada öncelikli olarak klorofil tahmininde kullanılan klorofil-pigment ilişkili indeksler ve bunun yanısıra strüktürel ve kırmızı kenar (Red Edge) indeksler kullanılmıştır. Farklı fenolojik dönemler için elde edilen spektral yansımaları değerleri SPAD (Minolta-502) değerleri ile korelasyona tabi tutulmuş, öne çıkan hiperspektral indeksleri ve onların optimal band kombinasyonlarını hesaplamak için ise "En Küçük Kısmi Kareler toplamı" (PLS) modeli kullanılmıştır. Bu çalışmada, farklı spektral indekslerin klorofil tahmininde fenolojik dönemlerdeki LAI değişimine karşın, tepkileri ve hassasiyetleri incelenmiştir. Sonuçta saturasyon değişiminden en az ve fazla etkilenen indeksler ortaya çıkartılmıştır. Böylece indekslerin kanopinin klorofil kapsamını tahmin etme gücü ortaya konmuştur. Klorofil tahmininde erken dönemde artan LAI değerine bağlı olarak, saturasyon

### Article Info

Received: 26/09/2024  
Accepted: 04/11/2024  
Published: 30/12/2024

### Citation:

Aydoğdu, M., Yıldız, H. (2024). Use of Hyperspectral Data for Chlorophyll Estimation Based on Leaf Area Index (LAI) in Wheat. Turkish Journal of Remote Sensing, 6(2), 97-111.

\*Corresponding Author: Metin Aydoğdu, metin.aydogdul@tarimorman.gov.tr, +90 312 315 65 60 (175)

değişiminden en az etkilenen ve yüksek korelasyon gösteren indeks NDVI<sub>(705,750)</sub> 'dir (LAI= 2.63, R<sup>2</sup>= 0.554). Bunu sırasıyla Red Edge<sub>(740-720)</sub>, (LAI= 2.63, 1.722), NDVI<sub>(550,780)</sub>, (LAI= 2.63, 0.733), SRPI<sub>(430,680)</sub> (LAI= 2.63, 0.661), LCCI<sub>(705,750)</sub> (LAI= 2.63, 0.554) ve NPCI<sub>(430,680)</sub> (LAI= 2.63, 0.203) takip etmiştir. Erken dönemde yüksek korelasyon gösteren bu indeksler R<sup>2</sup>=0.836-0.761 korelasyon aralığında yer almıştır. Haymana 2013-2014 yılları arasında geç dönemde (26 Mayıs, 04-12-24 Haziran 2014) LAI değerleri 0.63-3.38 arasında değişmekte korelasyon değerleri ise R<sup>2</sup> =0.892-0.862 arasında yer almaktadır. Geç dönemde artan LAI değerine bağlı olarak saturasyon değişiminden en az etkilenen ve yüksek korelasyon gösteren indeks MSR<sub>(705,750)</sub>'dir. (LAI=1.904, 0.906). Bunu sırasıyla NDVI<sub>670</sub> (LAI=1.904, 0.703), NDVI<sub>550</sub> (LAI=1.904, 0.651) ve LCCI<sub>(705,750)</sub> (LAI=1.904, 0.448) takip etmiştir.

## 1. INTRODUCTION

The use of remote sensing technology to determine nitrogen levels in plants is not new. Since it is known that leaf nitrogen concentration depends on the amount of chlorophyll in the plant, studies have focused on determining the leaf concentration of the plant (Haboudane et al. 2008). However, the spectral absorption of chlorophyll and its encapsulation by other plant pigments make it difficult to accurately estimate plant nitrogen levels using remote sensing technology (Hatfield et al.). Plant chlorophyll coverage is affected by other stress factors such as water, light, disease and other plant nutrient deficiencies or toxicity (Penuelas and Filella 1998; Chaerle & Straeten 2000; Barraclough and Kyle 2001). Advanced research on plant indices has been obtained with different combinations of narrow bands among themselves. Field-based studies using hyperspectral reflectance values obtained with handheld spectroradiometry have focused on different plants, both on the leaf and canopy (Blackburn, 1998a,b; Thenkabail et al., 2001; White, Trotter, Brown, & Scott, 2000; Yoder & Pettigrew-Crosby, 1995).

Increasing the sensitivity of the vegetation indices to be used in the calculation of chlorophyll and other pigments is possible with the correct selection of sensitive band regions in hyperspectral imaging (Blackburn, 1998b). As a consequence of the different measurement conditions, there is disagreement on the choice of wavelengths to be used in the determination of plant parameters. Hyperspectral reflectance values recorded under natural conditions in productive crops with high input costs have been published, albeit in limited numbers (Broge & Mortensen, 2002; Filella, Serrano, & Penuelas, 1995; Serrano et al., 2000).

The performance of vegetation indices (VI) used to determine the nitrogen and chlorophyll concentration of plants is related to variables such as the biomass and chlorophyll density of the field and nitrogen uptake Hansen & Schjoerring (2003); Feng et al. (2008); Fava et al. (2009). Therefore, it has become necessary to develop new approaches to determine the nitrogen concentration of the plant, especially in the early stages. Therefore, improved multiple linear regression models using more bands (Miao et al. 2009), partial sum of least squares (PLS) (Hansen & Schjoerring 2003), artificial neural networks (Yi et al., 2007) have been developed.

Red-Edge is important in determining the Chlorophyll content in plants (Clevers et al., 2001; Curran, 1989; Dash & Curran, 2004). Recently, red edge bands on Sentinel-2 have been used in simulation studies to estimate LAI and Chlorophyll (Delegido et al., 2011; Herrmann et al., 2011). Studies have shown that ratio indice (RVI) and normalized differential indice (NDI) using Red Edge bands give very good results in chlorophyll and nitrogen estimation. Gitelson et al., 2003, 2006 developed two different indices called Red Edge (CIred-edge = R800/R710 - 1) and Green-Chlorophyll Indice (CIgreen = R800/R550 - 1) for chlorophyll estimation using NIR (800 nm) bands and red edge bands (710 nm). It was found important that these indices provide accurate approaches by eliminating the negative effects of saturation. Studies have shown that plants show the most typical reflection in the near infrared region (400-1100 nm). Therefore, spectroradiometric measurements in plants are concentrated in the near infrared region (Başyigit & Dinç, 2001). The fact that the reflectance characteristics of plants are directly related to leaf chlorophyll content and mineral content has led to the idea that nutrient deficiencies can also be determined by spectral methods.

The decrease in chlorophyll concentrations in the leaf is due to nitrogen deficiency (Penuelas et al. 1994). In case of severe nitrogen deficiency, plants show more reflection in the red reflection region. Increases in reflectance in the red region indicate chlorophyll deficiency caused by nitrogen deficiency, while decreases in reflectance in the near-infrared region indicate decreases in leaf area index and green biomass (Filella et al. 1995). This situation has been determined by many researchers, especially in cereals (Asrar et al. 1984; Jensen et al. 1990).

To summarise the main objective of the research; the amount of nitrogen in plants is directly related to chlorophyll. Today, classical deterministic classical methods are used for the determination of chlorophyll in plants. This is time-consuming and expensive. It has become necessary to utilise remote sensing technology to estimate the chlorophyll in the plant in a short time and accurately by reducing the effects of factors affecting chlorophyll uptake in the plant. For this purpose, improved narrow band spectral indices were used and their linear regression equations were developed.

## 2. MATERIALS and METHOD

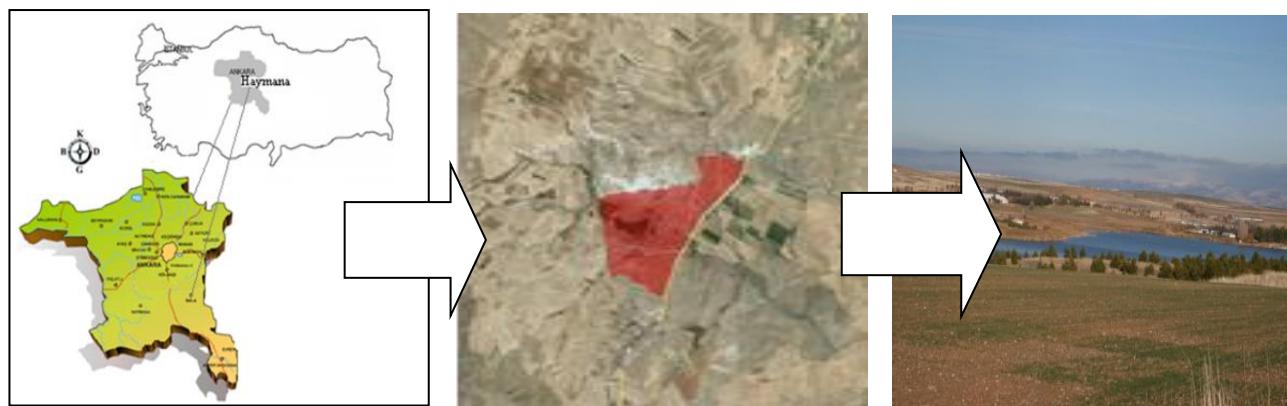
### 2.1. Material

#### 2.1.1. Study area

The study were carried out for one year during the 2013-2014 production season at the İkizce / Haymana Research-Practice Farm of the Ankara Field Crops Central Research Institute, located in the south-west of Ankara, in an area with a continental climate, dry and hot in summer and cold and rainy in winter (Figure 1). The test area is between 39° 12' -

43° 6" north latitude and 35° 58" -37° 44" east longitude.

The project area is located in the south of Ankara province, within the borders of Haymana district center, at the 22nd km of Haymana-Gölbaşı State Highway, with Topaklı village in the northwest and İkizce village in the southwest, and covers an area of 968.3 ha. The slope of the land varies between 2-15%. The altitude of the area where the meteorological station in the farm is located is 1070 m. The land is between 1028-1132 meters above sea level. The main crops grown in the region are wheat and barley.



**Figure 1.** Study area

#### 2.1.2. Climate characteristics of study area

To evaluate the climate of the study area, according to the 20-year data of İkizce station, the average annual temperature of the area is 10.0 °C. The average highest temperature is 18.5 °C in August and the average lowest temperature is -5.2 °C in January. Annual precipitation is 398.7 mm. The wettest month is December with 53.8 mm and the driest month is August with 13.8 mm. Annual precipitation distribution is 133.8 mm in spring (33.6%), 58.2 mm (14.6%) in summer (14.6%), 84

mm (21.1%) in autumn (21.1%), and 122.7 mm (30.8%) in winter (Anonymous, 2005).

Frost is quite severe in Ankara and its region. The average number of frosty days is 85 days. Early and late spring and fall frosts coincide with certain calendar days. These days are likely to be April 20 in the spring and every day in November in the fall. Hail usually falls in the spring, in April and May. It can be large and severe enough to damage fruit and other crops. The long-term average climate data for the experimental area are given in Table 1 (DMI, 2011).

**Table 1.** Long-year average climate data for the region (1975 – 2010)

Climate data	MONTHS												Mean
	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII	
Average temperature °C	0.3	2.1	6.2	11.3	16.0	20.2	23.5	23.2	18.7	13.0	6.8	2.2	11.9
Max. temperature, °C	4.3	6.7	11.9	17.2	22.2	26.6	30.2	30.2	26.0	19.6	12.3	6.1	17.7
Min. temperature, °C	-3.1	-2.0	1.1	5.7	9.7	13.1	16.1	15.2	11.9	7.5	2.3	-0.9	6.8
Precipitation, mm	39.2	33.6	36.1	50.0	49.7	35.1	16.0	12.4	18.9	32.5	36.0	42.6	33.5
Average sunshine duration,h	11.1	10.4	10.6	12.1	12.3	9.3	4.1	3.2	4.2	7.5	8.9	11.0	8.7
Relative humidity, mm	72	71	60	58	58	50	37	35	41	57	70	79	57.3
Evaporation, mm	-	-	-	103.0	146.6	200.0	254.2	244.0	167	95.2	44.3	-	104.5
Wind speed, m s <sup>-1</sup>	1.2	1.3	1.4	1.2	1.3	1.2	1.2	1.2	1.1	1.2	1.3	1.3	1.2

#### 2.1.3. Soil characteristics of experiment area

The soil of İkizce farm lands belongs to the brown soil group. Soil analysis was carried out by Ankara Soil and Water Resources Central Research Institute. According to the results; the soil texture of the test area has a clayey-loamy structure and the

average water holding capacity was found to be 62.50%. EC (Ds m<sup>-1</sup>) value was calculated as 0.610, Total Salinity 0.025%, Ph 7.57 (neutral values), Lime % was calculated as 37.81 (high lime). Organic matter content was low (average 1.22%) and organic carbon content was low (average 0.71%).

## 2.2. Methods

Field studies were carried out in an area representing dry conditions in the experimental field located in the Haymana enterprise of the Central Research Institute of Field Crops, which was left fallow in the previous year. The experiment was carried out on 15 plots by applying 5 different fertilizer doses (0-4-8-12-16 kg/da.) on the data obtained from the sampling points on the plots formed according to the random blocks experimental design with 3 replications in rainfall-dependent irrigation under dry conditions. One control plot without fertilizer was left in each replicate.

The experiment was started by obtaining the trial results obtained between 2013 and 2014 for the first year. The experimental area consists of a total of 15 plots with 3 replications. The width of each parcel is planned as 6 m. and the length as 30 m. The area of each parcel is 180 m<sup>2</sup>. DAP was calculated as 12 kg./da (378 g/31.5 m<sup>2</sup>) per decare as base fertilizer and applied to the plots. In the spring, 33% ammonium nitrate fertilizer was used as top fertilizer, and additional application was made by calculating the amount to be given to the plot based on pure matter. IKIZCE wheat seed was applied at 20 kg/da (378 gr/ 31.5 m<sup>2</sup>). Before planting, soil samples were taken from the experimental area and nutrient and physical analysis were performed.

The experimental plots were arranged in three replications as 6 m.\*30 m. = 180 m<sup>2</sup> and 20 kg (0.630 gr/31.5 m<sup>2</sup>) of IKIZCE wheat per decare was sown with a 24-row pneumatic seeder with a row spacing of 13 cm. Half of the 10 m. plot length determined for each plot was reserved for agronomic sampling (% cover, LAI calculation, wet-dry biomass per m<sup>2</sup>, etc.) to be taken at different growth stages. The remaining half (5 m) was allocated for the calculation of grain yield.

### 2.2.1. Collection and evaluation of hyperspectral data

Spectroradiometric canopy reflectance measurements were made using a portable handheld spectroradiometer between 11 am and 3 pm, when the sun's rays were perpendicular to the earth's surface and there was no cloud cover. With the help of the spectral sensor, the spectral reflections in the plant leaves were performed every 3 nm in the band range from 331 nm to 1141 nm. Measurements were taken from a height of 70 cm. at an angle of 250° to the earth's surface. Before each reading, the spectroradiometer was first calibrated and white and black calibrations were performed.

Before spectral reflectance measurements, the spectroradiometer was calibrated with a standard white board ( $\text{Ba}_2\text{SO}_4$ ). This ensured that all reflection values obtained were minimized by the negative effects of noise and atmosphere.

Spectral reflectance measurements of vegetation were taken from Haymana-İkizce experimental area, three measurements were taken from each plot (from the beginning, middle and end), 45 measurements were taken from 15 plots from three replicates, and 3 measurements were taken from the breeding plot and 48 measurements were obtained in total. Measurements were taken at 8 different phenological stages. These measurements were then averaged and used in the calculation. Spectral measurements were taken at different phenological developmental stages of the plants (Zadoks-Feekes) such as tillering, stalk emergence (Z-35), flowering (Z-54), spike (Z-74), grain filling (Z-84) and grain tying (Z-92) (Table 2).

Before the readings, at least three readings were taken from each plot (at the beginning, middle and end of the plot) with the device, which went through signal testing, automatic integration time adjustment and white and black calibration stages, and the collected reflectance values were stored in the device as raw data with .dvp extension. This raw data was then imported into the computer as .csv so that it could be opened and processed in Excel. A special software was used for this. These raw data collected were subjected to an internal organization and the reflectance values obtained from the plots were averaged and made ready to be processed for use in vegetation indice formulas.

**Table 2.** Different growth stages and classification scales sampled during the 2013-2014 vegetation period in Haymana

<b>Phenological Period</b>	<b>Sampling Dates</b>	<b>Period</b>	<b>Zadoks Skalası</b>	<b>Feekes</b>
Early Period	March 19, 2014	Emergence Period	10-19	1
	March 26, 2014	Tillering Period	21-25	2
	April 03, 2014	End of Tillering Period	26-29	3
	April 22, 2014	Beginning of the bolting	30	4-5
Late Period	May 13, 2014	Bolting Period	31-39	6-7-8-9
	Mayis 22, 2014 - Mayis 26, 2014	New formation of the flag leaf ,Spiking, Flowering	40-69	10
	June 04, 2014	Beginning of the Milk Formation Period	70-77	11
	June 12, 2014	Dough Formation Period and hardening of the grain	80-87	11.2
	June 24, 2014	Hardening and Maturation of the Grain , Start of Ripening	91-92	11.3-11.4
	July 22, 2014	Harvest	99	11.4

### 2.2.2. Measurement of nitrogen content by chlorofilometer (SPAD 502, Minolta)

Fischer (2001) reported that the chlorophyll content of leaves reflects their photosynthetic capacity and Yadava (1986) reported that there was a linear relationship between SPAD values and the amount of chlorophyll contained in the leaves at the time of reading. This system is based on the indirect determination of chlorophyll content and nitrogen content by measuring the green color of the leaves.

Chlorofilometer (SPAD 502, Minolta, Spectrum Technologies Inc.) was used to determine the chlorophyll content. The SPAD meter emits light at two different wavelengths (650 nm and 950 nm) and is calibrated basis on the uptake of these rays by chlorophyll (Maas and Dunlap 1989, Minolta, 1989).

SPAD has been developed to measure the amount of chlorophyll in the leaves of the plant, so that it is possible to determine the amount of additional fertilizer required. The amount of chlorophyll is an indicator of the amount of nitrogen. An increased SPAD value is an indication of a healthy plant. SPAD measures the relative amount of chlorophyll a plant has using two wavelengths. Chlorophyll readings in the plant reach peak values in the blue region (400-500 nm) and in the red region (600-700 nm).

The basis of the method is to determine the relationship between leaf chlorophyll levels and nitrogen nutrition status of the plant. In this method, the chlorophyll readings obtained by SPAD meter are converted into NSPAD values by normalising the SPAD values due to the changes in environmental factors on the genotypes. Drought or disease or lack of any nutrients in farmers' fields can cause chlorophyll depletion and discoloration. Therefore, in nitrogen fertilizer trials for calibration purposes, the SPAD value should be converted to NSPAD value. In any fertilizer trial, the percentage value obtained by dividing the SPAD reading of the same genotype in the plots fertilized at different amounts within the

trial by the highest SPAD value (chlorophyll reading) reading of the plant obtained by using the highest fertiliser dose in the same plot is called NSPAD value. Calibration equations are obtained from these values. In farmers' practices, control strips with the nitrogen level corresponding to the highest yield level are formed in practice, and the values read from these strips are subjected to normalisation process and the necessary supplementary nitrogen requirement for the remaining parts of the field is determined.

### 2.3. Testing the Performance of Vegetation Indices for Chlorophyll Estimation

PLS (Partial Least Sum of Squares) Regression Model was used to reveal the important wavelengths that stand out in chlorophyll estimation. To determine the chlorophyll concentration in the plant according to different developmental stages (Early-Late-Full Year), the correlation values between the chlorophyll value calculated by using the vegetation indices from the plots in the experiment and the measured chlorophyll (SPAD) concentration were examined. In the experiment, a total of 18 different Vegetation Indices were calculated in different band combinations to be used in chlorophyll estimation in wheat (Table 3). For each indice, the accuracy and performance of the model were tested by calculating the  $r^2$ , Sum of Squares of Error (RMSE) values and Relative Error % (% RE) obtained from the correlation model with leaf chlorophyll (SPAD) concentration.

**Table 3.** Vegetation indices used in chlorophyll estimation

Indice	Formula	Literature
NDVI <sub>670</sub>		Original formula
NDVI <sub>550</sub>		Original formula
NDVI <sub>(705,750)</sub>	NDVI=(R <sub>750</sub> -R <sub>705</sub> )/(R <sub>750</sub> +R <sub>705</sub> )	Original formula
MSR <sub>705,750</sub>	MSR(705,750)=[(R <sub>750</sub> /R <sub>705</sub> )-1]/[(√R <sub>750</sub> /R <sub>705</sub> )+1]]	Original formula
MCARI <sub>(705,750)</sub>	MCARI(705,750)=(R <sub>750</sub> -R <sub>705</sub> )-0.2(R <sub>750</sub> -R <sub>550</sub> )(R <sub>750</sub> /R <sub>705</sub> )	Original formula
TCARI/OSAVI	3[(R <sub>700</sub> -R <sub>670</sub> )-0.2(R <sub>700</sub> -R <sub>550</sub> )(R <sub>700</sub> /R <sub>670</sub> )]/[(1+0,16)(R <sub>750</sub> -R <sub>705</sub> )/(R <sub>750</sub> +R <sub>705</sub> +0,16)]	Haboudane et al. (2002)
OSAVI (Optimized SAVI)	OSAVI =(1+0,16)( R <sub>750</sub> -R <sub>705</sub> ) / ( R <sub>750</sub> +R <sub>705</sub> +0,16 )	Waldner et al. (2015)
TCARI	TCARI=3[(R <sub>700</sub> -R <sub>670</sub> )-0.2(R <sub>700</sub> -R <sub>550</sub> )(R <sub>700</sub> /R <sub>670</sub> )]	Haboudane et al. (2002)
MCARI/OSAVI	[(R <sub>750</sub> -R <sub>705</sub> )-0.2(R <sub>750</sub> -R <sub>550</sub> )(R <sub>750</sub> /R <sub>705</sub> )]/[(1+0,16)(R <sub>750</sub> -R <sub>705</sub> )/(R <sub>750</sub> +R <sub>705</sub> +0,16)]	Original formula
GREEN INDEKS (G)(Green Indice)	GI= R <sub>554</sub> / R <sub>677</sub>	Smith et al. (1995)
SRPI (Simple Ratio Pigment Indice)	SRPI= R <sub>430</sub> / R <sub>680</sub>	Penuelas et al.(1994)
RVI (Ratio Vegetation Indice)	RVI= (R <sub>790</sub> :R <sub>810</sub> ) / (R <sub>640</sub> :R <sub>660</sub> )	Jacobsen et al. (1998)
RDVI (Renormalized Difference Vegetation Indice)	RDVI = (R <sub>800</sub> -R <sub>670</sub> ) / (R <sub>800</sub> +R <sub>670</sub> ) <sup>0.5</sup>	Roujean and Breon (1995)
SIPPI (Structural insensitive Pigment indice)	SIPPI = ((R <sub>800</sub> -R <sub>445</sub> ) / (R <sub>800</sub> + R <sub>680</sub> )	Penuelas et al. (1995a)
NPCI ((Normalized Pigment Chlorofil Indice)	NPCI = (R <sub>680</sub> -R <sub>430</sub> ) / (R <sub>680</sub> +R <sub>430</sub> )	Penuelas et al. (1995b)
LCCI (Leaf and Canopy Chlorophyll Indice)	LCCI = (R <sub>750</sub> -R <sub>705</sub> ) / (R <sub>750</sub> + R <sub>705</sub> )	Gitelson ve Merzlyak 1994b
NVI (New Vegetatation Indice)	NVI = (R <sub>777</sub> -R <sub>747</sub> ) / (R <sub>673</sub> )	Gupta, et. al. 2001
ARI (Antocyanin Reflectance Indice)	ARI = (1/R <sub>550</sub> )-(1/R <sub>700</sub> )	Zarco-Tejada et al. 2005
Red Edge (750-700)	R <sub>750</sub> - R <sub>700</sub>	Gitelson & Merzylak (1996)
Red Edge (740-720)	R <sub>750</sub> - R <sub>700</sub>	Gitelson & Merzylak (1996)

#### 2.4. Statistical Analyses And Regression Model Establishment in Chlorophyll Prediction

Reflectance readings obtained from the test area every 3 nm in the band range 331-1141 nm. were used to calculate the spectral indices formulated according to single and dual band combination. As a result, the indices obtained from replicates I, II and III from the experimental area, especially the indices used in the literature and used in chlorophyll estimation, were used in the regression model to be developed to calculate the chlorophyll (SPAD) concentration in the plant.

In addition, different vegetation indices developed to reveal the chlorophyll tracking of wheat at different growth stages were used. In this respect, the developmental stages of wheat are analysed in two parts. Firstly, the period of 1-9 weeks (Feeks 1-9) when the plant did not completely cover the soil surface was considered as the early period, and the second period of 40-11 weeks (Feeks 10-11.2) when the canopy completely covered the soil was considered as the late period.

The results were calculated separately for each period, as well as for the whole year. Correlation and regression analyses were performed using SPSS-16.0 software. To evaluate the performance of the model, the correlation ( $R^2$ ) differences between the

indices and chlorophyll concentration were compared. The sum of squared errors (RMSE) and relative error percentage (RE %) were calculated. It was concluded that vegetation indices with higher  $R^2$  values and lower RMSE and RE % values were effective in calculating plant chlorophyll concentration. The sum of squared errors (RMSE) (1) and the relative error percentage (RE %) (2) are calculated by the following equation.

*The sum of squared errors (RMSE)*

$$\sqrt{\frac{\sum_{i=1}^n (y_{obs,i} - y_{model,i})^2}{n}} \quad (1)$$

*The relative error percentage RE(%)*

$$\frac{\text{The sum of squared errors (RMSE)}}{y_{mean,i}} * 100 \quad (2)$$

In Formula ;  $y_{obs,i}$  = Observed Value (SPAD)

$y_{model,i}$  = Value estimated from equation

$y_{mean,i}$  = Average Chlorophyll Value

n = Number of Samples Used in the Experiment

### 3. RESULTS

#### 3.1. Plant indice-chlorophyll relationships according to phenological periods

In the experiment conducted in Haymana location in 2013-2014, the effectiveness of different indices in determining the amount of chlorophyll of the plant was investigated. When the phenological periods were analyzed in terms of months, the highest correlation values were found at the end of the milky stage and the period when the grain started to harden (June 12, 2014-ZADOKS 80-87)

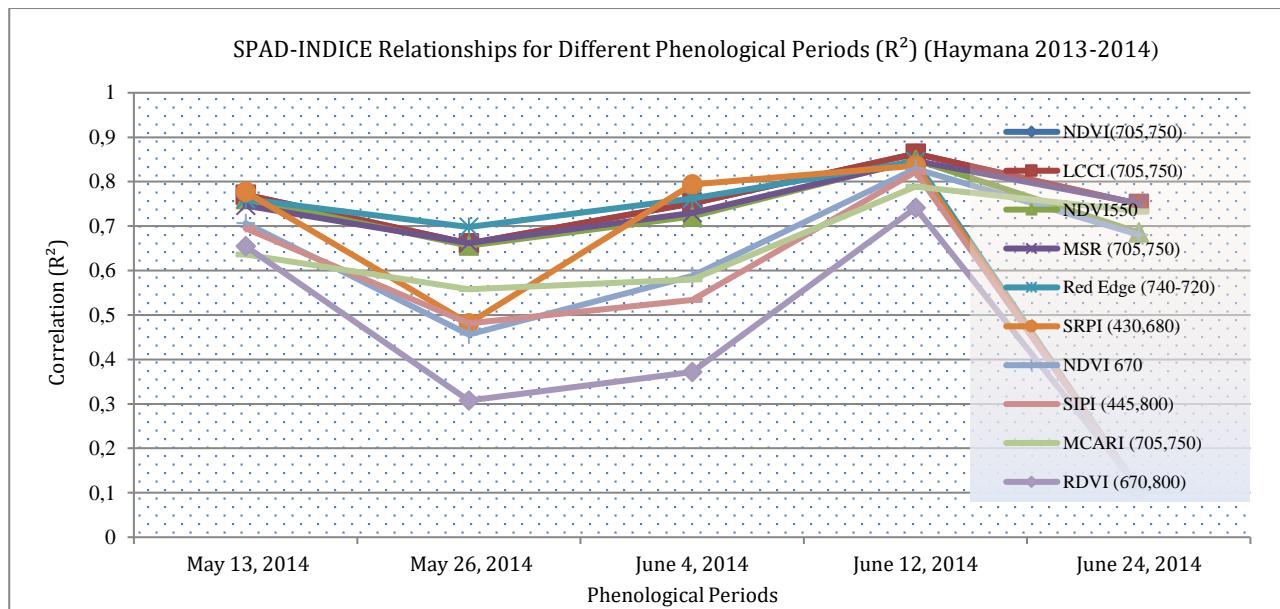
( $R^2= 0.849-0.449$ ). As shown in Table 4, the highest correlation values were found in Leaf Canopy Chlorophyll Index (LCCI) and NDVI<sub>(705-750)</sub>, which are structural indices, at N16 nitrogen dose during the hardening period of the grain ( $R^2= 0.863^{**}$ ). This was followed by Ratio Vegetation Indice (RVI) at flowering (May 26, 2014, ZADOKS 40-69) ( $R^2= 0.859^{**}$ ). Modified Simple Ratio MSR<sub>(705-750)</sub>, Red Edge<sub>(740-720)</sub> and Simple Ratio Pigment Indice (SRPI) of structural indices and chlorophyll pigment indices showed high correlation values ( $R^2= 0.847, 0.846, 0.836$ ) at flowering (June 12, 2014) (Table 4 (Figure 2).

**Table 4.** Prominent indices according to phenological periods (SPAD-vegetation indice relationships) (Haymana 2013-2014)

Index	Phenological Periods				
	May 13, 2014	May 26, 2014	June 04, 2014	June 12, 2014	June 24, 2014
NDVI <sub>670</sub>	0,707**	0,456	0,588*	0,829**	0,681**
NDVI <sub>550</sub>	0,761**	0,656**	0,722**	0,849**	0,686**
NDVI <sub>(705,750)</sub>	0,771**	0,661**	0,751**	0,863**	0,750**
MSR 705,750	0,746**	0,662**	0,730**	0,847**	0,751**
MCARI(705,750)	0,636*	0,558**	0,580	0,789**	0,733**
TCARI/OSAVI	-0,743**	-0,742**	-0,787**	-0,837	0,552*
MCARI/OSAVI	0,607*	0,465	0,467	0,735**	0,699**
GREEN INDEKS (G)(Green Indice)	0,378	-0,523*	-0,329	0,449	0,109
SRPI (Simple Ratio Pigment Indice)	0,777**	0,481	0,794**	0,836**	0,109
RVI (Ratio Vegetation Indice)	0,690**	0,859**	0,770**	0,673**	-0,109
RDVI (Renormalized Difference Vegetation Indice)	0,655**	0,308	0,372	0,741**	0,109
SIP(I)Structural insensitive Pigment indice)	0,695**	0,481	0,534*	0,822**	0,109
NPCI ((Normalized Pigment Chlorofil Indice)	-0,784**	-0,478	-0,797**	-0,839**	-0,109
LCCI (Leaf and Canopy Chlorophyll Indice)	0,771**	0,661**	0,751**	0,863**	0,750**
NVI (New Vegetatation Indice)	0,641*	0,615*	0,613*	0,755**	0,109
ARI (Antocyanin Reflectance Indice)	0,729**	0,779**	0,660**	0,738**	-0,109
Red Edge (750-700)	0,636*	0,355	0,368	0,738**	0,109
Red Edge (740-720)	0,761**	0,698**	0,762**	0,846**	0,108

\* Correlation is at 0.05 significance level.

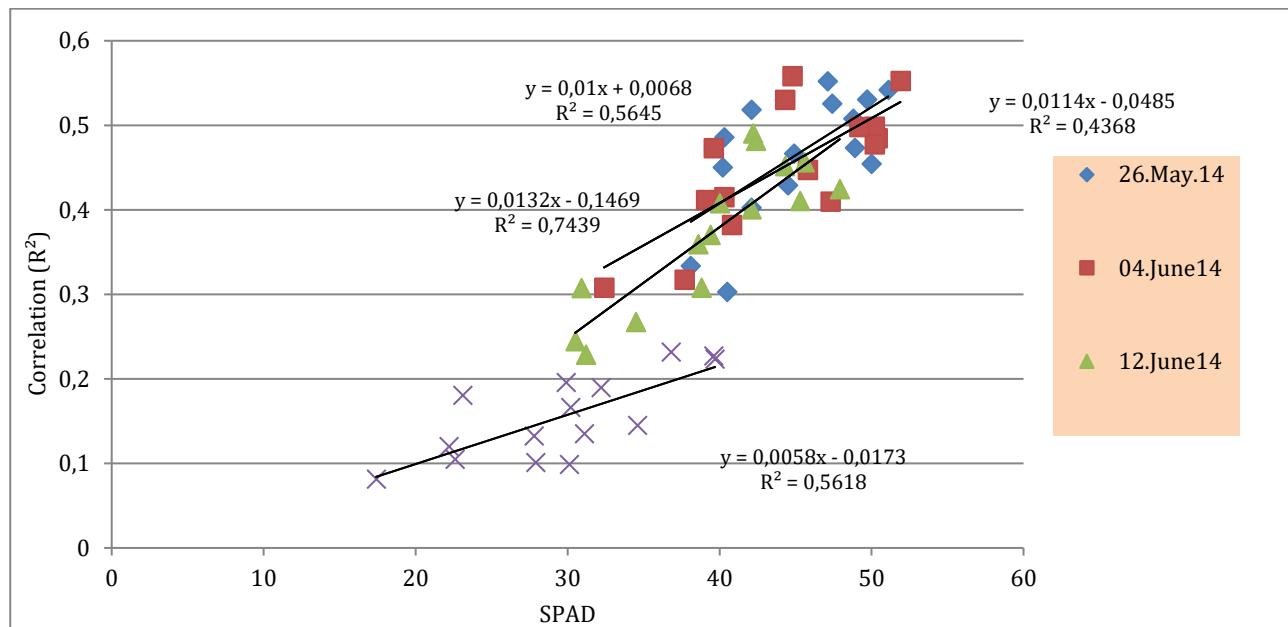
\*\* Correlation is at 0.01 significance level



**Figure 2.** SPAD-indice relationships for different phenological periods (Haymana 2013-2014)

When evaluated according to different phenological periods, the highest correlation values ( $R^2 = 0.744$ ) were found at the end of the milky stage

and the period when the grain started to harden (12 June 2014-ZADOKS 80-87) (Figure 3).



**Figure 3.** Phenological periods effective in chlorophyll estimation (Haymana 2013-2014)

### 3.2. Validation of the Model

A cross-validation study was carried out between the predicted chlorophyll values and the observed values to evaluate the performance between the indice values and SPAD values according to different growth periods. As a result, high-performing indices are ranked from high to low

according to their correlation ( $R^2$ ) values and from low to high according to their root mean square error of the sum of squares (RMSE) values. The prominent indices in chlorophyll estimation were revealed in the early period (May 13, 2014) (Table 5) and in the late period (May 26, June 04-12-24, 2014) (Table 6).

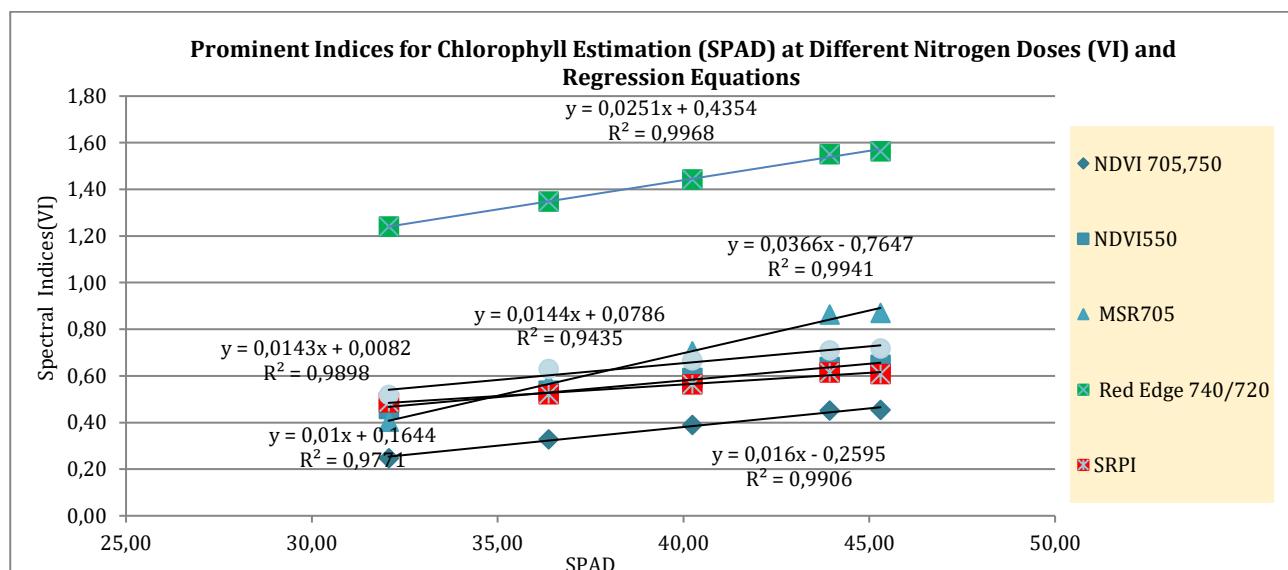
**Table 5.** Prominent indices for chlorophyll estimation in the early period (May 13, 2014) (Cross-validation Results) (Haymana 2013-2014)

Indice	$R^2$	RMSE	% RE
NPCI (680,430)	0,615	1,337	3,068
SRPI (680,430)	0,604	1,354	3,108
LCCI (705,750)	0,594	1,37	3,145
NDVI (705,750)	0,594	1,37	3,145
Red Edge (740/720)	0,579	1,395	3,202
NDVI 550	0,579	1,397	3,207
MSR	0,557	1,433	3,288
ARI (700,550)	0,531	1,472	3,379
NDVI (670,800)	0,499	1,521	3,491
SIPi	0,483	1,548	3,553
RVI	0,476	1,557	3,574
RDVI	0,429	1,626	3,733
NVI	0,411	1,652	3,791
MCARI	0,404	1,661	3,811
Red Edge 750-700	0,404	1,661	3,813
MCARI/OSAVI	0,368	1,711	3,927
Green Indice	0,163	1,992	4,572
TCARI/OSAVI	-0,552	1,44	3,306

**Table 6.** Indices that stand out in chlorophyll estimation in the late period (26 May, 04-12-24 June 2014) (Cross-validation Results (Haymana 2013-2014)

Indice	(R <sup>2</sup> )	RMSE	% RE
LCCI	0,796	4,542	7,57
NDVI <sub>(705,750)</sub>	0,796	5,344	8,906
NDVI <sub>550</sub>	0,781	4,687	7,811
MSR	0,774	5,531	9,218
NDVI <sub>670</sub>	0,743	5,778	9,63
MCARI/OSAVI	0,674	6,168	10,281
MCARI	0,674	6,268	10,447
NVI	0,504	7,623	12,705
RDVI	0,496	7,643	12,739
Red Edge <sub>740/720</sub>	0,494	7,139	11,899
Red Edge <sub>750-700</sub>	0,494	7,596	12,66
SIP1	0,460	8,073	13,455
SRPI	0,412	7,697	12,828
RVI	0,291	7,669	12,782
Green Indice	0,182	9,155	15,259
ARI	0,042	10,331	17,218
TCARI/OSAVI	-0,045	10,05	16,75
NPCI	-0,416	8,203	13,672

The prominent indices (VI) and regression equations for SPAD (Chlorophyll) estimation at different nitrogen doses are shown in Figure 4.

**Figure 4.** Prominent Indexes (VI) and regression equations for chlorophyll estimation (SPAD) at different nitrogen doses

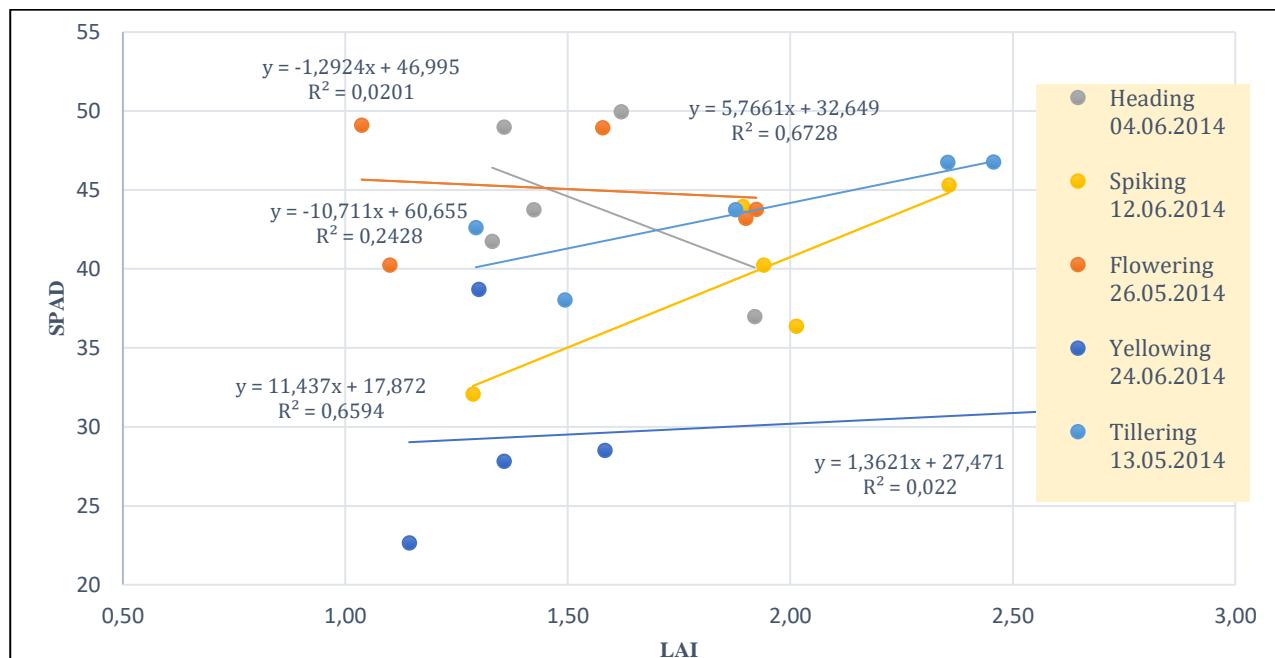
### 3.3. Chlorophyll (SPAD) Leaf Area Index (LAI) and Spectral Indice Relationships for Different Phenological Periods: (Haymana 2013-2014)

The relationships between SPAD-LAI were examined according to the replicate averages in different phenological development periods (Table 7), and the highest coefficient correlation value ( $R^2=0.673$ ) was reached especially in the estimation

of chlorophyll at early emergence (13 May 2014). Due to the increasing saturation effect of LAI, the correlation showed a decreasing trend during the flowering period ( $R^2=0.020$ ) and a slight increase during the grain setting period (04 June 2014) ( $R^2=0.243$ ). It increased again ( $R^2=0.659$ ) at spike (12 June 2014) and decreased again ( $R^2=0.022$ ) at yellowing (Figure 5).

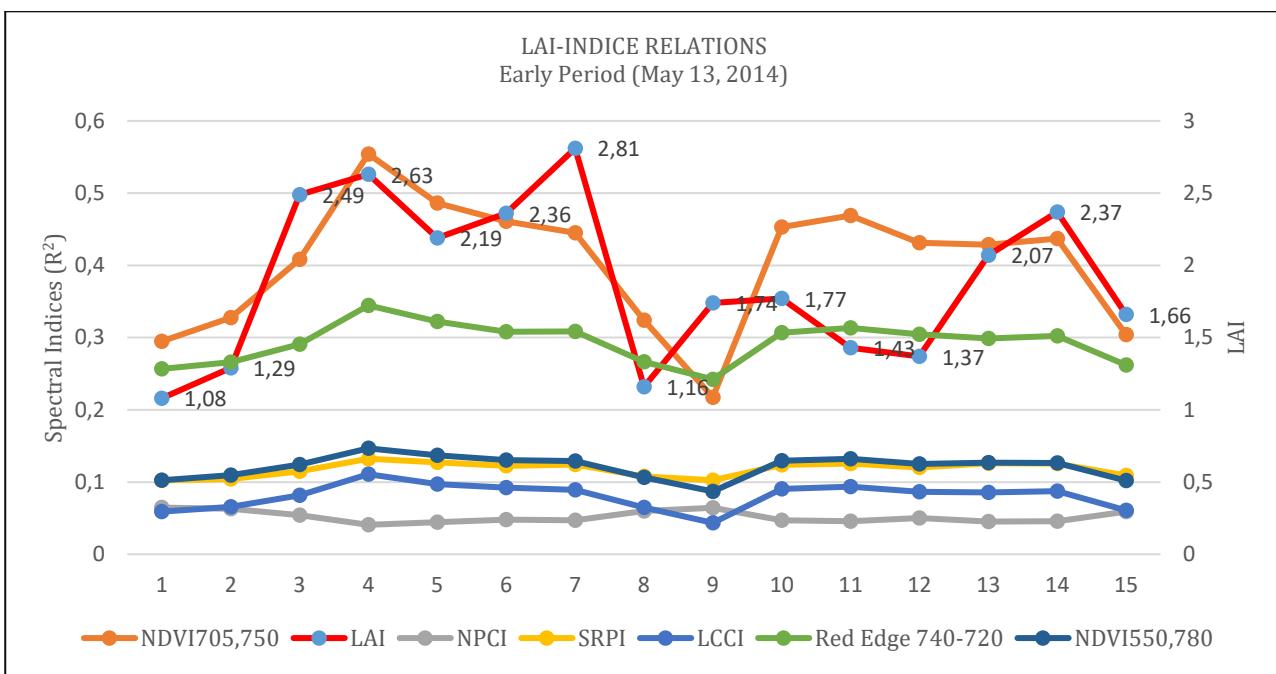
**Table 7.** SPAD-LAI Relationships obtained according to recurrence averages in different phenological periods (Haymana-İkizce, 2013-2014)

Recurrence Average	13.05.2014 (Bolting)		26.05.2014 (Flowering)		04.06.2014 (Heading)		12.06.2014 (Spiking)		24.06.2014 (Ripening)	
	LAI	SPAD	LAI	SPAD	LAI	SPAD	LAI	SPAD	LAI	SPAD
N <sub>0</sub>	1,49	38,03	1,100	40,23	1,92	36,97	1,29	32,07	1,14	22,63
N <sub>4</sub>	1,29	42,60	1,900	43,20	1,33	41,73	2,01	36,37	1,36	27,80
N <sub>8</sub>	1,88	43,73	1,923	43,77	1,42	43,73	1,94	40,24	1,58	28,50
N <sub>12</sub>	2,35	46,73	1,578	48,93	1,36	48,97	1,89	43,94	2,73	30,77
N <sub>16</sub>	2,46	46,77	1,037	49,10	1,62	49,93	2,36	45,31	1,30	38,70

**Figure 5 .** According to different phenological periods SPAD- LAI relationships in wheat (Ikizce) (Haymana 2013-2014)

Many vegetation indices are strongly influenced by the unfavourable reflection properties of the soil at low LAI. As LAI increases, the predictive power of the spectral indices increases as the saturation effect decreases. In this study, the responses and sensitivities of different spectral indices for chlorophyll estimation against LAI change in phenological periods were investigated. As a result, the indices that are least and most affected by saturation changes were revealed. Thus, the power of plant indices to predict the chlorophyll content of canopy was demonstrated. Leaf Area Index values

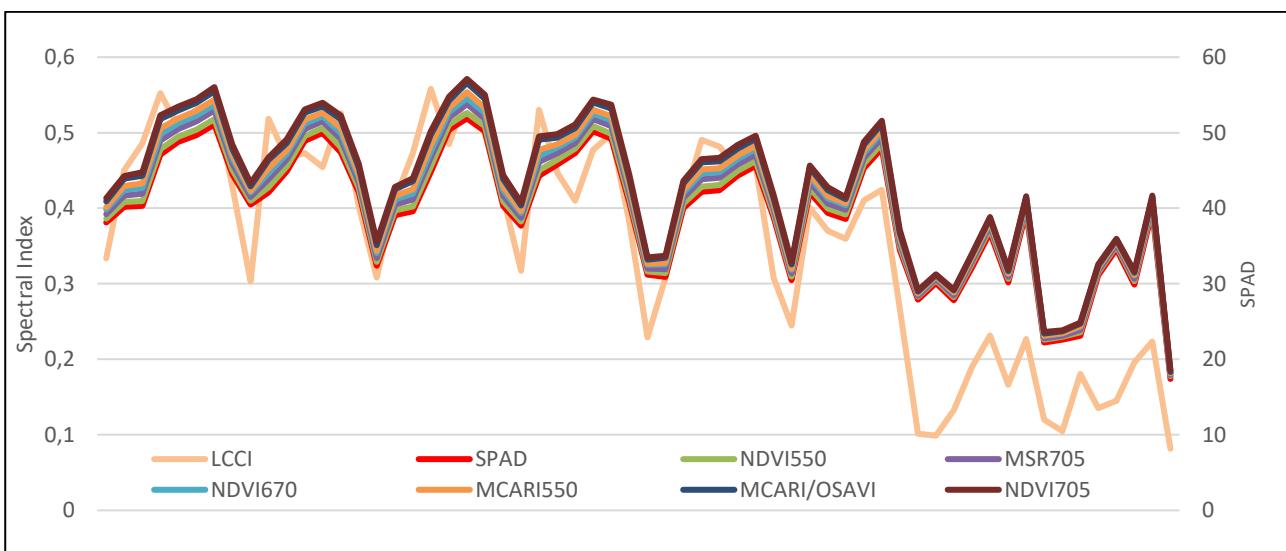
obtained from the experimental area in Haymana'da between 2013-2014 varied between 1.08-2.81 in the early period (May 13, 2014). In chlorophyll estimation, NDVI<sub>(705,750)</sub> is the indice that is least affected by saturation change due to increasing LAI value in the early period and shows high correlation (LAI= 2.63, R<sup>2</sup>= 0.554). This was followed by Red Edge<sub>(740-720)</sub>, (LAI= 2.63, 1.722), NDVI<sub>(550,780)</sub>, (LAI= 2.63, 0.733), SRPI<sub>(430,680)</sub> (LAI= 2.63, 0.661), LCCI<sub>(705,750)</sub> (LAI= 2.63, 0.554) and NPCI<sub>(430,680)</sub> (LAI= 2.63, 0.203). In this early period, highly correlated indices were in the range R<sup>2</sup>=0.836-0.761 (Figure 6).



**Figure 8.** LAI-Spectral indice relations in late period (May 26, June 04-12-24 2014)

When the relationship between SPAD-Indice values was examined in the late period (May 26, 04-12-24

June 2014), it was observed that LCCI was the indice most affected by SPAD readings (Figure 9).



**Figure 9.** SPAD-Spectral Indices relations in late period (May 26, 04-12-24 June 2014)

#### 4. DISCUSSION and CONCLUSION

##### 4.1. Discussion

In recent years, advances in imaging spectrometry have led to new vegetation indices sensitive to chlorophyll concentration, minimizing spectral confusion caused by soil background and atmosphere, resulting in more accurate approaches ((Collins (1978), Baret, Jacquemoud, Guyot, & Leprieur (1992), Demetriades-Shah, Steven, & Clark (1990), Filella & Pen˜uelas (1994), and Mauser & Bach (1994)).

In the early stages of growth, the change in plant biomass and leaf area index is greater, and their effects on reflectance may obscure the effects of

chlorophyll and nitrogen (Haboudane et al. 2002). In the late stages of growth, the effects of these structural changes are less visible as the canopy of the plant completely covers the soil. Fischer (2001) reported that the chlorophyll content of leaves reflects their photosynthetic capacity and Yadava (1986), reported a linear relationship between SPAD values and the amount of chlorophyll contained in the leaves at the time of reading. This system is based on the indirect determination of chlorophyll content and nitrogen content by measuring the green color of the leaves. Martinez and Guiamet (2004), in a study on wheat and maize, reported that SPAD value increased as the proportional water content of leaves decreased. Spectral vegetation indices (VIs), calculated as combinations of near infrared (NIR)

and red reflectance, correlated well with canopy parameters related to biomass and chlorophyll, where photosynthetic activity (APAR) is absorbed and green leaf area index (GLAI) is rich (Elvidge & Chen, 1995; Myneni & Williams, 1994).

In our study, it was observed that the least affected and highly correlated indices were observed in the early period due to the increasing saturation change in the leaves. As a result, it was observed that the spectral indices calculated in this period were in parallel with the results of previous studies and reached high correlation values. With remote sensing techniques, it has gained great importance to keep up with the rapid changes in the climatic calendar in plant development quickly and quickly and to realize the right applications on time. It has become inevitable that inputs should be used more economically and optimally, and should be applied quickly to the field at the required time and in the required amount. In addition, great contributions will be made to the sensitive agricultural practices that have been carried out in this field recently. With this study, it will be possible to determine the amount of nitrogen and chlorophyll in the plant at an early stage and to plan fertilizer application and recommendation programmes accordingly at an early stage.

#### 4.2. Conclusion

Thanks to this study, the chlorophyll estimation power of the predefined narrow and broadband vegetation indices has been revealed, and by combining the available wavelengths, indices with high estimation power have been obtained. Using all bands of the spectroradiometer, vegetation indices with high predictive power of chlorophyll by phenological periods were derived using least partial squares regression (PLS). At Haymana location, the highest correlations between chlorophyll readings (SPAD) and spectral indices were determined at the end of the milking period and the period when the grain started to harden (June 12, 2014-Zadox 80-87) ( $R^2=0.849-0.449$ ). The highest correlation values were found in LCCI and NDVI<sub>(705,750)</sub> at dose N<sub>16</sub> when the grain started to harden ( $R^2=0.863^{**}$ ). Moreover, RVI indice ( $R^2=0.859^{**}$ ), structural indice MSR<sub>(705,750)</sub>, ( $R^2=0.847$ ), red edge indice Red Edge<sub>(740-720)</sub> ( $R^2=0.846$ ) and chlorophyll pigment indice SRPI showed high correlation values ( $R^2=0.836$ ) at flowering (June 12, 2014). When the relationships between SPAD and LAI were examined at the same location, the highest correlation value for chlorophyll estimation was found during the heading period (May 13, 2014) ( $R^2=0.673$ ). It showed a decrease ( $R^2=0.020$ ) during the flowering period (May 26, 2014) due to increased saturation and a slight increase ( $R^2=0.243$ ) during the grain setting period (June 04, 2014). It increased during the spiking period (June 12, 2014) ( $R^2=0.659$ ) and decreased again during the yellowing period ( $R^2=0.022$ ). In chlorophyll

estimation, NDVI<sub>(705,750)</sub> (LAI= 2.63,  $R^2=0.554$ ) was the least affected by the saturation change due to the increasing LAI value in the early period (May 13, 2014), while MSR<sub>(705,750)</sub> (LAI=1.904,  $R^2=0.906$ ) was found in the late period (May 26, June 04-12-24, 2014).

#### Authorship Contribution

The authors contributed equally to the study

#### Conflict 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.

#### REFERENCES

- Asrar G, Fuchs M, Kanemasu ET & Hatfield JL. (1984). Estimating absorbed photosynthetic radiation and leaf area index from spectral reflectance in wheat. *Agron. J.* 76:300–306. [https://doi.org/10.2134/agronj1984.00021962007\\_600020029x](https://doi.org/10.2134/agronj1984.00021962007_600020029x)
- Başayığit, L, Dinç, U., (2001). Toprak Etüd ve Haritalama Çalışmalarında Bilgisayar Teknolojilerinin Kullanımı, Tarımda Bilişim Teknolojileri 4. Sempozyumu,Sütçüimam Üniversitesi, Kahramanmaraş, s 283-291" kaynağından özetlenmiştir.
- Baret, F., Jacquemoud, S., Guyot, G., & Leprieur, C. (1992). Modeled analysis of the biophysical nature of spectral shifts and comparison with information content of broad bands. *Remote Sensing of Environment*, 41, 133– 142. [https://doi.org/10.1016/0034-4257\(92\)90073-S](https://doi.org/10.1016/0034-4257(92)90073-S)
- Barraclough, P. B., & Kyle, J. (2001). Effect of water stress on chlorophyll meter readings in winter wheat. In W. J. Horst, et al. (Eds.), *Plant nutrition-food security and sustainability of agro-ecosystems* (pp. 722–723). Dordrecht, The Netherlands: Kluwer Academic Publishers. [https://doi.org/10.1007/0-306-47624-X\\_350](https://doi.org/10.1007/0-306-47624-X_350)
- Blackburn, G. A. (1998a). Quantifying chlorophylls and carotenoids at leaf and canopy scales: An evaluation of some hyperspectral approaches. *Remote Sensing of Environment*, 66, 273–285. [https://doi.org/10.1016/S0034-4257\(98\)00059-5](https://doi.org/10.1016/S0034-4257(98)00059-5)
- Blackburn, G. A. (1998b). Spectral indices for estimating photosynthetic pigment concentrations: A test using senescent tree leaves. *International Journal of Remote Sensing*,

- 19, 657-675.  
<https://doi.org/10.1080/014311698215919>
- Broge, N. H., & Mortensen, J. V. (2002). Deriving green crop area index and canopy chlorophyll density of winter wheat from spectral reflectance data. *Remote Sensing of Environment*, 81, 45-57. [https://doi.org/10.1016/S0034-4257\(01\)00332-7](https://doi.org/10.1016/S0034-4257(01)00332-7)
- Chærle, L., & Van Der Straeten, D. (2000). Imaging techniques and the early detection of plant stress. *Trends in plant science*, 5(11), 495-501.
- Clevers, J. G., De Jong, S. M., Epema, G. F., Van Der Meer, F., Bakker, W. H., Skidmore, A. K., & Addink, E. A. (2001). MERIS and the red-edge position. *International Journal of Applied Earth Observation and Geoinformation*, 3(4), 313-320. [https://doi.org/10.1016/S0303-2434\(01\)85038-8](https://doi.org/10.1016/S0303-2434(01)85038-8)
- Collins, W. (1978). Remote sensing of crop type and maturity. *Photogrammetric Engineering and Remote Sensing*, 26, 43-55.
- Curran, P.J. (1989). Remote sensing of foliar chemistry. *Remote Sens. Environ.* 30:271-278. [https://doi.org/10.1016/0034-4257\(89\)90069-2](https://doi.org/10.1016/0034-4257(89)90069-2)
- Dash, J., & Curran, P. J. (2004). The MERIS terrestrial chlorophyll index. <https://doi.org/10.1080/0143116042000274015>
- Delegido, J., Verrelst, J., Alonso, L., & Moreno, J. (2011). Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors*, 11(7), 7063-7081. <https://doi.org/10.3390/s110707063>
- Demetriades-Shah, T. H., Steven, M. D., & Clark, J. A. (1990). High resolution derivative spectra in remote sensing. *Remote Sensing of Environment*, 33, 55- 64. [https://doi.org/10.1016/0034-4257\(90\)90055-Q](https://doi.org/10.1016/0034-4257(90)90055-Q)
- Elvidge,C.D., & Z.Chen.(1995). Comparison of broad-band and near-infrared vegetation indices. *Remote Sensing of Environment*,54, pp. 38-48. [https://doi.org/10.1016/0034-4257\(95\)00132-K](https://doi.org/10.1016/0034-4257(95)00132-K)
- Fava,F.,Colombo,R.,Bocchi,S.,Meroni,M.,Sitzia,M.,Fois ,N.,et al.(2009). Identification of hyperspectral vegetation indices for Mediterranean pasture characterization. *International Journal of Applied Earth Observation and Geoinformation*, 11,233-243. <https://doi.org/10.1016/j.jag.2009.02.003>
- Feng,W.,Yao,X.,Zhu,Y.,Tian,Y.C., & Cao,W.X. (2008). Monitoring leaf nitrogen status with hyperspectral reflectance in wheat. *Europe Journal of Agronomy*, 28,394-404. <https://doi.org/10.1016/j.eja.2007.11.005>
- Filella, I., & Pen˜uelas, J. (1994). The red edge position and shape as indicators of plant chlorophyll content, biomass and hydric status. *International Journal of Remote Sensing*, 15, 1459- 1470.
- Filella, I., Serrano, L., Serra, J., & Penuelas, J. (1995). Evaluating wheat nitrogen status with canopy reflectance indices and discriminant analysis. *Crop science*, 35(5), 1400-1405. <https://doi.org/10.1080/01431169408954177>
- Fischer, R.A., (2001). Selection traits for improving yield potential: In Application of physiology in wheat breeding, Eds M.P. Reynolds, J.I. Ortiz-Monasterio, A. McNab., Mexico:CIMMYT p. 148-1159.
- Gitelson, A. and Merzlyak, M.N. 1994b. Spectral reflectance changes associate with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation. *Journal of Plant Physiology*, 143, 286-292.
- Gitelson A.A. & Merzylak, M. N. (1996). Signature analysis of leaf reflectance spectra: Algorithm development for remote sensing. *J. Plant Physiol.* 148:493-500. [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7)
- Gitelson, A. A., Gritz, Y., % Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of plant physiology*, 160(3), 271-282. <https://doi.org/10.1078/0176-1617-00887>
- Gitelson, A. A., Keydan, G. P., & Merzlyak, M. N. (2006). Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. *Geophysical research letters*, 33(11). <https://doi.org/10.1029/2006GL026457>
- Gupta, R.K., Vijayan, D. and Prasad, T.S. 2001. New hyperspectral vegetation characterization parameters, *Advances in Space Research*, 28(1), 201-206, [https://doi.org/10.1016/S0273-1177\(01\)00346-5](https://doi.org/10.1016/S0273-1177(01)00346-5)
- Haboudane,D.j. R.Miller, N.Tremblay, P.J. Zarco-Tejada, & L. Dextraze (2002). Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment* 81 (2-3):416-426. [https://doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4)
- Haboudane, D.Tremblay, N., Miller, J.R. & Vigneault, P. (2008). Remote estimation of crop chlorophyll

- content using spetral indices derived from hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 46, 423-437. <https://doi.org/10.1109/TGRS.2007.904836>
- Hansen, P. M., & Schjoerring, J. K. (2003). Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least square regression. [https://doi.org/10.1016/S0034-4257\(03\)00131-7](https://doi.org/10.1016/S0034-4257(03)00131-7)
- Hatfield J.L., Gitelson,A.A., Scepers,j.s., & Walthall,C.L (2008). Application of spectral remote sensing for agronomic decisions. *Agronomy Journal*, 100, 117-131. <https://doi.org/10.2134/agronj2006.0370c>
- Herrmann, I., Pimstein, A., Karnieli, A., Cohen, Y., Alchanatis, V., & Bonfil, D. J. (2011). LAI assessment of wheat and potato crops by VENμS and Sentinel-2 bands. *Remote Sensing of Environment*, 115(8), 2141-2151.
- Jacobsen, A., K.B. Heidebrecht, A.A. Nielsen (1998): Monitoring Grasslands Using Convex Geometry and Partial Unmixing- a Case Study. Proceedings of 1st EARSel Workshop on Imaging Spectroscopy, Remote Sensing Laboratories, University of Zürich, Switzerland, 6-8 October. Eds. Michael Shaepman, Daniel Schläpfer, Klaus Itten. Pp. 309-316.
- Jensen A, Lorenzen B, Spelling-Ostergaard H & Kloster-Hvelplund E. (1990). Radiometric estimation of biomass and N content of barley grown at different N levels. *Int. J. Remote Sens.* 11:1809–1820. <https://doi.org/10.1080/01431169008955131>
- Maas, S. J., & Dunlap, J. R. (1989). Reflectance, transmittance, and absorptance of light by normal, etiolated, and albino corn leaves. *Agronomy Journal*, 81(1), 105-110. <https://doi.org/10.2134/agronj1989.00021962008100010019x>
- Martinez, D.E. & Guiamet, J.J., (2004). Distortion of SPAD 502 chlorophyll meter reading by changes in irradiance and leaf water status, INRA, EDP Sciences, *Agronomie* 24: 41-46. <https://doi.org/10.1051/agro:2003060>
- Mauser, W., & Bach, H. (1994). Imaging spectroscopy in hydrology and agriculture—determination of model parameters. In: J. Hill, & J. Megier (Eds.), Imaging spectrometry—a tool for environmental observations ( pp. 261–283). Dordrecht, The Netherlands: *Kluwer Academic Publishing*. [https://doi.org/10.1007/978-0-585-33173-7\\_14](https://doi.org/10.1007/978-0-585-33173-7_14)
- Miao,W. & Gastwirth, J. L (2009). A new two stage adaptive nonparametric test for paired difference. *Statistics and Its Interface* 2 213-221. MR2516072. <https://dx.doi.org/10.4310/SII.2009.v2.n2.a11>
- Minolta. (1989). SPAD-502 owner's manual. Industrial Meter Div. Minolta Corp., Ramsey, N.J.
- Myneni, R. B., & Williams, D. L. (1994). On the relationship between FAPAR and NDVI. *Remote Sensing of Environment*, 49, 200– 211. [https://doi.org/10.1016/0034-4257\(94\)90016-7](https://doi.org/10.1016/0034-4257(94)90016-7)
- Penuelas J, Gamon JA, Freedan A, Merino J & Field C (1994). Reflectance indices associated with physiological changes in N and water-limited sunflower leaves. *Remote Sens. Environ.* 46:100118. [https://doi.org/10.1016/0034-4257\(94\)90136-8](https://doi.org/10.1016/0034-4257(94)90136-8)
- Penuelas, J., Filella, I., & Gamon, J. A. (1995). Assessment of photosynthetic radiation-use efficiency with spectral reflectance. *New Phytology*, 131, 291–296. <https://doi.org/10.1111/j.1469-8137.1995.tb03064.x>
- Peñuelas J., Baret F., Filella I. (1995a). Yaprak spektral yansımاسından karotenoid klorofil-a oranını değerlendirmek için yarı deneysel endeksler . *Photosynthetica* 1995 , 221–230. [https://doi.org/10.1007/BF00029464.](https://doi.org/10.1007/BF00029464)
- Peñuelas J., Filella I., Lloret P., Oz FM, Vilajeliu M. (1995b). Elma ağaçlarındaki akar etkilerinin yansımıda değerlendirmesi . *Int. J. Remote Sens.* 16,2727-2733. <https://doi.org/10.1080/01431169508954588>
- Peñuelas, J., & Filella, I. (1998). Visible and near-infrared reflectance techniques for diagnosing plant physiological status. *Trends in plant science*, 3(4), 151-156. <https://doi.org/10.1080/01431169508954588>
- Roujean, J. L., & Breon, F. M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51, Issue 3, 4257(94)00114-3. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)
- Serrano, L., Filella, I., & Penuelas, J. (2000). Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. *Crop Science*, 40, 723–731. <https://doi.org/10.2135/cropsci2000.403723x>
- Smith RCG , Adams J. , Stephens DJ ve Hick PT , NOAA uyqusundan Akdeniz tipi bir ortamda buğday veriminin tahmini, Avustralya Tarım Araştırmaları Dergisi . ( 1995 ) 46 , no. 1, 113 - 125,2-s2.0-0028971783, <https://doi.org/10.1071/AR9950113>.

Thenkabail, P. S., Smith, R. B., & de Pauw, E. (2001). Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. *Remote Sensing of Environment*, 71, 158–182. [https://doi.org/10.1016/S0034-4257\(99\)00067-X](https://doi.org/10.1016/S0034-4257(99)00067-X).

Waldner, F., Fritz, S., Di Gregorio, A., & Defourny, P. (2015). Mapping priorities to focus cropland mapping activities: Fitness assessment of existing global, regional and national cropland maps. *Remote Sensing*, 7(6), 7959-7986. <https://doi.org/10.3390/rs70607959>.

White, J. D., Trotter, C. M., Brown, L. J., & Scott, N. (2000). Nitrogen concentration in New Zealand vegetation foliage derived from laboratory and field spectrometry. *International Journal of Remote Sensing*, 21, 2525–2531. <https://doi.org/10.1080/01431160050030628>.

Yadava, U.L., (1986). A rapid & nondestructive method to determine chlorophyll in intact leaves, *HortScience* 21:1449–1450.

Yi-Hui, L. (2007). Evolutionary neural network modeling for forecasting the field failure data of repairable systems. *Expert Systems with Applications*, 33(4), 1090-1096. <https://doi.org/10.1016/j.eswa.2006.08.032>.

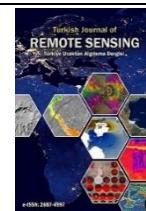
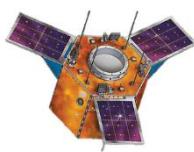
Yoder, B. J., & Pettigrew-Crosby, R. E. (1995). Predicting nitrogen and chlorophyll content and concentrations from reflectance spectra (400–2500 nm) at leaf and canopy scales. *Remote Sensing of Environment*, 53, 199–211. [https://doi.org/10.1016/0034-4257\(95\)00135-N](https://doi.org/10.1016/0034-4257(95)00135-N)

Zarco-Tejada, P.J., Berjón, A., López-Lozano, R., Miller, J.R., Martín, P., Cachorro, V., González, M., De Frutos, A., 2005. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. *Remote Sens. Environ.* 99 (3), 271-287. <https://doi.org/10.1016/j.rse.2005.09.002>



© Author(s) 2024.

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



## Production of WebGL Based Digital Documentation of Ponte Molino Gate From Point Cloud

Büşranur Güvercin<sup>1</sup>, Kasım Erdal<sup>1</sup>, Hasan Bilgehan Makineci<sup>1</sup>, Alberto Guarnieri<sup>2</sup>

<sup>1</sup>Konya Technical University, Faculty of Engineering and Natural Sciences, Konya, Türkiye

<sup>2</sup>University of Padua, CIRGEO-Interdepartmental Research Center of Geomatics, Padova, Italy

### Keywords

Cultural Heritage Documentation WebGL Octree

### ABSTRACT

In recent years, the rapid presentation and sharing of data obtained through photogrammetric techniques have gained significant importance in digital documentation projects. This study focuses on the digital documentation of the historically significant Ponte Molino Gate in Padova, Italy. Dating back to 40–30 BC, this structure was scanned using a terrestrial laser scanner (TLS), resulting in the creation of a comprehensive point cloud. The obtained data was visualized using Potree, a WebGL-based software, and prepared for online presentation. The study highlights Potree's capabilities in processing and visualizing point cloud data within a hierarchical structure, as well as its advantages in facilitating the virtual sharing and interactive exploration of cultural heritage assets. This approach demonstrates broad application potential in fields such as GIS, terrain modeling, and urban planning. The results indicate that Potree effectively reduces point cloud data size by 80% while retaining its hierarchical structure, thereby enabling efficient visualization and presentation. The findings also show that the data was reduced to a minimal file size for online accessibility, improving the preservation and accessibility of cultural heritage by 60%.

## Ponte Molino Kapısının Nokta Bulutundan WebGL Tabanlı Dijital Dokümantasyonunun Üretimi

### Anahtar Kelimeler:

Dokümantasyon Kültürel Miras Octree WebGL

### ÖZ

Son yıllarda fotogrametrik tekniklerle elde edilen verilerin dijital dokümantasyon projelerinde hızlı bir şekilde sunulması ve paylaşılması büyük önem kazanmıştır. Bu çalışmada, İtalya'nın Padova şehrindeki tarihi öneme sahip Ponte Molino Kapısı'nın dijital dokümantasyonu yapılmıştır. MÖ 40-30 yıllarına tarihlenen bu yapı, bir yersel lazer tarayıcı (TLS) ile taraşmış ve kapsamlı bir nokta bulutu oluşturulmuştur. Elde edilen veriler, Potree yazılımı kullanılarak WebGL tabanlı bir ortamda görselleştirilmiş ve çevrimiçi sunum için uygun hale getirilmiştir. Çalışma, Potree'nin nokta bulutu verilerini hiyerarşik bir yapıda işleme ve görselleştirme yeteneklerini, ayrıca kültürel miras varlıklarının sanal ortamda paylaşılması ve etkileşimli olarak incelenmesi sunduğu avantajları ortaya koymaktadır. Bu yaklaşım, GIS, arazi modelleme ve kentsel planlama gibi alanlarda geniş bir uygulama potansiyeline sahiptir. Çalışmanın sonuçları, Potree'nin nokta bulutu verilerini %80 oranında küçülterek hiyerarşik bir yapıda işleme ve görselleştirme yeteneklerini, ayrıca kültürel miras varlıklarının sanal ortamda paylaşılması ve etkileşimli olarak incelenmesi için sunduğu avantajları ortaya koymaktadır. Sonuçlar, elde edilen verilerin düşük dosya boyutuna indirgenerek çevrimiçi erişilebilir hale getirildiğini ve bu sürecin kültürel mirasın korunması ile erişilebilirliğini %60 daha verimli kıldığını göstermektedir.

### Article Info

Received: 16/10/2024  
Accepted: 04/12/2024  
Published: 30/12/2024

### Citation:

Güvercin, B., Erdal, K., Makineci, H.B., Guarnieri, A. (2024). Production of WebGL based digital documentation of Ponte Molino Gate from point cloud. Turkish Journal of Remote Sensing, 6(2), 112-121.

## 1. INTRODUCTION

In recent years, the easy, practical, rapid presentation and sharing of data obtained through photogrammetric methods have become the subject of many research studies. Data presentation and sharing are crucial in digital twins, historical artifacts documentation and smart city projects (Amirebrahimi, Rajabifard, & Sciences, 2012; de Kleijn et al., 2024; Döş & Yiğit, 2023; Jung et al., 2024; La Guardia & Koeva, 2023; Makineci & Erdal, 2021; Nguyen, Nguyen, Vo-Lam, Nguyen, & Tran, 2016). In this context, web-based applications developed to visualize and share data effectively have enabled such data to be easily, practically, and rapidly presented and shared. Additionally, with the contributions of the web graphics library (WebGL), these applications have the potential to simplify the understanding of complex datasets, enhance project management, and improve overall efficiency (Drap, Grussenmeyer, Gaillard, Curtinot, & Seinturier, 2004). WebGL allows for the rapid processing of data that cannot fit into memory directly within a browser, enabling software in this field to provide impressive and interactive visualizations (Drap et al., 2004; Klepárník & Sedláček, 2021).

The presentation of documented cultural structures and artifacts to users in quick and practical ways is as important as the documentation process itself. In a sample study, a historical cultural structure was documented using photogrammetric techniques. Following the cultural documentation process, a WebGL-based virtual tour platform was created to share the obtained data and present all architectural details comprehensively. This platform was made available to users and shared for use in other studies (Fascia, Barbieri, Gaspari, Ioli, & Pinto, 2024). There are many studies similar to this one. The common factor among these studies is their use of self-developed WebGL-based platforms and applications (Klepárník & Sedláček, 2021; Szujó, Biber, Gál, & Szabó, 2023). Another sample study reviewed the creation of a 3D model, point cloud data, and 360° imagery of a cultural heritage artefact using photogrammetric techniques. The data obtained was successfully shared online using the Potree application. The study highlighted that the application effectively facilitates the online sharing of 3D models and point cloud data. Additionally, it emphasized that this WebGL-based visualization is a fast and practical WebGL-based application, particularly noting the benefits of adding images, annotations, and details to the model (Apollonio, Fantini, Garagnani, & Gaiani, 2021). Also, in various studies related to Geographic Information Systems (GIS), cultural heritage documentation, virtual tours, and similar objectives, This application has been frequently employed for sharing obtained data online without the need to develop a WebGL platform (Nguyen et al., 2016; Sánchez-Aparicio et al., 2020). Potree, a web-based visualization tool built on WebGL technology and completed in 2016,

enables the easy visualization and presentation of large-scale point clouds and 3D model datasets within a browser. The application offers both online use in WebGL format and offline use through a desktop version. Potree can be quickly utilized by downloading its open-source library and completing the installation steps. This software is user-friendly, allowing even those with limited experience in 3D navigation to use it effectively. It simplifies the process further with dynamic annotations and predefined animations applied to the datasets. Additionally, a distinguishing feature of the software, compared to other WebGL software, is the ease of use of its technical tools, such as measurement and cross-section capabilities (Gaspari et al., 2023; Jung et al., 2024; Martinez-Rubi et al., 2015; Markus Schütz, 2015).

The primary operational principle of the application is its ability to handle extensive memory-intensive data. This capability relies on Potree's use of a modifiable nested octree (MNO) structure. The modifiability of this structure refers to the dynamic use and scalability of the data organization. One of the main reasons application employs the MNO structure is to progressively organize the dataset, thereby providing users with a more effective way to explore and examine large-scale point clouds (Markus Schütz, 2015).

The unique features offered by the Potree application enable its broad applicability across various fields, such as GIS, terrain modeling, urban planning, and archaeology. The application has become a significant tool for experts and researchers working with large-scale datasets (Markus Schütz, 2015). Potree's areas of application support more effective analysis and sharing of data produced through photogrammetric techniques, thereby enhancing the potential of this technology (Carey, Romero, Laefer, & Sciences, 2021; de Kleijn et al., 2024; Fascia et al., 2024).

In contemporary times, the preservation and accurate documentation of historical, artistic, and architectural cultural artifacts are directly dependent on digital documentation processes (Fascia et al., 2024). Additionally, after the completion of the digital documentation process for cultural artifacts, the creation of digital archives, their accessibility to various users, and the ongoing maintenance of these archives are of great importance (Apollonio et al., 2021; Fascia et al., 2024; Quintilla-Castán, Martínez-Aranda, & Agustín-Hernández, 2022). For the purpose of ensuring that information about digitally documented cultural artifacts is quickly and easily accessible and to serve as a resource for scholars, architects, and restoration experts, the digital documentation of cultural artifacts is shared using software and platforms based on WebGL technology (Apollonio et al., 2021; Dall'Asta, Leoni, Meschini, Petrucci, & Zona, 2019; Masciotta et al., 2021; Sánchez-Aparicio et al., 2020). This situation facilitates the management and maintenance of cultural artifacts and additionally

provides significant support in the planning and monitoring of research activities related to cultural heritage (Fascia et al., 2024).

Sharing digitally documented cultural artifacts on software and platforms built on WebGL technology offers numerous advantages. However, the problems and challenges encountered during this process are essential areas that require investigation (Apollonio et al., 2021; Boutsi, Ioannidis, & Soile, 2019; Szujó et al., 2023). The challenges faced in presenting and sharing large-scale data, the complex stages involved, and the encountered errors can adversely affect the process. This study aims to contribute to and share the digitally documented Ponte Molino Gate, located in Padova, Italy, using Potree. The primary reason for selecting Ponte Molino Gate for this study is its historical significance, dating back to 40-30 BC, making it one of the significant historical artifacts from the Roman period that still exist today. This gate, integrated with a bridge, is one of the two gates from the Roman era that is still actively used today, adding to its value. In line with this aim, the study seeks to examine in detail the working principles and internal dynamics of the Potree application, identify key considerations in the stages of presenting and sharing digital documentation using Potree, address potential errors, and assess the advantages and disadvantages.

## 2. MATERIAL AND METHOD

Ponte Molino Gate stands as one of the most significant medieval historical monuments in Padova (see Figure 1). Currently in active use, the gate and the adjacent bridge derive their name from the 34 watermills that floated on the river in the 1300s. Although these watermills were removed between 1883 and 1884, the historical structure of the Ponte Molino Gate and Bridge has been preserved. This gate, standing 26 meters high, is estimated to have been constructed around 40-30 BC. Despite being damaged numerous times, it has been rebuilt using original materials. Ponte Molino Gate and Bridge are one of the two remaining bridges from the Roman era that are still in use today. Aside from providing access to one of the city's main roads, one of the primary purposes for constructing this gate was for defence, evidenced by its oval arch with a strong tower. The historical significance and narrative of the gate extend beyond this. According to an inscription by Carla Leoni (1812-1874), a figure known for her writings on Padova's walls, it is said that Galileo observed the skies and saw Jupiter's four moons from the tower of Ponte Molino Gate. To ensure the preservation and transmission of this important cultural heritage to future generations, producing a digital twin and documenting the gate is essential. In this context, Ponte Molino Gate was scanned using a terrestrial laser scanner (TLS). Following the scanning process, a point cloud of the historic gate was obtained through data processing.

Upon examining the point data of the historic gate, it was determined that the architectural details of the gate were clearly understandable and sufficient for the digital documentation process. To present and share the obtained 3D point cloud, the data of Ponte Molino Gate was transferred to software.



**Figure 1.** Ponte Molino Gate

### 2.1. Web-Based Visualization Tool

Together with technological advancements in 3D web-based visualization and editing applications, the process of digital documenting and sharing of important structures has rapidly become widespread (Amirebrahimi et al., 2012; Nguyen et al., 2016). Web-based visualizations facilitate the increase and spread of virtual environments such as e-museums, virtual education platforms, and simulation studies, and the use of 3D models contributes to these applications (Makineci & Erdal, 2021). Additionally, virtual tour applications and panoramic videos also aid in enriching virtual environments through visualization technologies. This allows users to visit various locations, experience realistic simulations in a virtual setting, and interactively explore content (Boutsi et al., 2019; Schultz, Kerski, & Patterson, 2008).

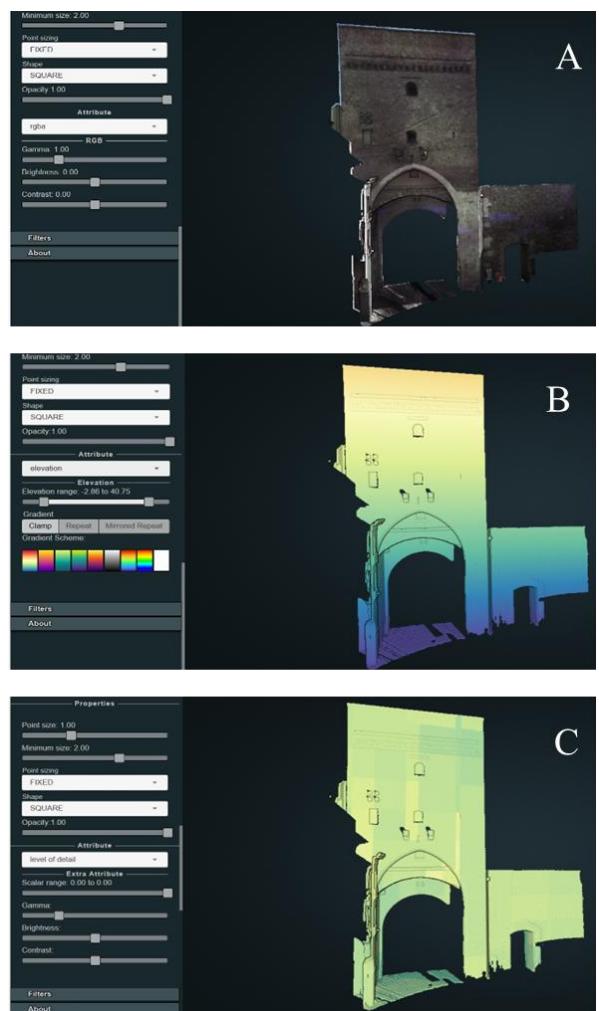
Potree is a JavaScript 3D web viewer that enables the rendering of large point clouds and provides features such as interaction with 3D objects, predefined views, measurements, and cross-sections. This viewer allows users to share and visualize point cloud data in various formats, including popular 3D file formats such as LAS, LAZ, PTX, and PLY. The core structure of the viewer

consists of measurement tools, object views, filter tools, and controls. Additionally, georeferenced annotations are one of Potree's key features, enabling the definition of the position and title of a label within the 3D scene (Gaspari et al., 2023; Markus Schütz, 2015). Another significant feature of the application is the ability to select different point attributes for visualization. This feature provides a considerable advantage in the rapid web-based visualization and presentation of point clouds or 3D models within a single application for various studies and purposes. Additionally, it allows for the integration of spatially distributed technical data into the 3D point cloud, making it useful for conservation and management projects involving digital inventories (Gobbetti & Marton, 2004; Markus Schütz, 2015).

In this study, the point cloud obtained from the TLS of the Ponte Molino Gate was uploaded to the web-based visualization program Potree (Figure 2). Also, Figure 3 shows the visualization of the Ponte Molino Gate using different point attributes on the application.



**Figure 2.** Potree user interface



**Figure 3.** Point attribute coloring (A: RGB, B: Elevation C: Level of detail)

## 2.2. Method

The primary principle of web-based visualization tools hinges on their ability to handle large datasets that do not fit into memory. Potree achieves this capability through its hierarchical octree structure. Potree's octree structure is based on a modifiable hierarchical octree, although it does not provide the functionality to modify the point cloud structure. This section will discuss the operational principle of the visualization tool. Before examining the Potree Octree Structure, it is necessary to review the Modifiable Nested Octree, which forms the foundation of this structure.

### 2.2.1. Modifiable Nested Octree (MNO)

The Modifiable Nested Octree (MNO) structure is a hierarchical data structure that organizes a point cloud by subdividing it into smaller, structured subsamples. At the upper levels of the octree, nodes represent larger spatial volumes with lower point densities, like dividing a large room into broad zones. As the hierarchy progresses to deeper levels, the spatial volume of each node decreases and the points within these nodes become more concentrated,

similar to further dividing each zone into smaller, detailed sections (Markus Schütz, Ohrhallinger, & Wimmer, 2020).

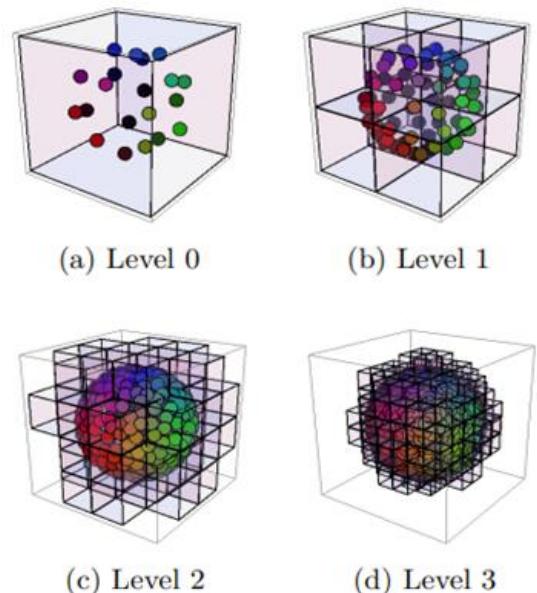
The MNO operates using a nested 128-cell three-dimensional grid to generate these subsamples. Initially, all points are assigned to the root node and each point is allocated to the point first grid cell it occupies. For example, imagine placing marbles into a grid where each cell represents a small compartment; each marble is assigned to the first compartment it touches. If a cell already contains points and the node's total point count is below a predefined threshold, new points are added to this cell. Instead of creating a new grid for every filled cell, a filled array is used to store point data efficiently. This prevents the unnecessary creation of sub-nodes thereby reducing memory usage and speeding up the processing (Scheiblauer, Wimmer, & Graphics, 2011).

## 2.2.2. Potree's Octree Structure

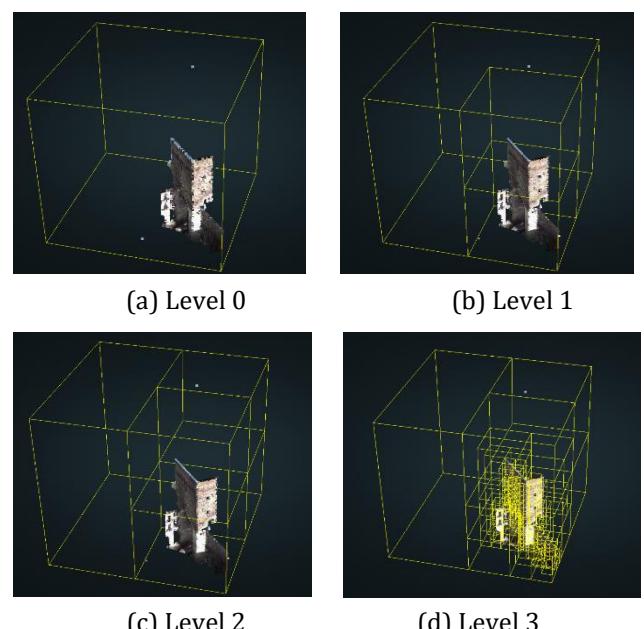
Potree creates a specialized data structure to efficiently handle large amounts of 3D point clouds. The core data structure of Potree is the "Octree." This octree structure hierarchically organizes three-dimensional space (Guarnieri, Vettore, & Pontin, 2005). This structure creates a bounding cell at the general boundaries of large 3D point clouds. This cell must encompass the entire point cloud. The minimum and maximum coordinate values along the x, y, and z axes are determined and fixed for this bounding cell. The bounding cell is then divided into eight equal subcells, enabling fast access and visualization. This hierarchical division continues until the data is partitioned into smaller cells (Markus Schütz, 2015). As a result, each point in the point cloud is placed into a cell within the octree structure, with each cell containing its assigned bounding cell and a list of the points it contains (Figure 4). Thus, the point cloud is represented in a hierarchical structure (M. Schütz & Wimmer, 2015).

The cells constitute the parts, with each part representing a node. At each level, as the size of a node decreases, the point density increases (La Guardia & Koeva, 2023; Rusinkiewicz & Levoy, 2000). Each node can be processed independently, providing a suitable structure for parallel computations. The ability to independently process cells and form parts offers a performance advantage in visualizing and presenting large point clouds (Rusinkiewicz & Levoy, 2000; Markus Schütz, 2015; Wand et al., 2007).

Figure 5 illustrates how the Potree Octree structure is applied to the point cloud. This figure visually explains how the point cloud is subdivided into the octree structure and how each cell is organized.



**Figure 4.** Placing each point of the point cloud into the cell of the octree structure (Markus Schütz, 2015)



**Figure 5.** Application of Potree Octree Structure to Point Cloud

If a node contains a large number of points, the Potree Octree Structure divides the node into smaller parts. If the number of points within the node is small, the node is not further subdivided. Larger nodes represent general boundaries and contain more minor, more specific nodes. This arrangement provides a level of detail (LOD) mechanism. The LOD dynamically adjusts the level of detail by adding or removing nodes based on the viewer's distance to the area being visualized. A more general view is presented as the viewer zooms out while zooming in reveals more details (Scheiblauer, 2014). Thus, Potree optimizes performance and provides a faster experience for

users when processing and visualizing large point clouds. Rapid rendering is significant during the

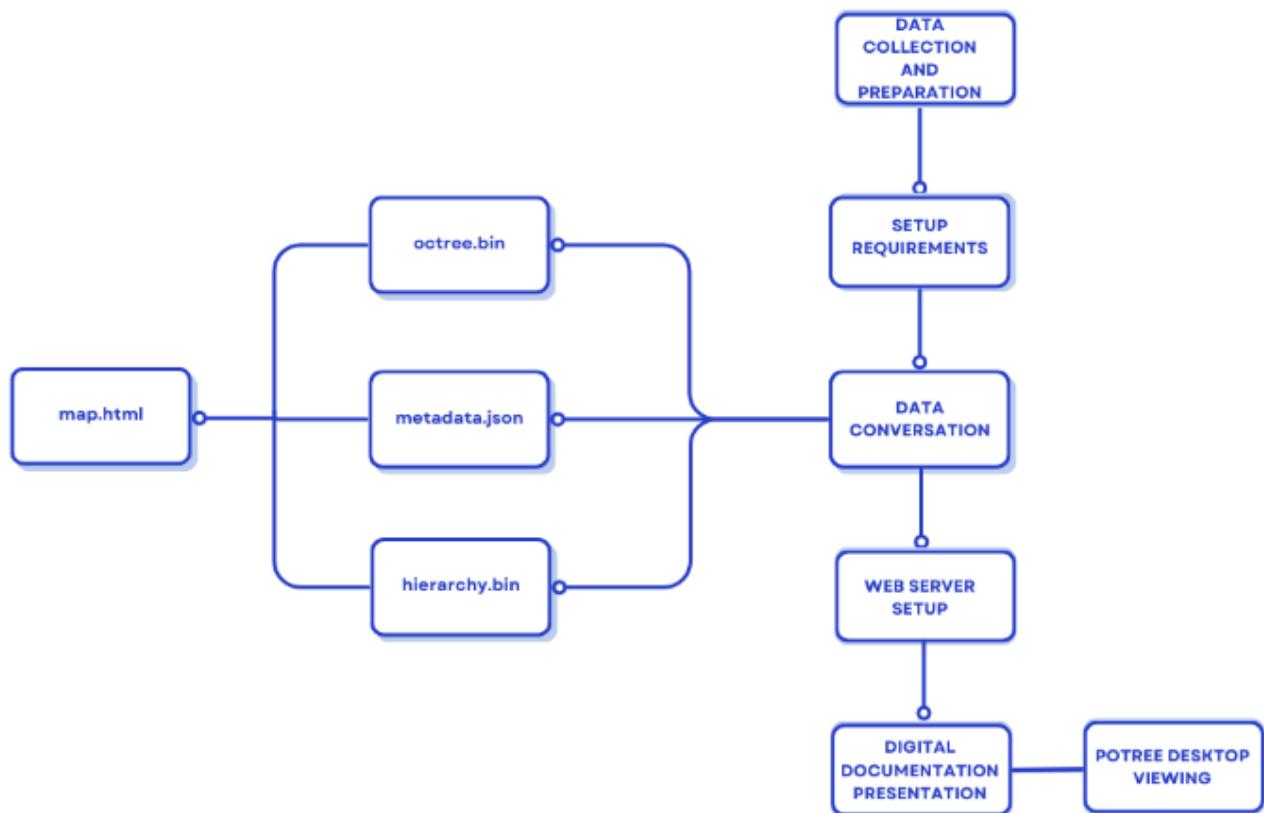
### 3. APPLICATION AND DISCUSSION

#### 3.1. Application

The study presents the WebGL-based digital documentation of the Ponte Molino Gate in two

process of interactively navigating through point data (Wimmer & Scheiblauer, 2006).

stages. In the first stage, the point cloud data was processed using a Potree Converter and converted into the octree structure of the Potree application. In the second stage, the processed data was transferred to a free web hosting platform, making it ready for online presentation (Figure 6).



**Figure 6.** Workflow chart

#### 3.1.1. Conversion of Data into Octree Structure

The Potree application's working principle requires converting the original point cloud into an octree structure, within which the data are hierarchically organized, enabling quick access and efficient processing.

The transformation of the point cloud into an octree structure is accomplished using the Potree Converter. This tool processes, organizes and configures the data to be compatible with the data structures used by Potree, employing various parameters for optimal performance. As an integral part of the workflow, correct configuration and parameter choice in the Potree Converter are crucial for effective visualization of data within the Potree application. The conversion process using the Converter can be conducted in two ways.

The first conversion is performed using the desktop version of Potree, which includes the

Converter. Once the installation is complete, the point cloud data is processed using this tool, which automatically generates the files octree.bin, metadata.json and hierarchy.bin.

In the second conversion method, the transformation process is conducted using the command line. For this process, it is sufficient to install Potree Converter and run it via the command line. The point cloud data is processed using the following command (1), which generates the octree.bin, metadata.json, and hierarchy.bin files:

```
PotreeConverter /path-to-pointcloud-file/pointcloud.las -o /path-to-output-directory
```

In both methods, after the conversion process, an HTML file is created using the command line to facilitate the presentation of the data. This can be done with the following command (2):

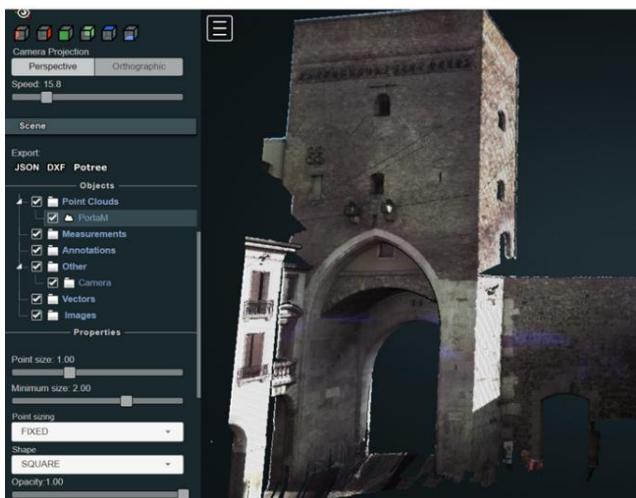
```
PotreeConverter.exe/path-to-pointcloud-file/
pointcloud.laz/pointcloud.las -o /path-to-output-
directory --generate-page YourPageName
```

The resulting octree.bin, metadata.json, hierarchy.bin files, along with the generated HTML file, are then ready for online presentation. This setup ensures that the converted point cloud data can be effectively visualized and shared through the web using Potree.

### 3.1.2. Online Presentation of Data

One of the key features of the Potree application is its ability to present data online. Since Potree is web-based, the data is accessible through a web browser. Users can easily access and examine high-resolution point clouds and 3D models. The online presentation of data facilitates project sharing and collaboration. After the data is converted into an octree structure, it is transferred to a platform offering free web hosting services to ensure easy sharing with other users, allowing the model to be presented online.

Upon completing the processing steps, the Ponte Molino Gate was successfully transferred to the Potree application and shared online on the Potree platform. The cultural documentation data for Ponte Molino Gate can be accessed at <http://potree.altervista.org/test/PortaM.html> (see Figure 7).



**Figure 7.** Online presentation of the Ponte Molino Gate

### 3.2. Discussion

The Potree application and platform is a significant web-based visualization tool that allows users to easily visualize and present large-scale datasets in a browser. It is noted for providing a robust and user-friendly platform for the effective presentation of 3D data. The features offered by Potree are highlighted for their broad applicability across various fields, such as GIS, terrain modelling, urban planning, and archaeology (Carey et al., 2021; de Kleijn et al., 2024; Nguyen et al., 2016; Szujó et al.,

2023). Within the scope of this study, the 3D model of the Ponte Molino Gate was shared online on the Potree platform. Considering the data used in this study, it is evident that its application can be expanded to cover a broader area. In similar studies, cultural heritage data has been evaluated on a wide scale, and it has been emphasized that one of the significant advantages provided by Potree is the inclusion of information and visuals related to cultural heritage. Additionally, in similar studies, the Potree platform has been integrated into a web browser specifically designed for cultural heritage, and the data has been presented to users online through this website (Apollonio et al., 2021; Boutsi et al., 2019; de Kleijn et al., 2024; Fascia et al., 2024). In future stages, it is anticipated that, as with other studies, presenting the Ponte Molino Gate on a dedicated website on a large scale will play a crucial role in reaching a wider audience for the cultural documentation of the Ponte Molino Gate.

The file sizes of TLS data present numerous challenges in terms of data presentation and sharing. One of the primary advantages of visualizing point clouds in a web browser is that users can share datasets without the need to install third-party applications or transfer large amounts of data. Laser scanning data obtained through WebGL-based platforms have been available online to users. However, specific information about file sizes and data transfer rates has not been disclosed. Potree focuses on large point clouds and provides users with tools for examining, analyzing, and verifying raw point cloud data using various measurement tools. Furthermore, the size of the LAS file before conversion was 19,713 KB. At the same time, the metadata.json file size after conversion decreased to 4 KB. Potree offers advantages over other WebGL-based platforms in terms of data size and data processing speed (Fascia et al., 2024; Markus Schütz et al., 2020).

### 4. CONCLUSION

The digital documentation of the Ponte Molino Gate using Potree serves as an effective approach to preserving and sharing cultural heritage. Potree's hierarchical octree structure efficiently processes and visualizes large point cloud datasets, making it a robust tool for fields that require detailed 3D modeling. Its ability to render point clouds in real time reduces loading times, significantly enhancing the user experience when working with extensive datasets. Additionally, its highly accurate measurement capabilities provide valuable support for precise analyses. However, its reliance on the graphics processing unit (GPU) during rendering poses a limitation for users with older hardware. Moreover, its visualization capabilities are restricted to point clouds, which may not meet the needs of projects that demand more versatile visual solutions.

This study highlights the significance of Potree's WebGL-based structure in improving the

accessibility and usability of complex datasets. WebGL technology plays a crucial role in this process by operating directly through web browsers without requiring external plugins or software, enabling users to access and interact with the application effortlessly. Its ability to render graphics in real time provides immediate feedback, resulting in a smoother and more responsive experience. Additionally, WebGL's compatibility with various operating systems and devices allows Potree to cater to a broad audience. The web-based nature of Potree also facilitates easy sharing and distribution, extending the reach and accessibility of the project. These features present an innovative method for quickly and easily transferring many cultural heritage sites into the digital realm. As a WebGL-based point cloud viewer, Potree ensures that large datasets can be easily shared and accessed over the internet, facilitating collaboration among researchers and professionals.

Moreover, during the conversion process, Potree significantly reduces the size of datasets. For instance, the size of the original LAS file, which was 19,713 KB, was reduced to just 4 KB in the resulting metadata.json format. This reduction not only facilitates efficient storage but also enables faster data sharing and processing.

Potree's real-time rendering capabilities also allow for the rapid and efficient visualization of large point cloud datasets, which is particularly beneficial in fields such as architecture, engineering, and construction where quick and accurate project evaluations are crucial. In the realm of education and research, Potree offers students and researchers a deeper, hands-on learning experience by allowing them to analyze and visualize complex datasets. Moreover, the high-precision measurement and analysis features of Potree provide valuable support for data scientists and engineers in performing detailed and reliable analyses, contributing to more efficient project management.

Looking ahead, Potree's ongoing development as an open-source project holds the potential for further technological advancements and feature enhancements. This positions Potree to better meet user needs and adapt to new technological trends in the future. Future research will focus on addressing challenges in data presentation and sharing, further optimizing WebGL's integration within Potree to improve performance, and expanding visualization capabilities beyond point clouds to meet the evolving demands of digital documentation projects.

## Acknowledgment

The authors would like to express our gratitude to Mr. Marco Piragnolo from CIRGEO for providing the TLS data free of charge and for all his support.

## Author contributions

B. Güvercin: Methodology, Software, Formal analysis, Writing - Original Draft and Visualization.  
 K. Erdal: Validation, Investigation and Writing - Original Draft.  
 H.B. Makineci: Conceptualization, Writing - Original Draft, Writing - Review & Editing and Supervision.  
 A. Guarneri: Resources, Data Curation, Writing - Original Draft, and Project administration

## Conflicts of Interest

There is no conflict of interest between the authors.

## Research and publication ethics statement

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

## REFERENCES

- Amirebrahimi, S., Rajabifard, A. J. I. A. o. t. P., Remote Sensing, & Sciences, S. I. (2012). An integrated web-based 3D modeling and visualization platform to support sustainable cities. *1*, 299-304.
- Apollonio, F. I., Fantini, F., Garagnani, S., & Gaiani, M. (2021). A Photogrammetry-Based Workflow for the Accurate 3D Construction and Visualization of Museums Assets. *Remote Sensing*, *13*(3). doi:10.3390/rs13030486
- Boutsi, A.-M., Ioannidis, C., & Soile, S. (2019). An Integrated Approach to 3D Web Visualization of Cultural Heritage Heterogeneous Datasets. *Remote Sensing*, *11*(21). doi:10.3390/rs11212508
- Carey, C., Romero, J., Laefer, D. F. J. T. I. A. o. t. P., Remote Sensing, & Sciences, S. I. (2021). New potree shader capabilities for 3d visualization of behaviors near covid-19 rich healthcare facilities. *46*, 61-66.
- Dall'Asta, A., Leoni, G., Meschini, A., Petrucci, E., & Zona, A. (2019). Integrated approach for seismic vulnerability analysis of historic massive defensive structures. *Journal of Cultural Heritage*, *35*, 86-98. doi:<https://doi.org/10.1016/j.culher.2018.07.004>
- de Kleijn, M., Clevis, K., García González, J., Roling, M., Jongsma, J., de Hond, R., ... Moormann, E. M. (2024). Art and archaeology in an interactive time-traveling online and museum experience. A case study on the Via Appia Antica. *Digital Applications in*

- Archaeology and Cultural Heritage*, 33, e00342.  
doi:<https://doi.org/10.1016/j.daach.2024.e00342>
- Döş, M. E., & Yiğit, A. Y. J. T. F. D. (2023). Küçük ölçekli tarihi eserlerin fotogrametri yöntemi ile 3B modellenmesi ve web tabanlı görselleştirilmesi. 5(1), 20-28.
- Drap, P., Grussenmeyer, P., Gaillard, G., Curtinot, P.-Y., & Seinturier, J. (2004). *Presentation of the web based ARPENTEUR tools: towards a Photogrammetry based Heritage Information System*. Paper presented at the XXth Congress of the International Society for Photogrammetry and Remote Sensing (ISPRS).
- Fascia, R., Barbieri, F., Gaspari, F., Ioli, F., & Pinto, L. (2024). FROM 3D SURVEY TO DIGITAL REALITY OF A COMPLEX ARCHITECTURE: A DIGITAL WORKFLOW FOR CULTURAL HERITAGE PROMOTION. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLVIII-2/W4-2024, 205-212. doi:10.5194/isprs-archives-XLVIII-2-W4-2024-205-2024
- Gaspari, F., Ioli, F., Barbieri, F., Rivieri, C., Dondi, M., Pinto, L. J. T. I. A. o. t. P., Remote Sensing, & Sciences, S. I. (2023). REDISCOVERING CULTURAL HERITAGE SITES BY INTERACTIVE 3D EXPLORATION: A PRACTICAL REVIEW OF OPEN-SOURCE WEBGL TOOLS. 48, 661-668.
- Gobbetti, E., & Marton, F. (2004). Layered point clouds: a simple and efficient multiresolution structure for distributing and rendering gigantic point-sampled models. *Computers & Graphics*, 28(6), 815-826. doi:<https://doi.org/10.1016/j.cag.2004.08.010>
- Guarnieri, A., Vettore, A., & Pontin, M. (2005). A volumetric approach for 3D surface reconstruction. Paper presented at the Proc., CIPA 2005, 20th Int. Symp.
- Jung, J., Fei, S., Tuinstra, M., Yang, Y., Wang, D., Song, C., . . . Zhao, L. (2024). Data to science: an open-source online platform for managing, visualizing, and publishing UAS data. Paper presented at the Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping IX.
- Klepárník, R., & Sedláček, J. J. J. D. L. A. (2021). UAV Photogrammetry, Lidar or WebGL? A Comparison of Spatial Data Sources for Landscape Architecture. 6, 220-229.
- La Guardia, M., & Koeva, M. (2023). Towards Digital Twinning on the Web: Heterogeneous 3D Data Fusion Based on Open-Source Structure. *Remote Sensing*, 15(3). doi:10.3390/rs15030721
- Makineci, H. B., & Erdal, K. (2021). Documentation of Cultural Heritage with Backpack LiDAR Usage on Photogrammetric Purpose. [Sırt Lidarının Fotogrametrik Amaçlı Kullanımıyla Kültürel Mirasın Dokümantasyonu]. *Türkiye Lidar Dergisi*, 3(1), 1-6. doi:10.51946/melid.921032
- Martinez-Rubi, O., Verhoeven, S., Van Meersbergen, M., Van Oosterom, P., GonÁlves, R., & Tijssen, T. (2015). *Taming the beast: Free and open-source massive point cloud web visualization*. Paper presented at the Capturing Reality Forum.
- Masciotta, M. G., Morais, M. J., Ramos, L. F., Oliveira, D. V., Sánchez-Aparicio, L. J., & González-Aguilera, D. (2021). A Digital-based Integrated Methodology for the Preventive Conservation of Cultural Heritage: The Experience of HeritageCare Project. *International Journal of Architectural Heritage*, 15(6), 844-863. doi:10.1080/15583058.2019.1668985
- Nguyen, M.-T., Nguyen, H.-K., Vo-Lam, K.-D., Nguyen, X.-G., & Tran, M.-T. (2016). *Applying virtual reality in city planning*. Paper presented at the Virtual, Augmented and Mixed Reality: 8th International Conference, VAMR 2016, Held as Part of HCI International 2016, Toronto, Canada, July 17-22, 2016. Proceedings 8.
- Quintilla-Castán, M., Martínez-Aranda, S., & Agustín-Hernández, L. (2022). *Digital 3D inventory for the promotion and conservation of the architectural heritage*. Retrieved from
- Rusinkiewicz, S., & Levoy, M. (2000). *QSplat: a multiresolution point rendering system for large meshes*. Paper presented at the Proceedings of the 27th annual conference on Computer graphics and interactive techniques. <https://doi.org/10.1145/344779.344940>
- Sánchez-Aparicio, L. J., Masciotta, M.-G., García-Alvarez, J., Ramos, L. F., Oliveira, D. V., Martín-Jiménez, J. A., . . . Monteiro, P. (2020). Web-GIS approach to preventive conservation of heritage buildings.

- Automation in Construction, 118, 103304.  
doi:<https://doi.org/10.1016/j.autcon.2020.103304>
- Scheiblauer, C. (2014). *Interactions with gigantic point clouds*.
- Scheiblauer, C., Wimmer, M. J. C., & Graphics. (2011). Out-of-core selection and editing of huge point clouds. 35(2), 342-351.
- Schultz, R. B., Kerski, J. J., & Patterson, T. C. (2008). The Use of Virtual Globes as a Spatial Teaching Tool with Suggestions for Metadata Standards. *Journal of Geography*, 107(1), 27-34.  
doi:10.1080/00221340802049844
- Schütz, M. (2015). *Potree: Rendering large point clouds in web browsers*. Technische Universität Wien,
- Schütz, M., Ohrhallinger, S., & Wimmer, M. (2020). *Fast Out-of-Core Octree Generation for Massive Point Clouds*. Paper presented at the Computer Graphics Forum.
- Schütz, M., & Wimmer, M. (2015, 28 Sept.-2 Oct. 2015). *High-quality point-based rendering using fast single-pass interpolation*. Paper presented at the 2015 Digital Heritage.
- Szujó, G., Biber, Z., Gál, V., & Szabó, B. (2023). MaGISTER-mine: A 2D and 3D web application in the service of mining industry. *International Journal of Applied Earth Observation and Geoinformation*, 116, 103167.  
doi:<https://doi.org/10.1016/j.jag.2022.103167>
- Wand, M., Berner, A., Bokeloh, M., Fleck, A., Hoffmann, M., Jenke, P., . . . Schilling, A. (2007). *Interactive Editing of Large Point Clouds*. Paper presented at the PBG@ Eurographics.
- Wimmer, M., & Scheiblauer, C. (2006). *Instant Points: Fast Rendering of Unprocessed Point Clouds*. Paper presented at the PBG@ SIGGRAPH.



© Author(s) 2024.

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



## Simülasyon Modeli ile Deprem Senaryosu Oluşturulması ve Aksaray İli Triyaj Tahmin Analizi

Asuman Akşit<sup>1</sup>, Semih Ekercin<sup>2</sup>, Ümrان Kaya<sup>3</sup>

<sup>1</sup>Aksaray Üniversitesi, Mühendislik Fakülte, Jeodezi ve CBS ABD, Aksaray, Türkiye

<sup>2</sup>Antalya Bilim Üniversitesi, Antalya, Türkiye

<sup>3</sup>Antalya Bilim Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü, Antalya, Türkiye

### Anahtar Kelimeler:

Arena Simülasyon Modeli  
Afet Yönetimi,  
Risk Yönetimi,  
Türkiye,  
Orta Anadolu

### ÖZ

Depremler, canlı yaşamını ciddi şekilde etkileyebilen doğal felaketlerdir. Zemin özelliklerine bağlı olarak değişkenlik göstermekle birlikte, bazı durumlarda deprem şiddeti nedeniyle önemli can ve mal kayıpları meydana gelebilir. Literatürdeki çalışmalara bakıldığına depremleri önceden belirlemek mümkün olmamaktadır. Fakat, afet yöntemi çalışmalarının doğru planlanması ile maddi hasarlar ve sosyo-ekonomik kayıplar en aza indirgenebilir. Afet yönetimi kapsamında risk yönetimi ve kriz yönetimini iyi bir şekilde planlamak toplumun olumsuz yönde etkilenmesini azaltarak kaynakların doğru kullanılması hedefini gözetlen bir yaklaşımdır. Bu noktada en büyük görev bölge yöneticilerine düşmektedir. Ülkemizde afetlerden kaynaklanan can ve mal kayıplarında önemli bir rol oynayan depremlere yönelik afet yönetimi çalışmalarında, olası depremler için senaryolar geliştirilmektedir. Bunun için, stokastik temellere dayanan ve kurgusal yapıya sahip iki ana yaklaşım kullanılmaktadır. Bu çalışma kapsamında Türkiye'nin artan nüfus ve sanayi potansiyeline sahip Aksaray ilinin merkez ilçesindeki 11 mahalle için deprem senaryosu üretilmiştir. Senaryonun üretilebilmesi için stokastik temelleri olan kurgusal yöntem kullanılarak ARENA simülasyon modeli oluşturulmuştur. Ayrıca modellen elde edilen verilerle üretilen senaryonun sonuçları kullanılarak Aksaray ili için ilk defa detaylı bir triyaj tahmin analizi yapılmıştır. Simülasyon modeli oluşturularken ilgili mahallelerin zemin profil bilgisi, bina kat sayıları ve mahallelerin nüfus sayıları arasındaki ilişki değerlendirilerek olası hasar ve kayıp tahmini yapılmıştır. Simülasyon tabanlı deprem senaryosundan elde edilen sonuçlara göre yapılan triyaj analizi, 5,1 Mw büyüklüğündeki olası bir depremde can kaybı sayısının (T4) 0 iken, 6,5 Mw büyüklüğündeki olası bir depremde 705 olacağını ve nüfusun yaklaşık %0,70'inin depremden etkilendiğini göstermektedir.

## Creating an Earthquake Scenario Using a Simulation Model and Triage Prediction Analysis for Aksaray Province

### Keywords:

Arena Simulation Model,  
Disaster Management,  
Risk management,  
Türkiye,  
Central Anatolia

### ABSTRACT

Earthquakes are natural disasters that can severely impact living conditions. While their effects may vary depending on the characteristics of the ground, in some cases, significant loss of life and property damage can occur due to the intensity of the earthquake. According to studies in the literature, it is not possible to predict earthquakes in advance. Proper planning of disaster management strategies can minimize material damage and socio-economic losses. Effective risk and crisis management planning aims to reduce societal impact while ensuring efficient resource use. The primary responsibility lies with regional managers, who develop earthquake scenarios to manage the significant loss of life and property caused by earthquakes. To achieve this, two main approaches based on stochastic foundations and fictional structures are used. In this study, an earthquake scenario has been developed for the 11 neighborhoods in the central district of Aksaray, a province with increasing population and industrial potential in Turkey. A stochastic-based fictional method was used to create an ARENA simulation model for generating the earthquake scenario. Using the model's data, a

### Makale Bilgileri

Geliş : 01/11/2024  
Kabul: 27/11/2024  
Yayınlanma: 30/12/2024

### Alıntı:

Akşit, A., Ekercin, S., Kaya, Ü. (2024). Simülasyon modeli ile deprem senaryosu oluşturulması ve Aksaray İli triyaj tahmin analizi. Türkiye Uzaktan Algılama Dergisi, 6 (2), 122-131.

detailed triage prediction analysis was conducted for Aksaray province for the first time. The model considered factors such as ground profiles, building heights, and population numbers to estimate potential damage. The results showed that in a 5.1 Mw earthquake, there would be no casualties (T4), while a 6.5 Mw earthquake would result in 705 casualties, affecting approximately 0.70% of the population.

## 1. GİRİŞ

Depremler kökeni yerin içinde olan ve kırılmalar sebebiyle aniden oluşan titresimlerin dalgalar şeklinde yayılması ile can ve mal kaybına sebep olduklarından insanları çok korkutan doğal afetlerden biridir. Deprem meydana geldiğinde bölgeye vereceği hasar ve kayıp, jeolojik faktörler, yapısal faktörler ve sosyo-ekonomik faktörlerle doğrudan ilişkilidir.

Depremler başta olmak üzere, ülkemizde meydana gelebilecek doğa kaynaklı afetlerin zararlarını azaltmak için yapılması gereken faaliyetler bulunmaktadır. Bunlar; risk yönetimi ve kriz yönetimi altında değerlendirilebilir (Gerdan, 2021). Deprem özelinde bakıldığından, risk yönetimi, deprem meydana gelmeden önce varolan tehlike ve risklerin belirlenmesi, depremin tahmini ve erken uyarı sistemleri, önlem alma, kurtarma, tahliye, ilk ve acil yardım planları ve depreme hazırlıklı olma çalışmalarından oluşmaktadır. Kriz yönetiminde ise deprem sonrası hızlı müdahale ve iyileştirme evresinde yapılacaklar ön plana çıkar. Risk ve kriz yönetimin temel hedefi afet kaynaklı ortaya çıkabilecek zararı en aza indirmektir. Afet öncesi, sırası ve sonrasında kapsayan bu aşamaların etkin bir şekilde sürdürülebilmesi için, olası bir afet sonrasında zararın tahmin edilerek buna yönelik senaryolar oluşturulması afet yönetimi çalışmalarında sıkılıkla kullanılan bir yöntemdir (Kaya & Yıldırım, 2012). Literatürde deprem senaryosu oluşturmak için deterministik, stokastik ve kurgusal yöntemler kullanılmaktadır. Deterministik yöntemde, doğa kaynaklı afet tehlikesi olasılık temeline dayandırılmışdan, şiddet, ivme ve hız gibi belirsizlik bulundurmayan matematiksel bir tanım kullanılarak oluşturulur (Jica, 2002; Küçükçoban, 2004). Bu yöntem ile deprem senaryosu oluşturulacak ise diri fay hatları ve bu fayların üretebileceği en büyük deprem büyülüklüğü belirlenir. Bu fayların konuma olan minimum mesafe hesaplanır. Sonrasında belirlenen bölgede depremin olacağı varsayımları yapılarak, depremin maksimum yaratabileceği yer hareketi verileri belirlenir (Özmen & Can, 2016). Stokastik yöntemler kullanılarak oluşturulan deprem senaryolarında ise hasar yapıcı bir depremin belli bir konumda ve belli bir zaman diliminde meydana gelme olasılığı belirlenmeye çalışılır (Crozi vd., 2005). Bir diğer yöntem olan kurgusal yöntemde ise olası depremin etkileri sosyal olarak ifade edilir. Diğer bir ifade ile bu yöntem matematiksel ifadelerden uzak bir yöntemdir (Çiftçi vd., 2020).

Deprem senaryosunda deterministik ve stokastik yöntemlerin kullanılabilmesi için, ilgili bölgede kaydedilmiş deprem hasar ve kayıp

verilerine dayanarak, mevcut bilgilerle geleceğe yönelik tahminler yapılması gerekmektedir. Ancak, verilerin yetersiz olduğu veya kayıtlı verilerin bulunmadığı durumlarda, hasar tahminleri güvenilir olmayacağından.

Türkiye dünyanın önemli deprem kuşaklarından (Alp-Himalaya Kuşağı) biri üzerinde yer almaktadır. Sismik açıdan oldukça aktif bir ülke olan Türkiye'nin, Orta Anadolu Bölgesi görelî olarak sakin bir bölge olarak değerlendirilse de bölgenin önemli aktif fay zonlarından biri olan Tuz Gölü Fay Zonu üzerinde yakın zamanda yapılan çalışmalar, zonun Aksaray'a yakın segmentlerinin büyülüklüğü 6,8'e varabilecek depremler üretme potansiyeline sahip olduklarını göstermektedir (Kürçer 2012, Gezgin 2020). Söz konusu fay zonun özleilklerine yönelik literatürde yapılmış farklı çalışmalar olmakla birlikte il özelinde detaylandırılmış deprem tehlike haritaları bulunmamaktadır. Bu durum olası bir depremin yaratacağı hasar ve kayıp konusunda eksiklik yaratmaktadır.

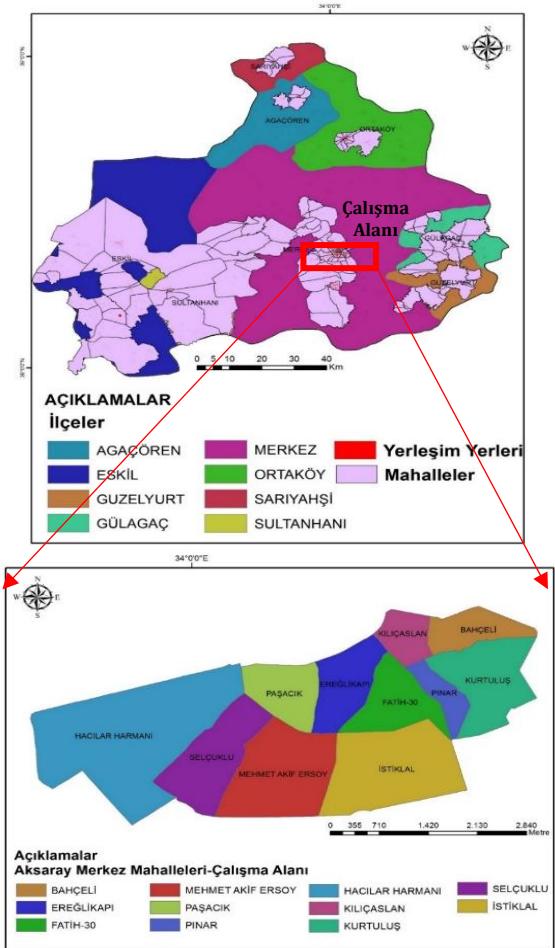
Bu çalışmanın amacı, hızla artan nüfusa sahip Aksaray ilinde Tuz Gölü Fay Zonu'nda meydana gelebilecek olası bir depremin belirlenen 11 mahallede yaratabileceği hasar ve kayıpların tahmin edilmesidir. Bu doğrultuda çalışma kapsamında stokastik temelleri olan kurgusal yöntem kullanılarak deprem senaryosu oluşturulmuştur. Ayrıca oluşturulan senaryodan sağlanan veriler ile yaralı önceliklendirme yöntemi olan triyaj tahmin analizi yapılmıştır. Çalışmada deprem senaryosu oluşturulması için kullanılan kurgusal yöntem deprem büyülüklüğü ve nüfus sayısı gibi kabul edilen varsayımların dikkate alınmasını sağlarken, stokastik yöntem ise zemin profil bilgileri ve binaların kat sayıları gibi olasılıksal değerlerin de senaryoya dahil edilmesini sağlamıştır.

Özetle, çalışma kapsamında simülasyon yapısı kullanılmış, deprem senaryosu oluşturulmuş ve kayıp tahmin analizleri gerçekleştirilmiştir. Aksaray ili için bu yöntemler kullanılarak yapılmış bir kayıp tahmin analizi bulunmamaktadır. Bu nedenle Aksaray ili için olası bir deprem sonrası olacak kayıpların tahmini açısından bu çalışmanın ilk olduğu ve literatüre farklı bir bakış açısı sunacağı düşünülmektedir. Ayrıca kullanılan yöntemin az maliyet gerektirmesi, avantajlı hızlı sonuçlar üretmesi açısından da deprem senaryosu konusundaki çalışmalarla katkı sağlaması beklenmektedir.

### 1.1. Çalışma Alanı

Aksaray ili, Edirne, İstanbul, Ankara, Adana, İskenderun karayolları ile Samsun, Kayseri, Konya ve

Antalya karayollarının kesişim noktasında yer almaktadır. Doğuda Nevşehir, güneydoğuda Niğde, batıda Konya, kuzeyde Ankara ve kuzeydoğuda Kırşehir ile çevrilidir. Yüzölçümü 7626 km<sup>2</sup> olan Aksaray, 8 ilçesi (Merkez, Ağaçören, Eskil, Gülağaç, Güzelyurt, Ortaköy, Sultanhanı, Sarıyahşi), 192 köy ve kasabasıyla birlikte geniş bir yerleşim alanına sahiptir (Şekil 1). İl, yüzey şekilleri bakımından genellikle düzlüklerden oluşur ve denizden 980 metre yüksekliktedir. İlin güneydoğusunda yer alan Hasandağı (3268 m) ve kuzeyini orta kısımdan ayıran, Hasandağı ile birleşen Ekeçik Dağı (2137 m) bu bölgedeki belirgin yüksekliklerdir.



**Şekil 1.** Çalışma alanı yer bulduru haritası

Bölgelerde ülkemizin önemli aktif tektonik yapılarından biri olan Tuz Gölü Fay Zonu bulunmaktadır. Tuz Gölü Fay Zonu, KB-GD doğrultusunda uzanan kita içi bir fay zonudur. Yakın dönemde yapılan çalışmalarla, Tuz Gölü Fay Zonu uzunlukları 9-30 km arasında değişen birbirine paralel ya da yarı paralel 11 geometrik segmente ayrılmış ve bu segmentlerden Aksaray'a yakın olan segmentlerin (Tuz Gölü, Akhisar-Kılıç ve Altunhisar segmentleri) büyülüğu 6,8'e çıkabilecek deprem üretme potansiyeli olduğu ortaya konmuştur (Kürçer 2012).

Bu durum, Aksaray il merkezinin de içinde bulunduğu, büyük ölçüde alüvyon zemin üzerine kurulu, nüfusu hızla artan ve yoğun sanayi

potansiyeline sahip olan bölgede, yıkıcı hasarların ve can kayıplarının meydana gelme olasılığını işaret etmektedir (Gezgin, 2020). Bu kapsamda Aksaray ili merkez ilçesinin Tuz Gölü fayına yakın olmasından dolayı çalışma alanı olan Bahçeli, Kurtuluş, Pınar, Kılıçarslan, Fatih, Ereğlikapı, İstiklal, Paşaçık, Mehmet Akif Ersoy, Selçuklu, Hacılar Harmanı mahalleleri üzerinde simülasyon modeli çalıştırılarak, olası bir deprem sonrası yaralıların önceliklendirilmesi amacıyla triyaj tahmin analizi yapılmıştır.

## 2. YÖNTEM

Çalışmada kurgusal yöntem ve stokastik yöntemin ele alınması, deprem büyüklüğü ve nüfus sayısı gibi kabul edilen varsayımların kurgusal yöntemin kapsama alanına girmesinden kaynaklanmaktadır. Stokastik yönteminde ise zemin profil bilgisi ve bina katsayı gibi olasılıksal değerleri kapsadığı için bu yöntemler melez bir şekilde kullanılmıştır. Ayrıca zemin profil bilgisi ve bina kat sayı bilgileri gibi veriler kullanılarak ARENA Simülasyon programında deprem senaryosu modellenmiştir. Yapılan modelleme sonucunda triyaj işleminin sınıflandırma grupları (ağır yaralı, hafif yaralı, geciktirilebilir yaralı ve ölü) referans alınarak can kaybı analizi yapılmıştır.

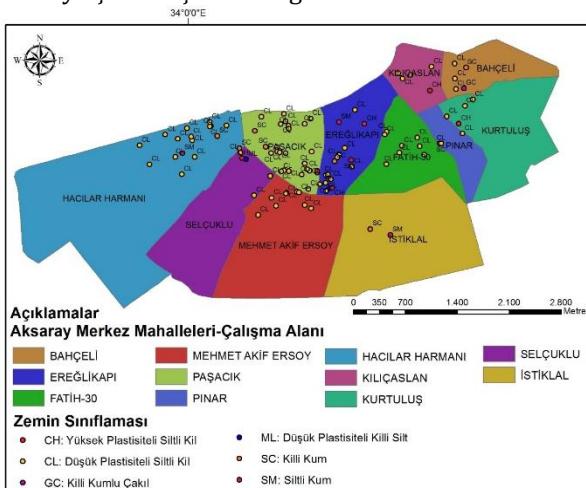
Simülasyon aracılığıyla deprem senaryosu oluşturulması için ARENA simülasyon programı kullanılarak, INTER (R) Core (TM) i7-7700HQ CPU ve 16 GB belleğe sahip bir bilgisayarda çalıştırılmıştır. Her mahalle için 10 kez tekrarlanan simülasyon sonuçları kaydedilmiş ve analiz edilmiştir.

### 2.1. Deprem Senaryosu

Olası afetlere karşı risk yönetimini en iyi şekilde gerçekleştirebilmek için, toplumların afetlerden fiziksel, sosyo-ekonomik ve psikolojik açıdan ne ölçüde etkileneceğini belirlemek önemlidir. (Karaman ve Şahin, 2009). Doğal afetlerin meydana geleceği zaman, yer, büyülüklük ve oluşturacağı hasar çoğunlukla belirsizdir (Çiftçi vd., 2020). Ancak bu belirsizliklere rağmen meydana gelecek bir afete yönelik alınacak önlemler, sonrası için iyileştirme çalışmalarının yapılabilmesi için çeşitli senaryo ya da modelleme çalışmaları yapılabilir. ARENA simülasyon programı da bu amaçla kullanılan programlardan biridir. Sismik yer hareketlerinin yapılar üzerindeki etkileri, zemin kalınlıkları ve bazı fiziksel özelliklerinden oluşan parametrelerle bağlıdır. Aksaray ili merkez mahalleler çalışma alanı kapsamında kullanılan önemli parametrelerden olan zemin profil yapısı için faydalanan sondaj verileri Şekil 2'de gösterilmektedir (Göktaş, 2021).

Çalışma alanında depreme ait belirsizliklerden dolayı zemin profil bilgisi ve bina kat sayıları dikkate alınarak senaryo oluşturulmuştur. Aksaray ili genelinde önceden yapılmış kapsamlı bir zemin profil çalışması bulunmadığı için parametre olarak

zemini profil bilgisi tercih edilmiştir. Çalışma alanında yer alan binaların zemin profil yapısı iyi, orta ve kötü şeklinde sınıflandırılmıştır. Diğer önemli parametre bina katsayılarıdır. Bu parametre de kendi içinde az katlı, orta katlı ve çok katlı olarak belirlenmiştir. Çok katlı ve zemin yapısı kötü olanının deprem nedeniyle yıkımı ve dolayısıyla kayıpların daha yüksek olacağı düşünülmektedir. 5,1-6,5 Mw büyüklüğündeki olası bir depremin seçilen parametreler dikkate alınarak oluşturulan senaryo şeması Şekil 3'te görülmektedir.



**Şekil 2.** Aksaray ili merkez ilçede bulunan mahallelerin zemin profil yapısı

Çalışma kapsamında Aksaray ili merkez mahallelerde oluşturulan deprem senaryosu için stokastik yöntem ve kurgusal yöntem kullanılmıştır.

alınır (Crozi vd., 2005). Stokastik yöntemlerle oluşturulan deprem senaryolarının bir bölümünü Coğrafi Bilgi Sistemleri (CBS) tabanlı hasar ve kayıp modelleri oluşturmaktadır. Ayrıca Probabilistic Seismic Hazard Analysis (PSHA), 1960'larda geliştirilen ve deprem tehlikesini değerlendirmek için kullanılan stokastik bir yöntemdir. Bu yöntem, belirli bir bölgedeki deprem olasılıklarını hesaplamak için zemin özellikleri, yerel faylar ve geçmiş deprem verilerini dikkate alır. İlk büyük uygulamalarından biri, Cornell'in 1968 yılında yaptığı çalışmadır. Cornell'in çalışması, olasılık teorisi ile deprem tehlikesi analizini birleştiren önemli bir örnek olarak kabul edilir (Cornell, 1968). Literatürde Kirşehir ili için stokastik bir yöntem kullanılarak üç farklı deprem senaryosu oluşturulmuştur. Bu senaryoların hazırlanmasında Earthquake Loss Estimation Routine (ELER) yazılım programından faydalanylmıştır (İşik, vd., 2019).

### 2.1.2 Kurgusal Yöntem

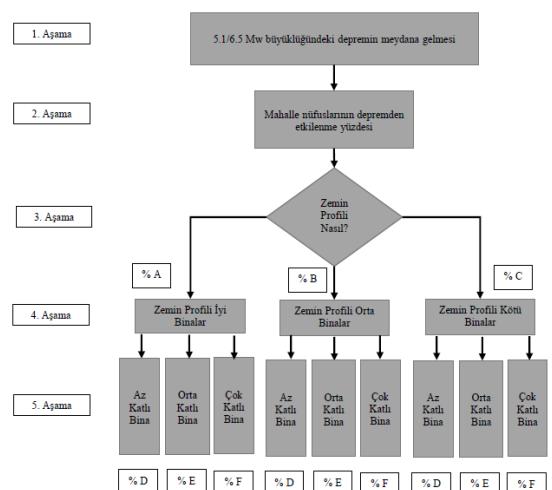
Kurgusal yöntem kullanılarak oluşturulan senaryolar sayısal veriler içermeyen, afetin etkilerini sosyal anlamda ifade etmeye yönelik bir yöntemdir. Bu nedenle de bir deprem için simülasyon modeli oluşturulurken sadece kurgusal yöntem kullanmak çok gerçekçi sonuçlar vermemeştir. Ancak bazı çalışmalarında, diğer yöntemler kullanılarak gerekli bilgilerin elde edilemediği ve varsayımların çok olduğu durumlarda başvurulan bir yöntem olarak kullanılmaktadır. (Doğan, 2015; Çiftçi vd., 2020).

### 2.2. ARENA Simülasyon Programı

Yapılan bu çalışma kapsamında simülasyon modelini oluşturmak için Rockwell ARENA simülasyon programı kullanılmıştır. ARENA, SIMAN'ı da geliştiren System Modelling firması tarafından üretilmiş ve 2000 yılında Rockwell Automation tarafından satın alınmış, Windows tabanlı popüler bir simülasyon ve otomasyon yazılımıdır. SIMAN işlemcisi ve simülasyon dilini kullanarak, tedarik zinciri, süreçler, lojistik, hizmet sistemleri, dağıtım ve depolama gibi çeşitli sistemlerin mevcut performansını ve olası alternatif çalışma senaryolarını analiz etmek için yaygın olarak tercih edilmektedir (Pulat vd., 2023). Bir sürecin ağ yapısını oluşturarak, kaynak tahsisini daha hassas bir şekilde ayarlamak ve sistem davranışını gözlelemek mümkün hale gelir. (Wang vd., 2009). Bu çalışmada deprem simülasyon modeli oluşturulurken ARENA programının modülleri; Create, Process, Decide, Record, Singal, Delay, Hold, Station, Assing, Batch, Separate ve Dispose modülleri kullanılmıştır.

### 2.3. Triyaj Yöntemi

Triyaj işleminde, acil durumlar veya kaos ortamlarında bulunan kişilerin sağlık durumları, ciddiyetlerine göre sınıflandırılır. Afet sonrası triyaj



**Şekil 3.** Arena simülasyon modelinin olasılıksal şematik gösterimi

#### 2.1.1 Stokastik Yöntem

Bu yöntemde çalışılan deprem senaryolarında yıkıcı olan yer hareketlerinin belli bir konum ve zamanda meydana gelebilme olasılıkları belirlenmeye çalışılır. Bu olasılıkların belirlenmesinde bölgeye etki eden farklı durumları dikkate alan tehlike bazlı modeller ve oluşum için üretilen yüzlerce ya da binlerce simülasyon kaynak

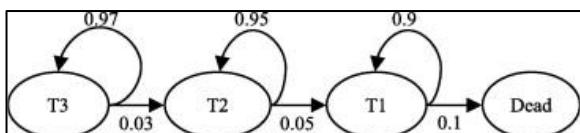
yapılmasının nedeni, kaynakların sınırlı olması ve mümkün olan en fazla sayıda insanın kurtarılmasını sağlamaktır. Triyaj işlemi sonrasında, kişiler sağlık durumlarına göre; ağır yaralı (T1), geciktirilebilecek yaralı (T2), hafif yaralı (T3) olarak sınıflandırılabilir veya ölü (T4) olabilirler. Çalışma kapsamında simülasyon girdileri kullanılarak simülasyon çıktıları olarak triyaj işlemi uygulanmıştır. Triyaj işleminde kullanılan sınıflandırma T1, T2, T3 ve T4 şeklinde gösterilmektedir (Tablo 1).

Çalışma kapsamında ilgili parametreler (zemin profil yapısı, bina katsayıları vb.) simülasyon girdisi olarak programa tanımlanmış, simülasyon çıktıları olarak ise Aksaray ili Merkez ilçede bulunan 11 mahalleye ait ayrı ayrı triyaj analiz (T1,T2,T3 ve T4) sonuçları üretilmiştir.

**Tablo 1.** Triyaj işleminde kullanılan sınıflandırma tablosu (Wilson vd., 2013)

Triyaj Sınıfı	Açıklama	Beklenen Müdahale
T1	Ağır yaralı	Acil müdahale ile hastaneye sevkı sağlanmalı
T2	Geciktirilebilir yaralı	Duruma göre 2-4 saat aralığında toleransla hastaneye sevkı sağlanmalı
T3	Hafif yaralı	4 saatten daha fazla toleransa sahip acil müdahale gerekmeyen Morga sevkin sağlanması
T4	Ölü	

Ayrıca, ağır yaralı (T1) bir kişiye yapılacak olan müdahale yanında geç kalındığında durumu ağırlaşıp ölü sınıfına (T4) geçebilmektedir ya da geciktirilebilir yaralı sınıfında (T2) yer alan bir kişi vakit ilerledikçe sağlık durumu ağır yaralı sınıfına (T1) yer alabilir. Bahsedilen bu geçiş, Markov zincirleri referans alınarak geçiş olasılıkları şeklinde, çalışmada yer almıştır (Şekil 4).

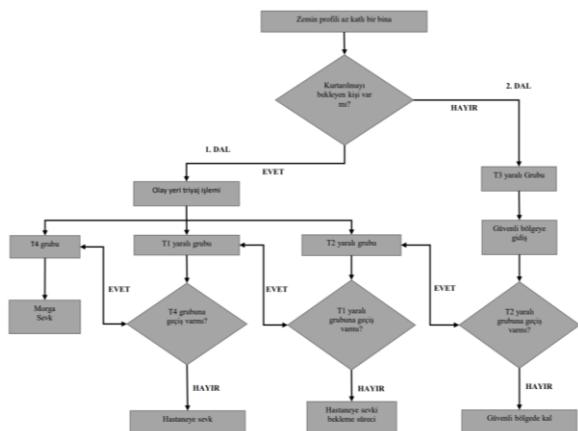


**Şekil 4.** Markov zinciri geçiş olasılıkları değerleri (Wilson vd., 2013)

Simülasyon modelinde kullanılan triyaj yöntemi sonrasında gelişen süreç Şekil 5'de gösterilmektedir. Şekil 5'de; Şekil 3'de gösterilen dokuz daldan örnek olarak zemin yapısı kötü ve çok katlı binalarda yaşayan insanların, bu hasarlı binalarda olup olmadığı sorgulanır. Şekil 5'deki triyaj yönetiminin 1.dal ve 2.dal olarak süreçler simülasyon modelinde çalıştırılmıştır.

Simülasyon modeli oluşturulurken deprem büyüklüklerine göre binaların yıkılma durumları ve triyaj yaralı önceliklendirme işleminin oranları literatür araştırması sonuçlarına göre modele

ışlenmiştir. Ayrıca Şekil 4'de gösterilen Markov zinciri geçiş oranları modele tanımlanmıştır.



**Şekil 5.** Deprem sonrası triyaj yönteminin şematik gösterimi

### 3. BULGULAR

Çalışma alanına ait deprem senaryo girdileri ARENA Simülasyon programında Şekil 3'de yer alan simülasyon modeline göre oluşturulmuştur. Şekil 3'de yer alan birinci aşamada Tuz Gölü Fay Zonu üzerinde veya yakın çevresinde Mw 5,1 ve Mw 6,5 büyüklüğünde olası bir depremin meydana geldiği ve Aksaray ili merkez mahallelerini etkilediği varsayılmıştır.

Depremin büyüklüğü ve yıkıcı etkisi arasındaki ilişki konusunda genellikle kabul edilen temel ilke, depremin büyülüüğündeki her bir birim artışın, salınan enerjiyi yaklaşık olarak 32 kat artırmasıdır (Aki & Richards, 2002). Bu ilişki, Richter ölçüde gidi logaritmik ölçeklerde depremlerin enerji salınımını değerlendirirken kullanılır. Bu hesaplama, depremin enerjisini değerlendirir. Ancak, yıkım oranı veya hasar derecesini doğrudan tahmin etmez. Depremin yıkıcılığını belirleyen faktörler, sadece enerji değil; deprem derinliği, yerel zemin özellikleri, yapıların dayanıklılığı ve nüfus yoğunluğu gibi değişkenleri de içerir. Yani, Richter ölçüde siddet ve enerji arasındaki ilişki üzerine olan bu varsayımdan, doğrudan hasar oranını yansıtmadıkla birlikte enerji artışı anlamada kullanılan bir referans sağlar (Aki & Richards, 2002).

Deprem siddetinde yıkım oranı arasındaki ilişkiyi inceleyen birkaç önemli model bulunmaktadır. Özellikle, deprem büyülüüğü ile hasar arasındaki ilişkiyi ele alan "Gutenberg-Richter ilişkisi" sıkça kullanılır. Bu formül, deprem büyülüğine bağlı olarak belirli bir büyülükteki depremlerin sayısını tahmin etmektedir.

Formül şu şekildedir:

$$\log_{10}N = a - bM \quad (1)$$

Bu noktada, depremin büyülüğü, o büyülükteki veya daha büyük depremlerin sayısını belirtir. Bu ilişkiye göre, her birim büyülü artışı, belirli bir

sürede aynı bölgedeki deprem sayısını yaklaşık on kat azaltır ve büyülüklük arttıkça meydana gelen yıkım olasılığı da genellikle artar. Bu duruma göre, her bir büyülüklük artışı belirli bir süre içinde aynı bölgedeki deprem sayısını yaklaşık on kat azaltır ve genellikle büyülüklük arttıkça yıkım riski de artar. Ek olarak, odak derinliği gibi faktörlerin yıkım üzerinde önemli bir etkisi olduğu belirlenmiştir. Daha sık depremler yüzeye daha yakın olduklarından dolayı daha yıkıcı olabilirken, derin depremlerin yıkıcı etkisi genellikle daha kısıtlıdır. Bu bağlamda, bazı araştırmacılar odak derinliği ve maksimum fay yer değiştirmesini içeren empirik modeller geliştirmiştir, çünkü derinliğin hasar tahmininde önemli bir rol oynadığı anlaşılmıştır. Bu ilişkiler, özellikle depreme dayanıklı yapıların tasarımında ve risk yönetiminde önemli rol oynamaktadır (Gutenberg & Richter, 1955). Bu kapsamda hesaplanan değerler Şekil 3'de yer alan simülasyon modelinde 2. aşamanın girdisi olarak kullanılmıştır.

Deprem sonrası bina yıkıldığından yaralı önceliklendirme oranları yapılan literatür çalışması sonucunda belirlenmiştir (Jaiswal, Wald & D'Ayala, 2011). Bu değerler Şekil 3'de yer alan simülasyon modelinde 5. aşamaya girilmiştir.

Deprem senaryosu girdileri olarak, ilk aşamada çalışma kapsamındaki 11 mahallenin zemin profil bilgilerine dayanarak, her mahallenin hasar durumunu tahmin edebilmek için zemin profilleri; iyi, orta ve kötü şeklinde oranlarla belirlenmiştir.

Bu oranlar Aksaray Belediyesi tarafından yapılan zemin sondajlarının sonuçlarına göre verilmiştir (Göktaş, 2021, Tablo 2). Elde edilen sonuçlar Şekil 3'de yer alan simülasyon modelinde 4. aşamanın girdisi olarak kullanılmıştır.

**Tablo 2.** Çalışma kapsamında ilgili mahallelerin zemin profil oranları

Mahalle/Zemin Profil Oranı	İyi	Orta	Kötü
BAHÇELİ	20%	30%	50%
EREĞLİKAPI MAH.	10%	40%	60%
FATİH	10%	20%	70%
HACILAR HARMANI	10%	10%	80%
İSTİKLAL	50%	30%	20%
KILIÇASLAN	10%	40%	50%
KURTULUŞ	10%	30%	60%
M. AKİF ERSOY	10%	20%	70%
PAŞACIK	10%	30%	60%
PINAR	10%	20%	70%
SELÇUKLU	10%	40%	50%

Şekil 3'de yer alan 5. aşama için ise Aksaray İl Özel İdaresi'nden temin edilen, mahallelerde bulunan binaların kat sayı kullanılmıştır (Tablo 3 ve Tablo 4)

Bu veriler ARENA Simülasyon modeli kurulumunda deprem senaryosu girdileri olarak modele işlenmiştir. Modele tanımlanan bu veriler ve istatistiksel oranlar ile çalışılmıştır.

**Tablo 3.** İlgili mahallelerde bulunan binaların kat sayıları

Mahalleler/	1 kat	2 kat	3 kat	4 kat	5 kat	6 kat	7 kat	8 kat	9 kat	14 kat	15 kat	Top. Bina Sayısı
BAHÇELİ	355	128	52	20	35	12						602
EREĞLİKAPI	127	121	107	195	227	54	3	22	1		1	858
FATİH	126	96	62	75	65	116	30	14	7			591
HACILAR HARMANI	414	104	36	57	24	9	3	5	1			653
İSTİKLAL	164	26	11	5	25	6	3	2				242
KILIÇASLAN	90	285	188	85	38	10				1		697
KURTULUS	449	198	94	24	25	11						801
M. AKİF ERSOY	324	50	43	39	43	15						514
PAŞACIK	166	78	53	86	280	51	4	28				746
PINAR	319	243	65	19	32	2			1			681
SELÇUKLU	211	70	24	32	20	1						358
Toplam	2745	1399	735	637	814	287	43	72	9	1	1	6743

**Tablo 4.** Çalışma kapsamında ilgili mahallelerin az, orta ve çok katlı bina katsayıları

Mahalleler/ Bina Kat Sayısı	Az Katlı	Orta Katlı	Çok Katlı
BAHÇELİ	1-2 kat	3-4 kat	5-6 kat 6-7-8-9-15 kat
EREĞLİKAPI MAH.	1-2 kat	3-4-5 kat	
FATİH	1-2-3 kat	4-5-6 kat	7-8-9 kat
HACILAR HARMANI	1-2-3 kat	4-5-6 kat	7-8-9 kat
İSTİKLAL	1-2 kat	3-4-5 kat	6-7-8 kat
KILIÇASLAN	1-2 kat	3-4 kat	5-6-14 kat
KURTULUŞ	1-2 kat	3-4 kat	5-6 kat
M. AKİF ERSOY	1-2 kat	3-4 kat	5-6 kat
PAŞACIK	1-2 kat	3-4-5 kat	6-7-8 kat
PINAR	1-2 kat	3-4 kat	5-6-8 kat
SELÇUKLU	1-2 kat	3-4 kat	5-6 kat

#### 4. TARTIŞMA VE SONUÇLAR

Tarihin her döneminde, depremler oldukça sık meydana gelmektedir. Depremler, öncelikle fiziksels hasarların yanı sıra sosyal, ekonomik ve psikolojik kayıplara da neden olmaktadır. Türkiye, konumu gereği etkileri yüksek olan şiddet depremlere maruz kalır. Hasar yapıcı depremlerin en sonucusu Merkez üssü Kahramanmaraş'ın Pazarcık ve Elbistan ilçelerinde meydana gelen 7,7Mw ve 7,6Mw büyüklüğündeki depremler, resmi rakamlara göre en az 53 bin kişinin ölümüne 100 binden fazla kişinin yaralanmasına yol açtı. "Asrin felaketi" olarak kayıtlara geçen ve 11 ili etkileyen 7,7Mw ve 7,6 Mw büyüklüğündeki depremlerle sarsılan Kahramanmaraş'ta 285 bin yapı stokunun % 55'i hasar aldı. Deprem sonucunda oluşan hasarı en aza indirmek için, depremlerde kriz yönetim sürecinin önceden titizlikle planlanması gereklidir.

Bu çalışmada Aksaray ilinde meydana gelebilecek 5,1Mw-6,5Mw büyüklüğünde bir depremin oluşturabileceği yaralı önceliklendirme (Triyaj Yöntemi) tahmini yapılmıştır. Bu çalışmada, kayıpların fiziksels boyutu incelenmiştir. Olası bir yıkıcı deprem sonrası yapılan çalışmaların en önemli amacı, can kayıplarını minimize etmektir. Ekonomik, sosyal ve psikolojik unsurlar, meydana gelen fiziksels kayıpların arkasında yatan etkenlerdir. Bu nedenle, deprem senaryosu hazırlanırken ağır yaralı, hafif yaralı ve ölü sayılarının toplamı tahmin edilmeye çalışılmıştır. Bu tahminlerin doğruluğu, deprem sonrası kriz yönetiminde yöneticilerin daha hızlı karar almasına ve kaynakların daha düzenli ve etkin bir şekilde dağıtımasına yardımcı olacaktır.

Deprem simülasyon sonucunda referans alınan bölüm RECORD modülü ile 5. aşamada yer alan 9 farklı daldan hesaplanan T1, T2, T3 ve T4 yaralı gruplarıdır. Örneğin, Ereğlikapi mahallesi için 10 kez çalıştırılan simülasyon sonuçlarının ortalama değerleri Şekil 6'te sunulmuştur. Deprem simülasyon çalışmasının sonuçları Ereğlikapi

Mahallesi üzerinde değerlendirilecektir. Bu sebeple mahalle ile ilgili bazı veriler simülasyon değerlendirilmesi için önem taşımaktadır. Mahalle, nüfus olarak Aksaray ilinin en kalabalık mahallelerinden biridir. Simülasyon sonucunda Ereğlikapi mahallesi için 5,1 Mw ve 6,5 Mw büyüklüğündeki depremin meydana gelmesi durumunda zemin profili ve bina kat sayısı bilgilerine göre T1, T2, T3 ve T4 grubunda yer alan kişilerin yoğunluk olarak hangi alanlarda bulunduğu sonuçları aşağıdaki Tablo 5'te ve Tablo 6'da sunulmuştur. Simülasyon çalışması öncesinde Tablo 2'de zemin profili iyi, orta ve kötü dağılımı Ereğlikapi için, iyi oranı %10, orta oranı %40 ve kötü oranı %60 olarak belirlenmiştir. Tablo 5'te 2. sütunda yer alan bina katsayı oranları ise Tablo 4'te açıklanmıştır. Ereğlikapi mahallesi toplam nüfusunun 5,1 Mw büyüklüğündeki olası depremde % 0,66 ve 6,5 Mw büyüklüğündeki olası depremde % 0,69 deprem senaryosu sonuçlarına göre sağlık açısından zarar görmüştür.

**Tablo 5.** Aksaray Ereğlikapi Mahallesi simülasyon sonucunun analizi (5,1 Mw)

Zemin Profili	Bina Kat Sayısı	T1	T2	T3	T4
İyi	Az Katlı	0	26	876	0
	Orta Katlı	0	26	545	0
	Çok Katlı	0	26	532	0
Orta	Az Katlı	0	26	1689	0
	Orta Katlı	0	13	938	0
	Çok Katlı	0	13	1243	0
Kötü	Az Katlı	13	139	4961	0
	Orta Katlı	0	128	3576	0
	Çok Katlı	0	139	3997	0
Toplam		13	536	18357	0

**Tablo 6.** Aksaray Ereğlikapi Mahallesi simülasyon sonucunun analizi (6,5 Mw)

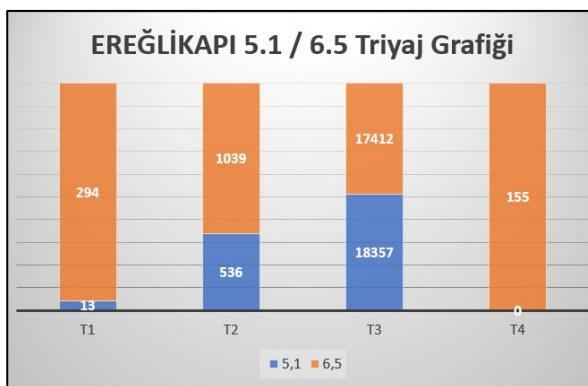
Zemin Profili	Bina Kat Sayısı	T1	T2	T3	T4
İyi	Az Katlı	0	13	849	0
	Orta Katlı	0	39	595	0
	Çok Katlı	0	13	480	26
Orta	Az Katlı	13	51	1739	0
	Orta Katlı	0	13	772	13
	Çok Katlı	26	51	1115	0
Kötü	Az Katlı	90	303	5177	13
	Orta Katlı	115	304	3286	26
	Çok Katlı	50	252	3399	77
Toplam		294	1039	17412	155

Çalışma kapsamında yer alan Aksaray merkez 11 mahallelerin 5,1 Mw ve 6,5 Mw büyüklüğündeki deprem senaryosu sonuçları Tablo 7'de ve Tablo 8'de sunulmuştur. 5,1 Mw büyüklüğündeki deprem simülasyon sonucuna göre ağır yaralı (T1) 59,

geciktirilebilir yaralı (T2) 2454, hafif yaralı (T3) 84458 ve ölü sayısı (T4) 0 olmuştur. Bu senaryoya göre toplam nüfusun yaklaşık % 0,69 deprem sonucunda sağlık durumlarının zarar görmesi nedeniyle etkilenmesi öngörlülmüştür.

Ayrıca 6,5 Mw büyülüğündeki deprem simülasyon sonucuna göre ağır yaralı (T1) 1342, geciktirilebilir yaralı (T2) 4782, hafif yaralı (T3) 80130 ve ölü sayısı (T4) 705 olmuştur. Bu senaryoya göre toplam nüfusun yaklaşık % 0,70 deprem sonucunda sağlık durumlarının zarar görmesi nedeniyle etkilenmesi öngörlülmüştür.

Simülasyon modelinin sonuçlarına göre Ereğlikapı mahallesi 5,1 Mw ve 6,5 Mw büyülüğündeki depremin meydana gelmesi durumundaki triyaj grafiği Şekil 7'te sunulmuştur.



Şekil 7. Ereğlikapı mahallesi triyaj grafiği

Name	Average	HalfWidth	Minimum	Maximum
T1 SAY 1	0	0	0	0
T1 SAY 2	0	0	0	0
T1 SAY 3	0	0	0	0
T1 SAY 4	1,3	2,940804	0	13
T1 SAY 5	0	0	0	0
T1 SAY 6	2,6	3,921072	0	13
T1 SAY 7	9	6,125951	0	25
T1 SAY 8	11,5	6,627516	0	25
T1 SAY 9	5	7,540524	0	25
T2 SAY 1	1,3	2,940804	0	13
T2 SAY 2	3,9	4,492153	0	13
T2 SAY 3	1,3	2,940804	0	13
T2 SAY 4	5,1	6,32191	0	25
T2 SAY 5	1,3	2,940804	0	13
T2 SAY 6	5,1	6,32191	0	25
T2 SAY 7	30,3	9,820356	0	51
T2 SAY 8	30,4	15,99302	0	63
T2 SAY 9	25,2	11,9835	0	63
T3 SAY 1	84,9	29,91878	25	152
T3 SAY 2	59,5	14,88848	25	89
T3 SAY 3	48	20,80693	0	101
T3 SAY 4	173,9	28,73217	101	241
T3 SAY 5	77,2	17,28672	51	114
T3 SAY 6	111,5	23,03072	63	165
T3 SAY 7	517,7	47,77629	419	622
T3 SAY 8	328,6	31,80493	254	406
T3 SAY 9	339,9	53,02168	254	482
T4 SAY 1	0	0	0	0
T4 SAY 2	0	0	0	0
T4 SAY 3	2,6	3,921072	0	13
T4 SAY 4	0	0	0	0
T4 SAY 5	1,3	2,940804	0	13
T4 SAY 6	0	0	0	0
T4 SAY 7	1,3	2,940804	0	13
T4 SAY 8	2,6	3,921072	0	13
T4 SAY 9	7,7	6,345251	0	25
Z1AB	201,5	38,4171	126	266
Z1CB	1309,2	30,67761	1231	1371

Şekil 6. Aksaray Ereğlikapı ARENA simülasyon sonuçları

Tablo 7. Aksaray ili merkez 11 mahallenin simülasyon sonucunun analizi (5,1 Mw)

Mahalle Adı	T1	T2	T3	T4	Toplam	Toplam Nüfus	Etkilenme Oranı
BAHÇELİ	2	87	3229	0	3318	3345	0,81
EREĞLİKAPI	13	536	18357	0	18906	19030	0,66
FATİH	11	452	15213	0	15676	15753	0,49
HACILAR HARMANI	4	168	5656	0	5828	5872	0,75
İSTİKLAL	1	52	2068	0	2121	2143	1,03
KILIÇASLAN	4	171	6074	0	6249	6291	0,67
KURTULUŞ	3	126	4571	0	4700	4744	0,93
M. AKİF ERSOY	4	168	5788	0	5960	6011	0,85
PAŞACIK	12	494	16863	0	17369	17485	0,67
PINAR	3	116	3957	0	4076	4113	0,9
SELÇUKLU	2	84	2682	0	2768	2782	0,51
TOPLAM	59	2454	84458	0	86971	87569	0,69

**Tablo 8.** Aksaray ili merkez 11 mahallenin simülasyon sonucunun analizi (6,5 Mw)

Mahalle Adı	T1	T2	T3	T4	Toplam	Toplam Nüfus	Etkilenme Oranı
BAHÇELİ	46	175	3058	24	3303	3345	1,26
EREĞLİKAPI	294	1039	17412	155	18900	19030	0,69
FATİH	248	873	14439	131	15691	15753	0,4
HACILAR HARMANI	92	328	5369	48	5837	5872	0,6
İSTİKLAL	28	111	1960	13	2112	2143	1,45
KILIÇASLAN	92	339	5762	48	6241	6291	0,8
KURTULUŞ	69	251	4336	36	4692	4744	1,1
M. AKİF ERSOY	92	328	5492	48	5960	6011	0,85
PAŞACIK	271	957	15998	143	17369	17485	0,67
PINAR	64	222	3761	35	4082	4113	0,76
SELÇUKLU	46	159	2543	24	2772	2782	0,36
<b>TOPLAM</b>	<b>1342</b>	<b>4782</b>	<b>80130</b>	<b>705</b>	<b>86959</b>	<b>87569</b>	<b>0,7</b>

Çalışma kapsamında elde edilen sonuçlar, olası deprem sonrası hasar oranını etkileyen zemin profil yapısı ve bina katsayısı parametreleri dikkate alınarak değerlendirildiğinde, zemin profil yapısı kötü ve yüksek katlı binalarda depreme maruz kalan kişi sayısı daha fazla olacaktır. Örneğin, deprem senaryosu çıktılarının gösterildiği Tablo 7 ve Tablo 8'e göre depremden en fazla etkilenen mahalleler arasında Ereğlikapi Mahallesi bulunmakta olup ve Tablo 2'ye bakıldığında, mahallenin %60 oranında zemin profilinin kötü olduğu görülmektedir. Tablo 3'e göre ise, mahallede 7, 8, 9 ve 15 katlı binaların bulunduğu tespit edilmiştir. Bu veriler ışığında, deprem sonrası hasar durumunu zemin profili ve bina kat sayısı gibi parametrelerin önemli ölçüde etkilediği anlaşılmaktadır. Olası bir depremin akabinde, meydana gelebilecek hasarlar ve kayıplar tamamen engellenmez. Ancak, Aksaray ili örneğinde deprem sonrası kayıp tahmin analizi sonuçları gibi senaryo çıktılarının kullanılmasıyla yapılan planlamalar ve düzenlemelerin; hizmet verecek personel, hizmet alacak kişiler ve yönetilecek süreç açısından daha etkili ve verimli olması beklenmektedir.

Deprem senaryosu, simülasyon ile hazırlanmıştır. Simülasyonun en temel amacı, aynı anda birden fazla parametreyi değerlendirme imkanı sunmaktadır. Skolastik (olasılıksal) modellere kıyasla, birden fazla parametreyi ele alan modeller, daha hızlı ve ekonomik sonuçlar sağlar. Simülasyonun bir diğer avantajı, Aksaray ili için tasarlanan yapıının başka iller için de uygun olabilir. Simülasyonun tekrar sayısı artırıldığında, elde edilen sonuçlar daha gerçekçi hale getirilebilir. Önceki deprem sonrası kayıpların tahminine yönelik çalışmalarda simülasyon programı kullanılmamış olması, bu çalışmanın özgünlüğü açısından önemli bir unsurdur ve senaryo oluşturma sürecine farklı bir bakış açısı kazandırmıştır.

Çalışması kapsamında, deprem sonrası hasar tahmini için zemin profili ve bina kat sayısı bilgileri

kullanılmıştır. Çalışmanın devamında, bu parametrelere ek olarak depremin odak derinliği de simülasyon ağına dahil edilerek elde edilen sonuçların gerçekçiliği artırılacaktır. Deprem hasarına etki durumu eklenen her bir parametre için sayısal açıdan değerlendirilebilecektir. Gelecekteki çalışmalar için bir diğer önemli nokta, Aksaray ili merkez mahallelerinin hasar durumlarının 11 mahalle bazında elde edilmiş olmasıdır. Ağ yapısı daha kapsamlı bir şekilde geliştirildiğinde, tek bir simülasyonla çıktıları alınmak istenen bölgenin triyaj analizleri daha hızlı ve tek seferde gerçekleştirilebilir.

### Bilgilendirme/Teşekkür

Bu çalışma, Aksaray Üniversitesi Fen Bilimleri Enstitüsü Jeodezi ve Coğrafi Bilgi Sistemleri ABD'da 1. Yazarın 2. yazar danışmanlığında yürütüldüğü tez çalışmasının bir bölümündür. Yazarlar, çalışma kapsamında kullanılan verilerin temini için Aksaray Belediyesi, Aksaray İl Özel İdaresi'ne ve analizlerin yapılması ve değerlendirilmesi konusundaki katkıları için Antalya Bilim Üniversitesi Arş. Gör. Ümran KAYA'ya teşekkür ederler.

### Araştırmacıların katkı oranı beyan özeti

A. Akşit : Verilerin toparlanması, Araştırma, Görselleştirme, Kontrol, Makale Yazımı  
S. Ekercin : Sonuçların kontrolü, Görselleştirme  
Ü. Kaya : Veri analizi, Araştırma, 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 gerektirdiğini beyan etmektedir.

## KAYNAKÇA

Aki, K. ve Richards, PG (2002). Kantitatif sismoloji .

Cornell, C. A. (1968). Engineering seismic risk analysis. Bulletin of the seismological society of America, 58(5), 1583-1606.

Crozi, M., Galetto, R., & Spalla, A. (2005). Deprem sonrası acil durumları yönetmek için bir Web CBS. Afet Yönetimi için Coğrafi Bilgi , 1255-1270.

Çiftçi, S., Çakırer, Z., & Sakallı, Ü. (2020). Simülasyon çalışması ile deprem senaryosu oluşturulması ve Kırıkkale ili kayıp tahmin analizi. International Journal of Engineering Research and Development, 12(2), 603-617.

Doğan, M. (2015). İl bazında afet lojistiği: Kocaeli ili örneği. Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü Yayınlanmamış Yüksek Lisans Tezi.

Gezgin, C. (2020). Gnss ve insar teknikleri ile Tuz Gölü fay zonu'nun (TGFZ) kinematik analizi. Doktora Tezi, Aksaray Üniversitesi Fen Bilimleri Enstitüsü.

Gerdan, S. (2021). Kentsel planlama açısından il afet risk azaltma planlarının değerlendirilmesi. Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi, 10(4), 1006-1012.

Göktaş, B. (2021). Aksaray ili 5 ve 6 nolu yağmursuyu drenaj bölgelerinin jeoteknik özelliklerinin incelenmesi (Master's thesis, Aksaray Üniversitesi Fen Bilimleri Enstitüsü).

Gutenberg, B., & Richter, C. F. (1955). Magnitude and energy of earthquakes. Nature, 176(4486), 795-795.

İşık, E., Sağır, Ç., Tozlu, Z., & Ustaoğlu, Ü. S. (2019). Farklı deprem senaryolarına göre Kırşehir ili kayıp tahmin analizleri.

Jaiswal, K., Wald, D., & D'Ayala, D. (2011). Developing empirical collapse fragility functions for global building types. *Earthquake Spectra*, 27(3), 775-795.

JICA, I. (2002). The study on a disaster prevention/mitigation basic plan in Istanbul including seismic microzonation in the Republic of Turkey. Pacific Consultants International, OYO Corporation, İstanbul.

Karaman, H., & ŞAHİN, M. (2011). Zeytinburnu ilçesi için deprem hasar tahmini çalışması. İTÜ.

Kürçer, A. (2012). Tuz Gölü Fay Zonu'nun Neotektonik Özellikleri ve Paleosismolojisi, Orta Anadolu, Türkiye.DERGİSİ/d, 8(3).

Kaya, İ., & Yıldırım, S. (2012). Afet Yönetimi ve Stratejik Planlama. İstanbul: Nobel Yayın Dağıtım.

Küçükçoban, S. (2004). Sismik hasar tahmini için bir yazılımın geliştirilmesi: Vaka çalışmaları (Yüksek lisans tezi, Orta Doğu Teknik Üniversitesi).

Özmen, B., & Can, H. (2016). Ankara için deterministik deprem tehlike analizi. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 31(1).

Pulat, M., Bayyurt, D., & Kocakoç, İ. D. (2023). Kayıt Sistemi Süreç İyileştirmesinde Simülasyon Tekniğinin Kullanımı ve Bir Uygulaması. Karadeniz Fen Bilimleri Dergisi, 13(1), 42-59.

Wang, Y., Li, W., & Lu, J. (2009). Reliability analysis of phasor measurement unit using hierarchical Markov modeling. *Electric Power Components and Systems*, 37(5), 517-532.

Wilson, D. T., Hawe, G. I., Coates, G., & Crouch, R. S. (2013). A multi-objective combinatorial model of casualty processing in major incident response. European Journal of Operational Research, 230(3), 643-655



© Author(s) 2024.

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